РОССИЙСКАЯ АКАДЕМИЯ НАУК

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ
РОССИЙСКОЙ ФЕДЕРАЦИИ (МИНОБРНАУКИ РОССИИ)

ГОСУДАРСТВЕННАЯ КОРПОРАЦИЯ ПО АТОМНОЙ ЭНЕРГИИ «РОСАТОМ»

РОССИЙСКАЯ АССОЦИАЦИЯ НЕЙРОИНФОРМАТИКИ

НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ЯДЕРНЫЙ УНИВЕРСИТЕТ «МИФИ»

НАУЧНО-ИССЛЕДОВАТЕЛЬСКИЙ ИНСТИТУТ СИСТЕМНЫХ ИССЛЕДОВАНИЙ РАН

НЕЙРОИНФОРМАТИКА-2020

XXII МЕЖДУНАРОДНАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ

СБОРНИК НАУЧНЫХ ТРУДОВ

- **АДАПТИВНОЕ ПОВЕДЕНИЕ И ЭВОЛЮЦИОННОЕ МОДЕЛИРОВАНИЕ**
- **НЕЙРОБИОЛОГИЯ**
- **ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ**
- **НЕЙРОСЕТЕВЫЕ СИСТЕМЫ ОБРАБОТКИ ДАННЫХ, РАСПОЗНАВАНИЯ ОБРАЗОВ И УПРАВЛЕНИЯ**
- **НЕЙРОННЫЕ СЕТИ И КОГНИТИВНЫЕ НАУКИ**

МОСКВА

УДК 001(06)+004.032.26(06)
ББК 72я5+32.818я5
М 82

XXII МЕЖДУНАРОДНАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ «НЕЙРОИНФОРМАТИКА-2020»: Сборник научных трудов. М.: НИЯУ МИФИ, 2020. – 416 с.

Сборник научных трудов содержит доклады, включенные в программу XXII МЕЖДУНАРОДНОЙ НАУЧНО-ТЕХНИЧЕСКОЙ КОНФЕРЕНЦИИ «НЕЙРОИНФОРМАТИКА-2020», проходившей 12–16 октября 2020 г. в онлайн-формате. Тематика конференции охватывает широкий круг вопросов: методические вопросы нейроинформатики, теория нейронных сетей, нейробиология, модели адаптивного поведения и когнитивные исследования, нейронные сети для управления, обработки изображений, временных рядов и другие приложения нейроинформатики.

В сборник включены доклады, посвященные теоретическим исследованиям искусственных нейронных сетей и их применению в задачах управления, прогнозирования и распознавания образов, моделированию в нейробиологии, когнитивным исследованиям, а также адаптивному поведению и эволюционному моделированию.

Ответственный редактор *А.Г. Трофимов*

Статьи получены до 30 июня 2020 года.
Материалы издаются в авторской редакции.

ISBN 978-5-7262-2707-8

© *Национальный исследовательский ядерный университет «МИФИ», 2020*

Оригинал-макет подготовлен *М.В. Макаровой*

Подписано в печать 05.11.2020. Формат 60×84 1/16.
Печ. л. 26,0. Тираж 100 экз. Заказ №

Национальный исследовательский ядерный университет «МИФИ»
Типография НИЯУ МИФИ
115409, Москва, Каширское ш., 31

ОРГАНИЗАТОРЫ КОНФЕРЕНЦИИ

- Российская академия наук
- Министерство науки и высшего образования Российской Федерации (Минобрнауки России)
- Государственная корпорация по атомной энергии «Росатом»
- Российская ассоциация нейроинформатики
- Научно-исследовательский институт системных исследований РАН (НИИСИ РАН)
- Национальный исследовательский ядерный университет «МИФИ» (НИЯУ МИФИ)
- Московский физико-технический институт (национальный исследовательский университет)
- Московский авиационный институт (национальный исследовательский университет), МАИ
- Государственный научный центр РФ Троицкий институт инновационных и термоядерных исследований (ГНЦ РФ ТРИНИТИ)

ОРГАНИЗАЦИОННЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – Климов В.В. (НИЯУ МИФИ, Москва)
Зам. председателя – Юдин Д.А. (МФТИ, Москва)
Акопов Э.И. – НИИСИ РАН, Москва
Смирнитская И. А. – НИИСИ РАН, Москва
Терехов С.А. – ЗАО «Связной Логистика», Москва
Трофимов А.Г. – НИЯУ МИФИ, Москва
Тюменцев Ю.В. – МАИ, Москва
Шумский С.А. – МФТИ, Москва
Ученый секретарь – Бесхлебнова Г.А. (НИИСИ РАН, Москва)

ПРОГРАММНЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – Gorban A. (University of Leicester, Great Britain)
Сопредседатель – чл.-кор. РАН Крыжановский Б.В. (НИИСИ РАН, Москва)
Сопредседатель – Дунин-Барковский В.Л. (НИИСИ РАН, Москва)
Сопредседатель – Шумский С.А. (МФТИ, Москва)
Abraham A. – Machine Intelligence Research Labs (MIR Labs), Washington, USA
Baidyk T. – The National Autonomous University of Mexico (UNAM)
Borisyuk R. – Plymouth University, United Kingdom
Cangelosi A. – Plymouth University, United Kingdom
Dosovitskiy A. – Albert-Ludwigs-Universität, Freiburg, Germany
Dudkin A. – United Institute of Informatics Problems of the National Academy of Sciences of Belarus, Minsk
Golovko V.A. – Brest State Technical University, Belarus
Hayashi Y. – Meiji University, Kawasaki, Japan
Husek D. – The Institute of Computer Science of Academy of Sciences of the Czech Republic, Prague
Izhikevich E. – Braincorporation, San Diego, USA
Jankowski S. – Warsaw University of Technology, Poland
Kecman V. – Virginia Commonwealth University, USA
Kernbach S. – Cybertronica Research, Research Center of Advanced Robotics and Environmental Science, Stuttgart, Germany
Koprinkova-Hristova P. – Institute of Information and Communication Technologies, Sofia, Bulgaria
Kussul E. – The National Autonomous University of Mexico (UNAM)
Narynov S. – Alem Research, Almaty, Kazakhstan
Pareja-Flores C. – Universidad Complutense de Madrid, Spain
Prokhorov D. – Toyota Research Institute of North America, USA
Rutkowski L. – Czestochowa University of Technology, Poland
Samsonovich A. – George Mason University, USA
Sandamirskaya Y. – Institute of Neuroinformatics, University of Zurich, Switzerland
Sirota A. – Ludwig-Maximilians-Universität, München, Germany

Snasel V. – Technical University Ostrava, Czech Republic
Tikidji-Hamburyan R. – Louisiana State University, USA
Tsodyks M. – Weizmann Institute of Science, Rehovot, Israel
Tsoy Y. – Institut Pasteur Korea, Republic of Korea
Wunsch Donald – Missouri University of Science and Technology, USA
Бурцев М.С. – МФТИ, Москва
Введенский В.Л. – НИЦ «Курчатовский институт», Москва
Доленко С.А. – НИИЯФ им. Д.В. Скобельцына МГУ, Москва
Ежов А.А. – ГНЦ РФ ТРИНИТИ, Москва
Жданов А.А. – ИТМиВТ РАН, Москва
Каганов Ю.Т. – МГТУ им. Н.Э. Баумана, Москва
Казанович Я.Б. – ИМПБ РАН – филиал ИПМ им. М.В. Келдыша РАН, Московская область, Пущино
Литинский Л.Б. – НИИСИ РАН, Москва
Макаренко Н.Г. – ГАО РАН, Санкт-Петербург
Мишулина О.А. – НИЯУ МИФИ, Москва
Редько В.Г. – НИИСИ РАН, Москва
Самарин А.И. – НИИ нейрокибернетики им. А.Б. Когана Южного федерального университета, Ростов-на-Дону
Терехов С.А. – ЗАО «Связной Логистика», Москва
Трофимов А.Г. – НИЯУ МИФИ, Москва
Тюменцев Ю.В. – МАИ, Москва
Ушаков В.Л. – НИЦ «Курчатовский институт», Москва
Чижов А.В. – Физико-технический институт им. А.Ф. Иоффе РАН, Санкт-Петербург
Яхно В.Г. – ИПФ РАН, Нижний Новгород

Уважаемые коллеги!

Конференция НЕЙРОИНФОРМАТИКА вновь собирает исследователей, работающих по актуальным направлениям теории и приложений искусственных нейронных сетей. Как и на предыдущих наших собраниях, в этом году на конференции НЕЙРОИНФОРМАТИКА-2020 представлены доклады по проблемам теории нейронных сетей, нейробиологии, моделям адаптивного поведения, нейросетевому моделированию объектов и систем, обработке статистических данных, временных рядов и изображений и многим другим прикладным задачам нейроинформатики.

Более 200 российских ученых и наших зарубежных коллег направили в оргкомитет конференции результаты своих исследований.

В этом году конференция проходит в рамках I Национального Конгресса по когнитивным исследованиям, искусственному интеллекту и нейроинформатике впервые в онлайн-формате. Программа конференции традиционно включает приглашенные доклады, лекции известных специалистов по актуальным проблемам нейроинформатики, секционные доклады и постерные сессии.

Особое внимание уделяется работам студентов, аспирантов и молодых специалистов, которые примут участие в творческом конкурсе.

За прошедшие годы конференция НЕЙРОИНФОРМАТИКА сложилась как представительный и многоплановый по тематике научный форум. В его работе принимают участие и известные ученые, и молодые специалисты, аспиранты и студенты. Желаем всем участникам конференции плодотворной работы, активного сотрудничества и новых творческих идей.

Оргкомитет

СОДЕРЖАНИЕ

Секция 1

АДАПТИВНОЕ ПОВЕДЕНИЕ И ЭВОЛЮЦИОННОЕ МОДЕЛИРОВАНИЕ

CHERNENKIY V.M., BELOUSOV E.A., POPOV I.A., GAPANYUK Y.E.
An Approach to Automated Metagraph Construction Based on the Hopfield Neural Network 11
ШЕСТАКОВ Е.И., ЖДАНОВ А.А.
Адаптивное управление модульным реконфигурируемым манипуляционным роботом 18

Секция 2

НЕЙРОБИОЛОГИЯ

МАЙОРОВ В.И.
Модель инструментализации движений, вызванных стимуляцией сенсомоторной коры 27
ГОЛУБЕВА Д.Н., ЧИЖОВ А.В., МАЛКИН С.Л.
Математическая модель влияния транспортеров глутамата EAAT2 на постсинаптические сигналы 37
МАЙОРОВ В.И.
Модель когнитивной карты в гиппокампе: ассоциация клеток места и направления 45
БОЖОКИН С.В.
Корреляция вспышек в нестационарной ЭЭГ 54
РАТУШНЯК А.С., МАЛАХИН И.А., ЗАПАРА Т.А.
Моделирование биологически инспирированных информационных систем через эволюцию простейших агентов 64
BARTSEV S.I., MARKOVA G.M.
On Detecting Neural Correlates in Simple Recurrent Neural Networks Passed the Delayed Matching to Sample Test 72
MALYKHINA G.F., SALNIKOV V.Y., SEMENYUTIN V.B.
Neural Network Algorithm for the Diagnosis of Impaired Cerebral Autoregulation 82
ПЕРМЯКОВ С.А., КУЗНЕЦОВ А.А.
Классификация функциональных состояний сердечно-сосудистой системы на основе паттернов амплитудно-фазового сопряжения ЭКГ 93

ПРОСКУРА А.Л., ВЕЧКАПОВА С.О., РАТУШНЯК А.С.
Молекулярные механизмы контроля эффективности возбуждающей синаптической передачи лептином в гиппокампе . 103
ВОРОНКОВ Г.С., ИЗОТОВ В.А.
Нейронный механизм константного экрана 112
KULIKOVA S.P.
Optimization of the TMS Coil Position Based on Diffusion Tractography Data..... 120

Секция 3

ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ

SHATS V.N.
Two Simple Classification Algorithms Based on Information Granulation..... 127
ДОРОГОВ А.Ю.
Регулярная нейронная сеть с фовеальной архитектурой 134
КРЫЖАНОВСКИЙ Б.В., ЛИТИНСКИЙ Л.Б., КАГАНОВА И.М.
Метод *n*-окрестностей для модели Изинга с дальнодействием 144
МАЦУКАТОВА А.Н., ЕМЕЛЬЯНОВ А.В., МИННЕХАНОВ А.А., ШВЕЦОВ Б.С., САХАРУТОВ Д.А., НЕСМЕЛОВ А.А., ДЕМИН В.А., РЫЛЬКОВ В.В., ФОРШ П.А., ЧВАЛУН С.Н., КАШКАРОВ П.К.
Эффекты второго порядка в мемристорах на основе поли-*n*-ксилилена..... 155
KUZNETSOV V.V., MOSKALENKO V.A., ZOLOTYKH N.YU.
Electrocardiogram Generation and Feature Extraction Using a Variational Autoencoder 165
ТИХОНОВ И.В., ЖДАНОВ А.А.
Алгоритм динамического слежения за объектами в режиме реального времени..... 174
ГОРБАНЬ А.Н., ПАРИН С.Б., ПОЛЕВАЯ С.А., ФИЛЯЕВ М.А., АШИНА Н.П., НУЙДЕЛЬ И.В., ШЕМАГИНА О.В., ЯХНО В.Г.
Моделирование этапов поведения человека при стрессовых нагрузках 183
МАСЛЕННИКОВ О.В., НЕКОРКИН В.И.
Динамика рекуррентных сетей частотных нейронов при контролируемом обучении генерации переключательных последовательностей 195
ЛАВРОВ Н.В., ЛАВРОВ В.В.
Классификация межнейронных связей внутри нейронных сетей ... 204
ДОРОГОВ А.Ю.
Самоподобные структуры многослойных нейронных сетей..... 214

Секция 4

НЕЙРОСЕТЕВЫЕ СИСТЕМЫ ОБРАБОТКИ ДАННЫХ, РАСПОЗНАВАНИЯ ОБРАЗОВ И УПРАВЛЕНИЯ

SHIRIYAZDANOV R., RUDNEV N., USTYUZHANIN K.
Application of Neural Network Algorithms
in Modelling and Optimization of Chemical Processes 225
МИКРЮКОВ А.А., МАЗУРОВ М.Е.
Когнитивная модель сценарного прогнозирования основных векторов
интернационализации деятельности университета 232
PILGUN M., KHARLAMOV A.A.
Predictive Analytics of Digital Conflicts:
a Neural Network Approach 241
ЛИТВИНОВ О.С., ЗАБЕЛИН А.Н.
Особенности подавления широкополосных помех
в адаптивных антенных решётках на нейросетевом управлении 250
АГЕЕВ А.В., СМОЛИН В.С., СОКОЛОВ С.М.
О задаче формирования системы управления
на основе нейронной сети 259
ЛИТВИНОВ О.С., МУРОДЬЯНЦ Д.В., КАРАНДАШЕВ Я.М.
Исследование характеристик подавления шумов
в адаптивных антенных решетках при нейросетевом управлении
фазовращателями в различных режимах их функционирования 269
ТАРАСОВ А.С., НИКИФОРОВ М.Б., ТАРАСОВА В.Ю.
Применение возможностей нейронных сетей
в задачах сопровождения подвижных объектов 277
ТАРАСОВ А.С., ТАРАСОВА В.Ю.
Разработка системы поиска похожих изображений
в локальных хранилищах 286
МАРЬЯСИН О.Ю., ЛУКАШОВ А.И.
Прогнозирование свободных цен на электроэнергию
с использованием нейронных сетей 294
KONNOVA N.
Automation of the Cardiovascular System States Diagnostics According
to Flowmetry Data With Application of Neural Network Algorithms... 304
СТАРКОВ С.О., ЛАВРЕНКОВ Ю.Н.
Управление доступом к среде передачи данных
в распределенных информационных системах
на базе рекуррентных нейронных ячеек 313

BASARAB M., IVANOV I., LUNIN B.
Neural Network Algorithm for Forecasting and Parameter Estimation of the Coriolis Vibratory Gyroscope 324
МАЛЫХИНА Г.Ф., МЯЭ М.А.
Автоматическая классификация кристаллов с использованием нейронных сетей 333

Секция 5

НЕЙРОННЫЕ СЕТИ И КОГНИТИВНЫЕ НАУКИ

ФОКИН С.И.
Математическая модель первичного нейрона рецептора 341
TIKHOMIROVA D.V., SAMSONOVICH A.V.
Empathy Facilitates Human Recognition of Artificial Intelligence Agents in a Social-Emotional Videogame 351
АЛЕКСЕЕВА А.Н., КРОТКОВА О.А., ГАЛКИН М.В., КАВЕРИНА М.Ю., ДАНИЛОВ Г.В.
Качественные оценки как один из вариантов преобразований многофакторной динамики в когнитивной сфере 359
ПЛОТНИКОВ С.А., КРОПОТОВ Ю.Д., ЛИПКОВИЧ М., СЕМЕНОВ Д.М., ФРАДКОВ А.Л.
Алгоритм нейрообратной связи с использованием методов искусственного интеллекта 367
ТЕЛЬНЫХ А.А., НУЙДЕЛЬ И.В., ШЕМАГИНА О.В.
Биоморфная структурно-функциональная модель обработки зрительных сигналов в живых системах 377
БОГАТЫРЕВ А.А., БРАНИЦКИЙ А.А., ВАНЧАКОВА Н.П., ДОЙНИКОВА Е.В., КОТЕНКО И.В., КРАСИЛЬНИКОВА Н.В., ЛЕВШУН Д.С., ТИШКОВ А.В.
Методики выявления и профилактики деструктивных форматов коммуникативного поведения молодежи в социальных сетях 388
ФИЛАТОВ Н.С., ЛИТВИНОВ О.В., УЛАНОВ В.Н.
Модели представления языка как ключевой элемент для автоматического реферирования текста 397
ДЕМАРЕВА В.А.
Характеристики фиксаций глаз на словах разного семантического класса при чтении на английском языке как отображение уровня языковой компетенции 405

Именной указатель авторов 411

Секция 1

Адаптивное поведение и эволюционное моделирование

V.M. CHERNENKIY, E.A. BELOUSOV, I.A. POPOV, Y.E. GAPANYUK
Bauman Moscow State Technical University, Russia
gapyu@bmstu.ru

AN APPROACH TO AUTOMATED METAGRAPH CONSTRUCTION BASED ON THE HOPFIELD NEURAL NETWORK

The article proposes an approach to automated metagraph construction based on the Hopfield neural network. The metagraph model is a kind of complex network model with emergence. Thus, constructing a metagraph model based on a compound domain is a complex task that requires automation. A brief description of the Hopfield neural network is given. The algorithm for automated metagraph generation based on Hopfield neural network is proposed. The vertices and metavertices of metagraph are represented as vertices-nodes, which are uniquely defined by a set of features. A feature may be an attribute belonging to vertex (metavertex), the nested vertex (metavertex), or the nested edge. The Hopfield neural network is trained on the metagraph data, and then a new vertex-node is passed to the network for recognition. As a result of recognition, two cases can occur. In the first case, the Hopfield neural network returns a spurious pattern. Therefore, the added vertex-node is not close to any of the existing ones; therefore, it should be added to the metagraph as an independent vertex-node. In the second case, the vertex-node that the Hopfield network returns is close to the new vertex-node, and it is correct to combine both vertices-nodes into one new metavertex. The results of experiments show that the proposed approach can be used for metagraph construction.

Keywords: *complex network, metagraph, metavertex, Hopfield neural network, spurious pattern.*

1. Introduction

Currently, models based on complex networks are increasingly used in various fields of science, from mathematics and computer science to biology and

sociology. The main Russian-language articles on complex networks are the works [1, 2]. In the article [3], it is suggested to use complex networks as a basis for building complex biological models.

According to [4]: «a complex network is a graph (network) with non-trivial topological features – features that do not occur in simple networks such as lattices or random graphs but often occur in graphs modeling of real systems.» The terms «complex network» and "complex graph" are often used synonymously. According to [5]: «the term 'complex network,' or simply 'network,' often refers to real systems while the term 'graph' is generally considered as the mathematical representation of a network.»

The metagraph model is a kind of complex graph (network) model with emergence, proposed by A. Basu and R. Blanning in their book [6] and then adapted for information systems description in articles [7, 8].

The most significant element of the metagraph model is the metavertex. The metavertex, in addition to the attributes, includes a fragment of the metagraph. The presence of private attributes and connections for metavertex is a distinguishing feature of the metagraph. It makes the definition of metagraph holonic – metavertex may include a number of lower-level elements and, in turn, may be included in a number of higher-level elements.

Designing a knowledge metagraph manually is a time-consuming task that may require significant human resources. Thus, this task requires automation. In this article, we propose an approach to automated metagraph construction based on the Hopfield neural network.

2. The Hopfield Neural Network

The Hopfield neural network [9] is a kind of recurrent neural network that implements associative memory. The Hopfield neural network is designed so that its response to the memorized M reference «images» is made up of these images themselves. If the image is slightly distorted and fed to the input, it will be restored, and the original image will be received as a response. Thus, the Hopfield network performs errors and interference correction. In [10], it is proposed to consider a stable image in a Hopfield network as an attractor in arbitrary state space.

If the input image cannot be assigned to one of the reference images, the network can generate new images that are similar to several reference images at once but are not one of them. Images generated in this way are called spurious patterns.

The Hopfield network has a limit on the number of images it can remember. However, the problem of estimating the number of reference images is quite

complex, and various approaches are proposed to solve it [11]. According to [11], the heuristic $P \approx 0.14 \cdot N$ is generally accepted, which means that if the number of images stored by the network P exceeds 14 % neurons of the network N, then the network becomes unstable.

The ability of the Hopfield network to work as an associative memory can be used for the task of constructing a metagraph.

3. The Algorithm for Automated Metagraph Generation

For the convenience of explanation of our approach in this section, the term «vertex-node» will be understood as any vertex or metavertex that already exists in the metagraph. Thus, in this section, we abstract from the internal structure of vertices-nodes, which may contain nested vertices (metavertices) and edges, and therefore, actually be metavertices.

To build the algorithm, we need to represent each vertex-node as a set of features. A feature may be an attribute belonging to vertex (metavertex), the nested vertex (metavertex), or the nested edge. Features are binary, feature values 1 and 0 encode, respectively, the presence or absence of a nested attribute, vertex (metavertex), or edge at a vertex-node.

To describe the algorithm, we denote the vertices-nodes as v_i and the features as a_j. Now we can represent each vertex-node as a binary vector in the feature space with which the Hopfield network can work.

The principle of operation of the algorithm is as follows. Let's train the Hopfield neural network on all vertices-nodes of the metagraph. After that, we fix the threshold of the neural network activation function and pass a new vertex-node to it for recognition.

As a result of recognition, two cases can occur. In the first case, the Hopfield neural network returns a spurious pattern. Therefore, the added vertex-node is not close to any of the existing ones; therefore, it should be added to the metagraph as an independent vertex-node. In the second case, the vertex-node that the Hopfield network returns is close to the new vertex-node, and it is correct to combine both vertices-nodes into one new metavertex. The algorithm is represented in Fig. 1 as a UML activity diagram.

Although the set of features is not explicitly used in the algorithm, it should be noted that the methods «HopfieldNet.train» and «HopfieldNet.test» implicitly involve the use of features.

Now consider examples for both cases. Let's assume that the following vertices-nodes v_i are present in the metagraph, and each vertex-node is characterized by the set of features as a_j.

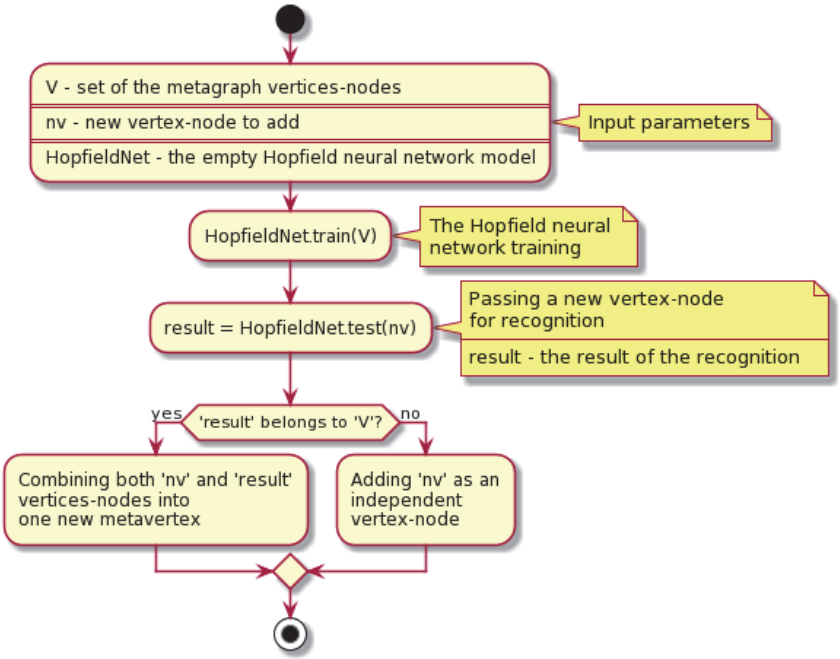

Fig. 1. The algorithm for automated metagraph generation

The example 1 (for case 1). Let the metagraph contains $v_1 = \{a_3, a_4\}$, $v_2 = \{a_2\}$, $v_3 = \{a_1, a_3\}$ (train set). We are adding a new vertex-node $v_4 = \{a_4, a_5\}$ (test set).

Table 1

The object-feature matrix for the example 1

Feature / Object	a_1	a_2	a_3	a_4	a_5	Comment
v_1	0	0	1	1	0	
v_2	0	1	0	0	0	The train set
v_3	1	0	1	0	0	
v_4	0	0	0	1	1	The test set
v_{4_RES}	1	0	0	1	1	The Hopfield network output

After the recognition process is complete, the Hopfield network returns the following vector $v_{4_RES} = \{a_1, a_4, a_5\}$. Among the existing vertices-nodes, there is no such vertex-node; therefore, we got a spurious pattern.

Thus, the v_4 should be added to the metagraph as an independent vertex-node. The object-feature matrix for the example 1 is represented in Table 1.

The example 2 (for case 2). Let the metagraph contains $v_5 = \{a_1, a_3, a_4\}$, $v_6 = \{a_2\}$, $v_7 = \{a_1, a_3\}$ (train set). We are adding a new vertex-node $v_8 = \{a_1, a_2, a_3, a_4, a_5\}$ (test set).

After the recognition process is complete, the Hopfield network returns the following vector $v_{8_RES} = \{a_1, a_3, a_4\}$. Comparing this vector with the vectors of the training set, we find that $v_{8_RES} = v_5$. Thus, the vertex v_8 is attracted to the attractor located at the vertex v_5.

Therefore, the vertices-nodes v_5 and v_8 should be combined into a separate metavertex. The object-feature matrix for the example 2 is represented in Table 2.

Table 2

The object-feature matrix for the example 2

Feature Object	a_1	a_2	a_3	a_4	a_5	Comment
v_5	1	0	1	1	0	
v_6	0	1	0	0	0	The train set
v_7	1	0	1	0	0	
v_8	1	1	1	1	1	The test set
v_{8_RES}	1	0	1	1	0	The Hopfield network output

4. The Experiments

The purpose of the experiments was to build a dependence on the algorithm's execution time on the number of vertices-nodes and features in the testing metagraph. Consider the pair (v, a), where v – is a number of vertices-nodes, and a – is a number of features. For each pair, the random binary matrix $M[v \times a]$ to describe the metagraph, and the random binary vector $nv[v]$ to describe the added vertex-node was constructed. Next, the matrix M was used to train the Hopfield network, and the vector nv was used as the vertex-node for adding. The execution time of the algorithm was measured. The experiment

was performed five times for each point, and the result was the average value of time for five experiments.

The experiments were performed on a server with the following characteristics:

Processor: Intel Core i5-6200U CPU @ 2.30GHz x 4
Memory: 8 GiB
Disk: 128 GB SSD
OS: Ubuntu 16.04 LTS, OS type 64-bit.
Python 3.7.

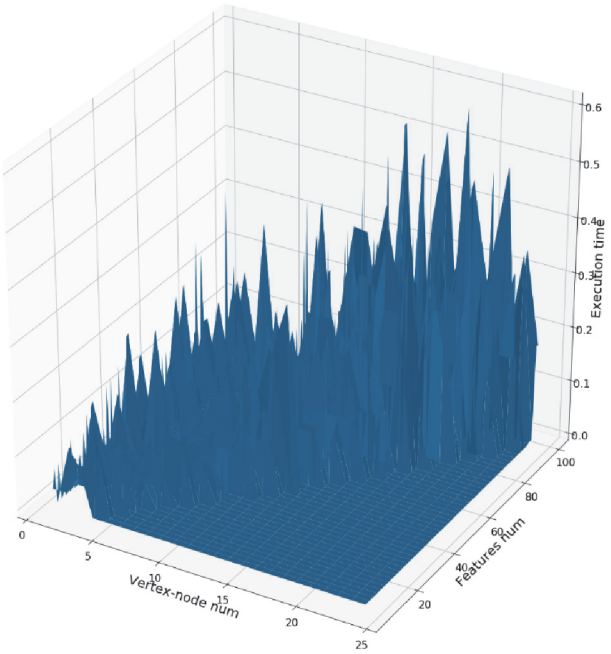

Fig. 2. The dependence of the execution time of the algorithm on the number of features and the number of vertices-nodes

The Fig. 2 shows the dependence of the execution time of the algorithm on the number of features and the number of vertices-nodes.

With a linear increase in the number of features and a linear increase in the number of vertices-nodes, the execution time of the algorithm also grows on average linearly. This result may seem trivial, but it is not, because the meta-

graph model is a complex hierarchy (or rather holarchy) of nodes. An increase in the number of created metavertices can, hypothetically, lead to a significant increase in the running time of the algorithm.

The scope of the function depends on the restrictions imposed by the Hopfield network. With the insufficient number of features and a large number of vertices-nodes, the algorithm cannot be applied.

5. Conclusions

Models based on complex networks are increasingly used in various fields of science. The metagraph model is a kind of complex network model with emergence.

Designing a knowledge metagraph manually is a time-consuming task that may require significant human resources. Thus, this task requires automation.

The ability of the Hopfield network to work as an associative memory can be used for the task of constructing a metagraph. The algorithm for automated metagraph generation is based on the ability of the Hopfield neural network to return spurious patterns. The results of experiments show that the proposed approach can be used for metagraph construction.

References

1. Evin I.A. Vvedenie v teoriyu slozhnikh setey [The introduction of the theory of complex networks]. Kompiuterniye issledovaniya i modelirovaniye [Computer research and modeling]. 2010. 2(2). 121–141.

2. Kuznetsov O.P., Zhilyakova L.Yu. Slozhniye seti i kognitivniye nauki [Complex networks and cognitive sciences]. Trudi XVII vserossiyskoy konferencii «Neuroinformatics-2015» [Proc. XVII all-russian conference «Neuroinformatics-2015»]. Moscow, 2015. 18–20.

3. Anokhin K.V. Kognitom: gipersetevaya model mozga [The cognitome: a hypernetwork brain model]. Trudi XVII vserossiyskoy konferencii «Neuroinformatics-2015» [Proc. XVII all-russian conference «Neuroinformatics-2015»], Moscow, 2015. 14–15.

4. Manoj B.S., Chakraborty A., Singh R. Complex Networks: A Networking and Signal Processing Perspective. Pearson. New York, 2018.

5. Chapela V., Criado R., Moral S., Romance M. Intentional Risk Management through Complex Networks Analysis. SpringerBriefs in Optimization. Springer, 2015.

6. Basu A., Blanning R. Metagraphs and Their Applications. Springer, New York (2007).

7. Chernenkiy V., Gapanyuk Yu., Nardid A., Gushcha A., Fedorenko Yu. The hybrid multidimensional-ontological data model based on metagraph approach. In: Petrenko, A., Voronkov, A. (eds.) Perspectives of System Informatics 2017, LNCS. 2017. Vol. 10742. P. 72–87. Springer, Moscow.

8. Chernenkiy V.M., Gapanyuk Yu.E., Revunkov G.I., Kaganov Yu.T., Fedorenko Yu.S., Minakova S.V. Using metagraph approach for complex domains description. In: Selected Papers of the XIX International Conference on Data Analytics and Management in Data Intensive Domains (DAMDID/RCDL 2017), Moscow, Russia. 2017. P. 342–349.

9. Hopfield J.J. Neural networks and physical systems with emergent collective computational abilities // Proceedings of the National Academy of Sciences of the USA. 1982. Vol. 79. No. 8. P. 2554–2558.

10. Ezhov A.A. Neural Network Model of Unconscious. In: Huang T., Lv J., Sun C., Tuzikov A. (eds) Advances in Neural Networks – ISNN 2018. LNCS. 2018. Vol. 10878. P. 19–28. Springer, Cham.

11. Folli V., Leonetti M., Ruocco G. On the Maximum Storage Capacity of the Hopfield Model // Frontiers in Computational Neuroscience. 2017. 10. 10.3389/fncom.2016.00144.

Е.И. ШЕСТАКОВ, А.А. ЖДАНОВ

Институт точной механики и вычислительной техники им. С.А. Лебедева РАН, Москва (ИТМиВТ РАН)

shesta7@yandex.ru, alexander.a.zhdanov@gmail.com

АДАПТИВНОЕ УПРАВЛЕНИЕ МОДУЛЬНЫМ РЕКОНФИГУРИРУЕМЫМ МАНИПУЛЯЦИОННЫМ РОБОТОМ

В статье предлагается подход к управлению модульным реконфигурируемым манипуляционным роботом, основанный на методе автономного адаптивного управления А.А. Жданова. Решается задача самообучения робота движению в целевую точку и движению по траектории, заданной совокупностью целевых точек. Процесс обучения происходит, в отличие от традиционного подхода, параллельно с управлением. Показаны экспериментальные исследования по применению данного подхода к манипуляторам с различным количеством степеней свободы и величиной угла дискретизации.

Ключевые слова: *адаптивное управление, искусственный интеллект, модульные реконфигурируемые роботы.*

Введение

Классические методы управления сложными динамическими объектами опираются на получение и использование точной аналитической

функциональной зависимости между входными и выходными параметрами. Но на практике во многих случаях установление такой зависимости представляет проблему, если объекты управления плохо поддаются формализации. К такому типу объектов относятся и модульные реконфигурируемые роботы, концепция построения которых предполагает наличие однотипных мехатронных модулей, объединяемых в единую многозвенную конструкцию. Благодаря возможностям стыковки и расстыковки модулей друг с другом робот может изменять свою кинематическую структуру, в зависимости от условий внешней среды и целевой задачи. Исследователи в области модульных роботов выделяют четыре основные конфигурации: «гусеница», «колесо», «шагающая платформа» и «манипулятор» (рис. 1.) и рассматривают проблемы реконфигурации, т.е. перехода из одной конфигурации в другую [1].

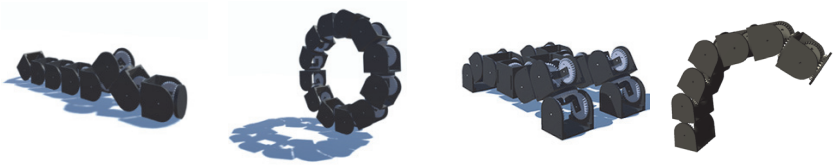

а *б* *в* *г*

Рис. 1. Типовые конфигурации модульных роботов

Для каждой из перечисленных конфигураций существуют алгоритмы управления, например [1]. Однако эти алгоритмы не всегда удается сделать достаточно робастными по отношению к возможным изменениям свойств робота в процессе его функционирования. Например, возможны изменения свойств приводов и датчиков или выход из строя некоторых модулей.

В связи с этим представляется актуальным вопрос о применении к управлению модульным реконфигурируемым роботом адаптивных методов управления. В настоящей статье предлагается применение с этой целью метода *автономного адаптивного управления* (ААУ) А.А. Жданова [2]. А именно, мы применили систему ААУ для организации самообучения модульного робота-манипулятора перемещениям его схвата в заданную точку. В данной работе развиваются идеи авторов, представленные в предыдущих публикациях [2-4]. Рассматриваются: актуальность применения адаптивных алгоритмов управления многозвенными манипуляционными роботами, краткое описание метода ААУ, примененного для управ-

ления таким роботом, программная среда моделирования и результаты экспериментальных исследований.

Постановка задачи

Классические методы управления многозвенными манипуляционными роботами предполагают аналитическое решение обратной задачи кинематики, т.е. нахождение углов поворота в сочленения механизма по координатам точки в пространстве. Сложность получения аналитической функциональной зависимости при увеличении количества сочленений, связанная с тем, что такие объекты управления зачастую плохо поддаются априорной математической формализации, вынуждает применять неклассические методы, использующие понятия информации и знаний, и часто называемые интеллектуальными. Это методы нечеткой логики, нейронные сети, генетические алгоритмы и некоторые другие, которые во многих случаях позволяют получать решение, хотя и не всегда гарантируют точность. Основная причина, мешающая достигать желаемой точности управления, связана с тем, что такие «интеллектуальные» методы, хотя и позволяют избежать математического моделирования объекта управления, но требуют априорной настройки по обучающим выборкам, после которой уже не допускают дообучения или переобучения в рабочем режиме. Это ограничивает сферу их применения, так как объекты управления часто обладают изменчивостью свойств, что требует от системы управления способности к динамической «адаптации», непосредственно в процессе управления. В качестве первого шага в этом направлении рассмотрено адаптивное управление для обучения робота движению в заданную точку, затем – движению по траектории, заданной совокупностью точек.

Описание метода ААУ

Приведем краткое описание метода ААУ. На рис. 2 показана общая структура системы, в которой, в отличие от традиционного подхода, принятого в теории управления, управляющая система (УС) является частью объекта управления ОУ. Исходя из этого, УС одновременно осуществляет две функции: управление и самообучение [2].

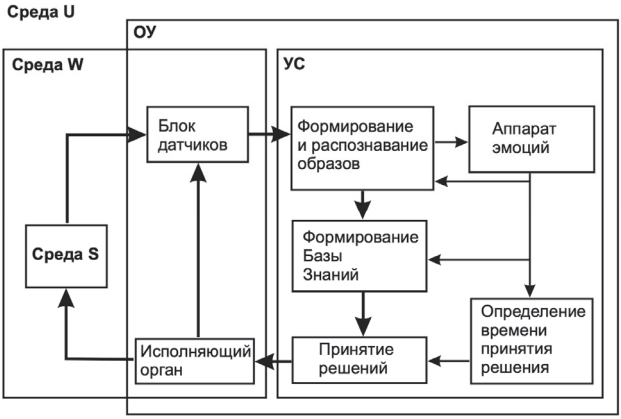

Рис. 2. Общая структура системы ААУ

Получая данные от датчиков, подсистема «Формирования и Распознавания образов» решает задачи самообучаемой системы распознавания. «Аппарат эмоций» – целезадающая подсистема качественного оценивания состояний – рассчитывает текущую «эмоциональную» оценку, на основании которой принимаются решения о действии. Принятое решение о действии сообщается исполнительным органам и запоминается для дальнейшего анализа. Подсистема «Формирования Базы Знаний» выявляет новые знания о причинно-следственных связях «образов» и «действий». Управление повторяется циклически с заданной постоянной времени.

Описание объекта в терминах ААУ и программной среды моделирования

Для применения метода ААУ необходимо соотнести элементы объекта управления, в данном случае модульного реконфигурируемого манипуляционного робота, с элементами системы управления, а именно, определить наборы датчиков, «образов», «действий», которые система может совершать, а также способ определения «эмоциональных» оценок распознаваемых образов.

В данном случае, измеряемыми параметрами являются значения углов в сочленениях манипулятора. Такие показания могут давать потенциометры, абсолютные энкодеры и другие средства измерений. «Образы» для системы управления будут представлять собой набор обобщенных координат $C = \{q_1, \ldots, q_n\}$, определяющий текущую конфигурацию модульно-

го робота. Этим обеспечивается *наблюдаемость* системы. В качестве примера на рис. 3 приведены различные наборы координат и соответствующие им конфигурации модульного реконфигурируемого робота.

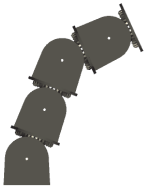

C = {20, 0, 45, 0}

а

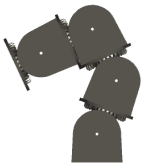

C = {20, -45, -90, 0}

б

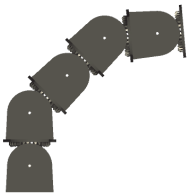

C = {0, 45, 0, 45, 0}

в

Рис. 3. Примеры конфигураций
манипуляционного реконфигурируемого модульного робота

Мы положили, что нормированная «эмоциональная» оценка распознанного образа зависит от расстояния d конца кинематической цепи до целевой точки, размера её ε-окрестности и рассчитывается по формуле:

$$Em = \begin{cases} \varepsilon/d, & d \geq \varepsilon \\ 1, & d < \varepsilon \end{cases} \qquad (1)$$

Значение нормированной «эмоциональной» оценки будет находиться в диапазоне [0; 1], что позволяет легко перевести ее в любую другую шкалу.

Типовыми действиями реконфигурируемого модульного робота являются либо фиксация текущего углового положения i-го модуля, либо его изменение на величину Δ (как в положительном, так и в отрицательном направлении). Таким образом, количество возможных действий робота равно $3n$, где n – число звеньев. Этим обеспечивается *управляемость* системы.

Одним из ключевых факторов, влияющих на скорость обучения в методе ААУ, является способ выбора действий. Например, можно перебирать действия одно за другим, или выбирать действия случайно. В [2] рассмотрены способы выбора действий с применением генетических алгоритмов и градиентного спуска. В нашем случае применяется метод случайного выбора действий с возвращением в ситуацию с наилучшей «эмоциональной» оценкой. Возвращение в ситуацию с наилучшей эмоциональной оценкой возможно благодаря структуре «образов», которые представляют собой, как было сказано выше, набор обобщенных коорди-

нат. Таким образом, система может просмотреть весь список образов, выбрать и перейти в образ с наилучшей оценкой, отработав требуемые углы в сочленениях.

Стоит отметить, что в процессе своего функционирования система может совершить ряд действий, которые приведут к столкновению модулей друг с другом (рис. 4). В этом случае, такой «образ» имеет минимально возможную эмоциональную оценку, даже не смотря на то, что робот отработал целевую точку.

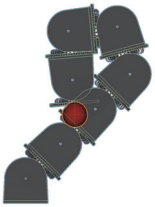

$C = \{45, 0, 0, -60, -80, -90, 0\}$

Рис. 4. Пример отработки точки с столкновением между модулями манипуляционного реконфигурируемого робота

Рис. 5. Общая структура программного комплекса «*АРАКС*» для моделирования и управления модульными реконфигурируемыми роботами

Моделирование процесса самообучения происходит в симуляторе «*АРАКС*» [4], общая структура которого приведена на рис. 5. Программное обеспечение позволяет моделировать модульные роботы в различных конфигурациях с учетом действия физических законов, а также управлять реальным образцом робота. Библиотека алгоритмов комплекса дополнена реализацией метода ААУ для управления роботом в конфигурации «манипулятор».

Интерфейс пользователя включает в себя возможность выбора количества модулей в кинематической цепи, задания величины Δ, а также возможность загрузки сохраненной Базы Знаний (если таковая имеется). Кроме того, пользователь может задать целевую точку или набор точек, которые должны быть последовательно отработаны.

Экспериментальные исследования

Проведенные экспериментальные исследования свидетельствуют о работоспособности метода ААУ применительно к управлению модульным реконфигурируемым роботом в конфигурации «манипулятор». На рис. 6 показаны зависимости времени обучения от количества модулей в кинематической цепи при разных начальных значениях параметра Δ. На рис. 7 изображены зависимости точности достижения целевой точки от значения параметра Δ при различном количестве модулей в составе манипулятора.

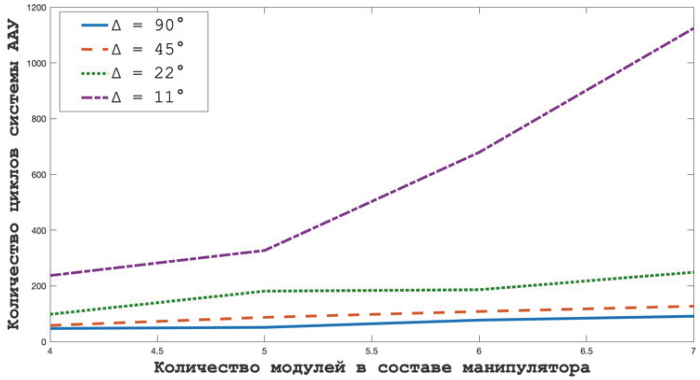

Рис. 6. Зависимости времени обучения от количества модулей в кинематической цепи при разных начальных значениях параметра Δ

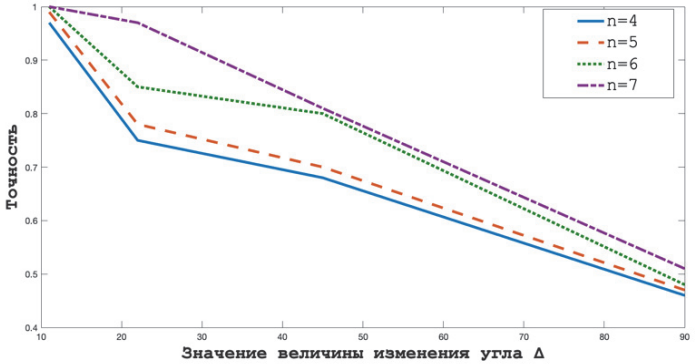

Рис. 7. Зависимости точности достижения целевой точки от значения параметра Δ при различном количестве модулей в составе манипулятора

Из экспериментальных данных видно, что значение величины изменения угла Δ влияет и на скорость обучения, и на точность найденного решения. Чем выше значение Δ, тем быстрее осуществляется обучение, а чем значение Δ меньше – тем выше точность решения.

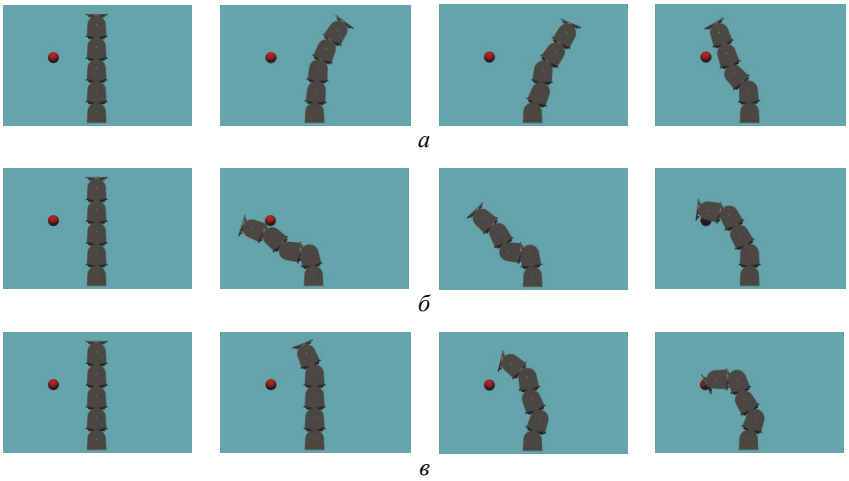

а

б

в

Рис. 8. Демонстрация способности самообучения модульного манипулятора: *а* – БЗ робота пустая; *б* – в БЗ частично заполнена знаниями; *в* – робот обучился, БЗ заполнена

Кроме того, видна закономерность между количеством модулей, точностью и временем обучения при фиксированном значении Δ. Чем больше модулей находится в кинематической цепи, тем выше точность, но при этом растет и время обучения.

Также стоит отметить существенное возрастание скорости обучения по сравнению с подходом, предложенным в [3].

Способность к самообучению проиллюстрирована на рис. 8. При пустой базе знаний (БЗ), робот из исходной позиции движется хаотично (см. рис. 8, *а*). Когда через некоторое время БЗ робота уже частично заполнена знаниями, робот из этой же исходной позиции сразу же, хотя и не очень точно, начинает двигаться в направлении целевой точки (см. рис. 8, *б*). В полностью обученном состоянии робот быстро и точно приходит в целевую точку (см. рис. 8, *в*). Видео демонстрацию можно посмотреть в сети Интернет по адресу https://youtu.be/J0v_ZsfIDa8.

Заключение

Предложен и реализован подход к управлению реконфигурируемым модульным роботом-манипулятором на основе метода автономного адаптивного управления А.А. Жданова. Проведенные экспериментальные исследования показали его работоспособность. Модульный реконфигурируемый манипуляционный робот постепенно самообучается точнее перемещать схват в заданную точку, тем самым демонстрируя адаптивное управление.

Дальнейшие исследования будут посвящены двум направлениям. Первое связано с модификацией предложенного подхода, в котором значение величины изменения угла Δ будет изменяться, способствуя росту скорости обучения при сохранении высокой точности. Второе направление связано со способами и возможностями применения метода ААУ для управления другими конфигурациями модульного робота.

Список литературы

1. Макаров И.М., Лохин В.М., Манько С.В., Романов М.П., Кадочников М.В. Управление движением мехатронно-модульных роботов с адаптивной кинематической структурой // Мехатроника, автоматизация, управление. 2008. № 3.

2. Жданов А.А. Автономный искусственный интеллект: Монография. 2-е изд. М.: БИНОМ. Лаборатория знаний, 2009. 359 с.

3. Манько С.В., Шестаков Е.И. Автоматический синтез сценариев походки реконфигурируемых мехатронно-модульных роботов в модификации шагающей платформы // Российский технологический журнал. 2018. Т. 6. № 4. С. 26–41.

4. Романов А.М., Манько С.В., Шестаков Е.И., Малько А.Н., Чиу В.Ю. Способы описания и средства моделирования мехатронно-модульных реконфигурируемых роботов // Труды ФГУП «НПЦАП». Системы и приборы управления. 2019. № 2. С. 51–67.

Секция 2

Нейробиология

В.И. МАЙОРОВ
Московский государственный университет им. М.В. Ломоносова
vimaiorov@mail.ru

МОДЕЛЬ ИНСТРУМЕНТАЛИЗАЦИИ ДВИЖЕНИЙ, ВЫЗВАННЫХ СТИМУЛЯЦИЕЙ СЕНСОМОТОРНОЙ КОРЫ

Представлена модель физиологического механизма инструментализации (спонтанного воспроизведения) движений, вызываемых подкрепляемой стимуляцией сенсомоторной коры. Инструментализация основана на усилении возбудительных связей пирамидных нейронов коры с дофаминовыми нейронами и между собой в условиях «дофаминового драйва». Правильное изменение связей между пирамидными нейронами критически зависит от редукции дофаминового драйва сразу же после достижения целевого состояния нейронной активности.

Ключевые слова: *условный рефлекс, кора, дофамин, мотивация, подкрепление, редукция драйва.*

Введение

Стимуляция сенсомоторной коры вызывает координированные движения по направлению к конечному положению («end point»), заданному точкой стимуляции [1]. Если такие движения подкреплять пищей, животное начинает повторять их самостоятельно без внешней подсказки [2].

Опыт паркинсонизма указывает на необходимость активации дофаминовых нейронов (ДН) для инициации и выполнения движений [3]. Например, активация ДН условным сигналом (УС) в результате выработки Павловского пищевого условного рефлекса (УР), вызывает реакцию приближения к источнику условного сигнала («Pavlovian approach») [4, 5]. В работе показано, что необходимым и достаточным условием инструментализации движений, вызванных стимуляцией коры – в отсутствие внешнего запускающего стимула, может быть усиление возбудительных связей от пирамидных нейронов коры к ДН.

Опыт паркинсонизма также показывает, что сложные автоматизированные навыки, привычки (например, жонглирование мячом профессиональным футболистом [3]) могут выполняться больными, большую часть времени находящимися в неподвижности. Но выработка привычки требует ещё долгих тренировок, когда ДН реагируют на ожидаемое поощрение не возбуждением, а снижением «дофаминового драйва», необходимого для инициации и выполнения движения. В работе предложена модель физиологического механизма подкрепляющей функции редукции дофаминового драйва, основанная на свойствах дофаминовой модуляции и двунаправленной синаптической пластичности.

Методика

Первый вариант модели состоит из 512 «пирамидных» нейронов (ПН), связанных друг с другом возбудительными ($\boldsymbol{w}$) и тормозными ($\boldsymbol{g}$) связями с вероятностью ≈ 0,4, и ДН, активность которого модулирует эффективность связей между ПН (рис. 1, А, В). ПН разделены на непересекающиеся группы по 64 нейрона в каждой, с более сильными внутригрупповыми возбудительными связями ($\times 25\boldsymbol{w}$). Подразумевается, что возбуждение каждой группы внешним стимулом ($\mathbf{S_G}$) вызывает движение ($\mathbf{R_G}$) к определённому конечному положению (цели – $\mathbf{G_R}$). ПН связаны тормозными синапсами с ДН с вероятностью ≈ 0,3. Одна или две группы ПН связаны с ДН возбудительными синапсами с вероятностью ≈ 0,48. Все связи между нейронами установлены заранее и не менялись в процессе работы модели.

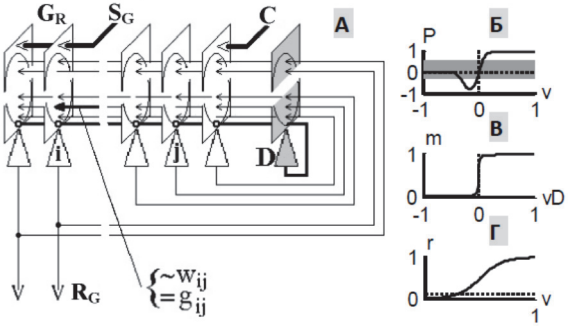

Рис. 1. А. Схема – пирамидные нейроны, светлые, дофаминовый нейрон (D), тёмный. Б. Функция синаптической пластичности (уравнения (14)–(16)). В. Зависимость синаптического возбуждения, генерируемого в ПН от уровня возбуждения ДН (уравнения (1), (6)). Г – зависимость уровня активности, выходящей по аксону, от уровня активности (потенциала) нейрона (уравнение (7))

В начале каждой пробы состояние нейронов инициировалось нормально-распределённым случайным шумом. Каждая проба состояла из **t** шагов (интервалов), динамика активности в которых рассчитывалась функцией решения дифференциальных уравнений MATLAB ode45. Поведение нейронов описывается системой дифференциальных уравнений (в векторно-матричных обозначениях):

$$d\boldsymbol{v}/dt = -0{,}01\boldsymbol{v} + (1-\boldsymbol{v})(m\boldsymbol{we}) - (1+\boldsymbol{v})(\boldsymbol{gi}) + \\ + (1-\boldsymbol{v})\boldsymbol{S}_G + (1-\boldsymbol{v})\boldsymbol{c} - 10\boldsymbol{h}, \quad (1)$$

$$d\boldsymbol{e}/dt = -0{,}01\boldsymbol{e} + (1-\boldsymbol{e})\boldsymbol{r}, \quad (2)$$

$$d\boldsymbol{i}/dt = -0{,}1\boldsymbol{i} + (1-\boldsymbol{i})\boldsymbol{r}, \quad (3)$$

$$d\boldsymbol{h}/dt = -0{,}05\boldsymbol{h} + 0{,}001\boldsymbol{v}, \quad (4)$$

$$dD/dt = -0{,}01D + (1-D)\boldsymbol{w}_D\,(\boldsymbol{v} + |\boldsymbol{v}|) - \\ - (1+D)\boldsymbol{g}_D(\boldsymbol{v} + |\boldsymbol{v}|) - 0{,}00075, \quad (5)$$

$$m = 0{,}5 + \left(\frac{1}{\pi}\right)\tan^{-1}(100D), \quad (6)$$

$$\boldsymbol{r} = \left(\frac{1}{1+e^{5-10v}}\right)(\boldsymbol{v} > threshold). \quad (7)$$

Условные обозначения: $\boldsymbol{v}$ – уровень активности (потенциал) нейрона; $\boldsymbol{w}$, $\boldsymbol{g}$ – величина возбуждающих и тормозных связей между ПН; $\boldsymbol{w}_D$, $\boldsymbol{g}_D$ – величина возбуждающих и тормозных связей между ПН и ДН; $\boldsymbol{r}$ – уровень активности на выходе нейрона после преобразования (рис. 1, Г); $\boldsymbol{e}$, $\boldsymbol{i}$ – «синаптическое» возбуждение и торможение под влиянием **r**, более медленное снижение возбуждения по сравнению с торможением отражает длительность NMDA – компонента ВПСП; $\boldsymbol{S_G}$ – активация, адресованная к группе ПН (соответствует стимуляции коры, вызывающей движение); $\boldsymbol{c}$ – условный (обстановочный) сигнал (УС); $\boldsymbol{h}$ – постактивационное торможение / посттормозное возбуждение; D – уровень активности ДН; m – коэффициент модуляции возбудительных связей между пирамидными нейронами в зависимости от уровня активности ДН (рис. 1, В).

Второй вариант модели состоит из 64 полностью связанных друг с другом ПН, среди которых выделялись (без изменения связей) 8–12 групп по 8 нейронов в каждой. Поведение модели описывается системой дифференциальных уравнений:

$$d\boldsymbol{v}/dt = -0{,}01\boldsymbol{v} + (1-\boldsymbol{v})(\boldsymbol{we}) - (1+\boldsymbol{v})(\boldsymbol{gi}) + \\ + (1-\boldsymbol{v})\boldsymbol{S_G} + (1-\boldsymbol{v})\boldsymbol{c} - 20\boldsymbol{h}\,, \quad (8)$$

$$d\boldsymbol{w}/dt = 0{,}005(0{,}1-\boldsymbol{w})\boldsymbol{P}^{+} + 0{,}25\boldsymbol{wP}^{-}, \quad (9)$$

$$d\boldsymbol{e}/dt = -m\boldsymbol{e} + (1-\boldsymbol{e})\boldsymbol{r};\ m = 0{,}05;\ m = 5, \quad (10)$$

$$d\boldsymbol{i}/dt = -0{,}25\boldsymbol{i} + (1-\boldsymbol{i})\boldsymbol{r}, \quad (11)$$

$$d\boldsymbol{h}/dt = -0{,}05\boldsymbol{h} + 0{,}001\boldsymbol{v}, \quad (12)$$

$$\boldsymbol{r} = \left(\frac{1}{1+e^{5-10\boldsymbol{v}}}\right)(\boldsymbol{v} > threshold), \quad (13)$$

$$\boldsymbol{P} = 1{,}83\left(\frac{e^{20\boldsymbol{v}}}{1+e^{20\boldsymbol{v}}} - \frac{0{,}5e^{20\boldsymbol{v}+6}}{1+e^{20\boldsymbol{v}+6}}\right), \quad (14)$$

$$\boldsymbol{P}^{+} = \boldsymbol{P}(\boldsymbol{e} > 0{,}1 \,\&\, \boldsymbol{P} > 0{,}5), \quad (15)$$

$$\boldsymbol{P}^{-} = \boldsymbol{P}(\boldsymbol{e} > 0{,}1 \,\&\, \boldsymbol{P} < -0{,}3), \quad (16)$$

где $\boldsymbol{w}$ – переменная величина возбуждающих связей между ПН. Связи изменяются в соответствии с функцией двунаправленной синаптической пластичности ($\boldsymbol{P}$, рис. 1, Б), когда значения функции $\boldsymbol{P}$ удовлетворяют условиям, установленным уравнениями (14)–(16); m – характеризует влияние модуляции, создаваемой ДН, на длительность «синаптического» возбуждения ($\boldsymbol{e}$); здесь уровень модуляции не вычислялся, а устанавливался в качестве входного параметра для отдельных временных интервалов: m = 0,05 подразумевало присутствие, а m = 5 отсутствие модуляции. Все тормозные связи постоянны. Остальные обозначения те же, что и в первом варианте модели.

Результаты

В первой части работы изучалось влияние возбудительных связей от одной или двух групп ПН к ДН на динамику активности нейронной модели. Примеры на рис. 2, А, Б показывают, что группа локально связанных ПН (отмеченных серой полосой в основании рисунка), которая возбуждает ДН, после более или менее длительной случайной задержки спонтанно переходит в возбуждённое состояние вместе с ДН (кривая на левой вертикальной стенке), а активность остальных ПН подавляется.

На рис. 2, В показано распределение латентных периодов и вероятность спонтанной вспышки возбуждения ПН в зависимости от силы связей с ДН. Разброс латентных периодов остаётся большим даже при оптимальной силе связей и высокой вероятности реакции. Если с ДН связаны 2 группы ПН, то даже вдвое б*о*льшая сила связи от одной группы не делает её активацию более вероятной по сравнению с другой, слабее связанной с ДН. Для избирательного возбуждения одной из двух одинаково связанных с ДН групп ПН (**a**, **b** на рис. 2, Г, Д, Е) достаточно слабой дополнительной активации этой группы внешним стимулом (рис. 2, Е).

Во второй части работы изучались изменения эффективности связей между ПН в зависимости от условий «дофаминовой» модуляции. Все пробы на рис. 3 начинались с одновременного включения УС и модуляции

(m = 0,05). Как видно из рис. 3, А многократное предъявление УС в условиях модуляции не вызывало заметных изменений в нейронной сети. В пробах на рис. 3, Б–Г в интервале с 21 по 30 шаг вычислений добавляется стимуляция группы ПН (**A**), которая выключалась после 30 шага одновременно с выключением УС и модуляции (m = 5). После нескольких сочетаний уровень возбуждения ПН в группе **A** в ответ на УС постепенно повышается за счёт усиления внутригрупповых связей между ПН (***A*⊃**) и усиления влияния на них нейрона, активируемого УС (**c→A**) (рис. 3, Ж).

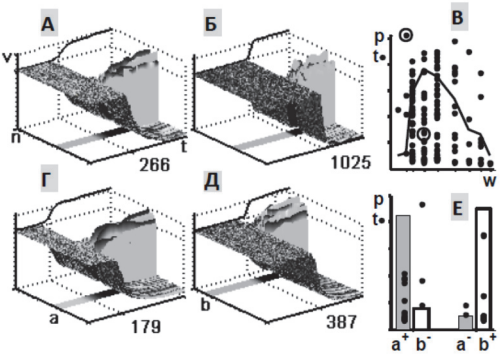

Рис. 2. Примеры (А, Б, Г, Д) и характеристики динамики активности ПН и ДН. **t** – время (число шагов), **n** – номер нейрона, **v** – потенциал. В. Точки – латентный период (**t**, 1–1025, число шагов) при разной силе связи (**w**) ПН с ДН; сплошная линия – вероятность реакции (**p**, 0–1) в интервале **t** ≤ 1025. Е – вероятность (**p**, столбики) и латентный период (**t**, точки) реакций двух групп нейронов, при действии стимулов $\mathbf{a}^+$ и $\mathbf{b}^+$, избирательно адресованных к каждой группе. Величина связи обеих групп с ДН равна минимальному значению из представленных на рис. 2, В

Под влиянием усиления связей от ***A***-нейронов к ***c***-нейрону может увеличиваться и ответ на УС (отмечено стрелкой), но только при слабом уровне торможения между ПН. При усилении торможения ответ не увеличивается (рис. 3, Б–Г).

Рис. 3, И показывает, что при стимуляции ПН группы **A** величина пресинаптического возбуждения (**Ae**, **ce**) и постсинаптический потенциал (**Av**) попадают в область кривой синаптической пластичности (слева на рис. 3, И), соответствующую усилению связей. Но уже при небольшой задержке выключения УС и модуляции – на 5 шагов после выключения стимуляции ПН, обучения не происходит (рис. 3, Д, К): пресинаптическое воз-

буждение (**Ae**, **ce**) попадает на фазу следового постактивационного торможения А-нейронов (**Av**) и происходит снижение весов связей (рис. 3, Ж, К внизу).

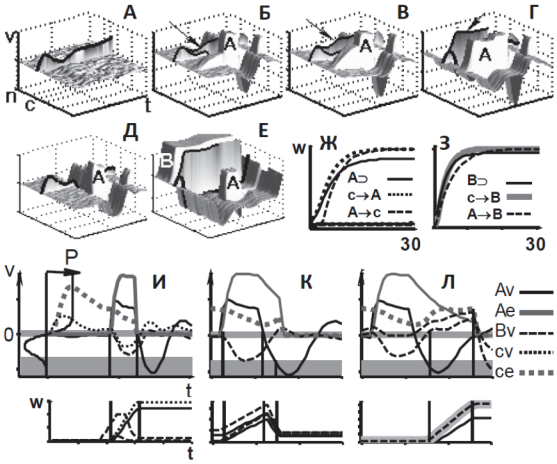

Рис. 3. А–Г. Динамика выработки условной возбудительной реакции группы ПН. А – реакция на условный сигнал после 30 предъявлений в условиях модуляции; Б–Г – условная реакция после 5, 7 и 30 сочетаний. Д, Е – при задержке выключения УС и модуляции на 5 (Д) и на 15 (Е) шагов. Ж, З – изменения связей между ПН при выработке УР (Ж) и при задержке в 5 (Ж) и в 15 (З) шагов (символом ⊃ обозначены внутригрупповые связи между ПН). И–Л – условия изменения связей при первом сочетании, отдельные кривые на рис. 3, И–Л представлены в разном масштабе. Внизу – изменения связей, обозначения, как на рис. 3, Ж, З

Если в сети ПН присутствует группа нейронов, более сильно связанных между собой (**В** на рис. 3, Е), то при увеличении задержки возбуждаются ПН этой группы. В начале ПН группы **В** активируются под влиянием пост-тормозной отдачи (**Bv,** первая и вторая пробы, штриховые линии на рис. 3, Л), в результате усиливаются внутригрупповые связи (также как между **А**-нейронами на рис. 3, И). Совпадение пост-тормозного возбуждения **В**-нейронов с возбуждением **А** и **с** нейронов (**Ae**, **ce**) вызывает усиление связей от **А** и **с** к **В**-нейронам (рис. 3, З).

Рис. 4 показывает, что сигналы, совпадающие с возбуждением определённой группы ПН (**a→A**, **b→B**), приобретают способность вызывать возбуждение «своей» группы нейронов (рис. 4А, Б) за счёт избирательного

усиления связей с ними (рис. 4? В). Однако сигнал (**c**), совпадающий с возбуждением обеих групп (по отдельности) не приобретает связей ни с одной из них (рис. 4, Е). Механизм этого эффекта показан на рис. 4, Г, Д. Например, связи между сигналом **c** и группой **A**, усилившиеся при возбуждении **A**-нейронов (рис. 4, Г), «стираются» при возбуждении нейронов группы **B**, вызывающем реципрокное торможение **A**-нейронов (рис. 4, Д) и наоборот.

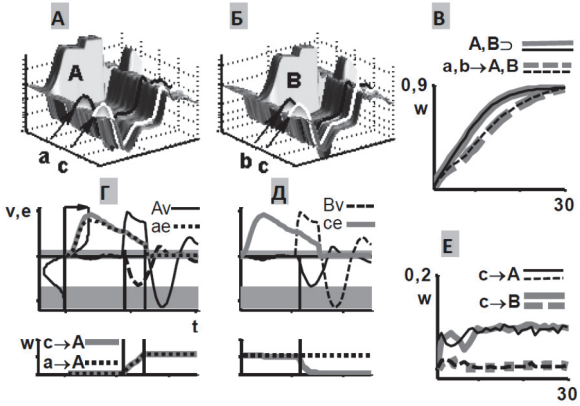

Рис. 4. Группы ПН (**A**, **B**) возбуждаются специфическим для каждой группы УС (**a**, **b**), общий сигнал (**c**) не приобретает связей ни с одной из них

Рис. 5 показывает механизм формирования системы пересекающихся групп ПН, активируемых каждая своим специфическим УС. На рис. 5, А–Г каждая группа, состоящая из 8 нейронов, имеет по 3 общих элемента с двумя другими (соседними по номерам нейронов), и 2 нейрона принадлежащих только ей («ядро» группы, рис. 5, Б). Во время обучения группы ПН активировались в случайном порядке одинаковое число раз. Перед переключением сигналов состояние нейронной сети возвращалось к исходному фоновому уровню, в тестовых пробах синаптическая пластичность блокировалась. Картина избирательной активации каждой группы под влиянием своего условного сигнала после обучения представлена на рис. 5А. Изменения связей между ПН показаны на рис. 5, В, Г. Условный сигнал (С) устанавливает связи со всеми ПН своей группы – как с ядром (С,4), так и с крайними элементами, которые входят также в состав других групп (С,5), но не с другими группами (С,6).

Внутренние межнейронные связи усиливаются между ПН ядра (1) и между краевыми элементами (1). Усиливаются связи от ПН ядра к периферии (2), но связи в противоположном направлении, от периферии к ядру

(3), остаются на низком уровне (Механизм этого тот же, что и механизм ослабления связей общего элемента (**c**) нейронных групп на рис. 4).

Группы ПН на рис. 5Д имеют по половине общих элементов (рис. 5, Е). В данном случае связи УС изменяются, как и в предыдущем (рис. 5, З, 4, 5, 6), внутренние связи усиливаются в каждой подгруппе в отдельности (рис. 5, Ж, 1), а связи между подгруппами внутри каждой группы остаются на низком уровне (рис. 5, Ж, 2, 3).

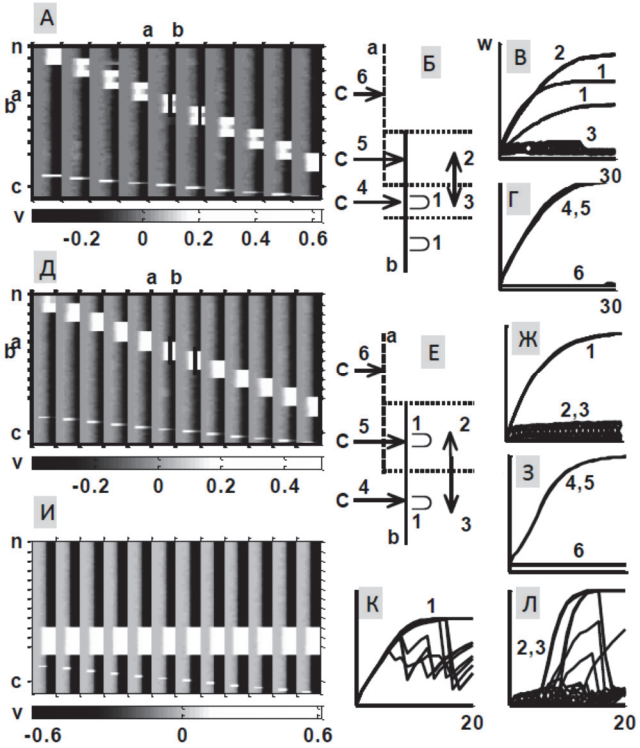

Рис. 5. Выработка УР в пересекающихся группах ПН

Такая упорядоченная структура связей формируется только при использовании непродолжительных условных сигналов (в данном случае действующих в течение не более 10 шагов). При увеличении продолжительности связи становятся хаотическими и, в конце концов, формируется группа нейронов, стабильно активирующихся при любом условном сигнале

(рис. 5, И). Это происходит, когда высокий уровень возбуждения ПН в условиях модуляции создаёт возможность ложных пластических перестроек (рис. 5, К, Л), похоже на то, как происходят ложные изменения связей при задержке выключения модуляции на рис. 3, Д, Е, З.

Заключение

Представлена нейронная модель механизма выработки инструментального УР, хорошо согласующаяся с физиологическим пониманием. Ядром процесса выработки целенаправленных (выполняемых в предвкушении награды) движений к *внешней* цели, является Павловский дофаминовый УР (аналогичный условному слюнному рефлексу), делающий источник внешнего УС как внешнюю цель побудительной причиной («incentive») движения [4–7]. В работе показано, что тот же механизм ассоциации между нейронами коры, программирующими движение во внутренней координатной системе схемы тела, и дофаминовыми нейронами может лежать в основе инструментализации движений, вызванных стимуляцией сенсомоторной коры. В результате, финальная поза становится побудительной причиной движения. Существенно, что с точки зрения рассмотренного выше механизма (и в соответствии, по крайней мере, с некоторыми экспериментальными данными [8]) выделение дофамина не более необходимо для выработки Павловского дофаминового рефлекса, чем выделение слюны для выработки слюнного рефлекса.

Спонтанные вспышки активности ПН, возбуждающих ДН, генерируются с большим разбросом латентных периодов относительно начала пробы, когда случайный шум активности в группе ПН и вызываемое им возбуждение ДН вместе достигнут критического уровня достаточного для запуска регенеративного процесса; другие группы ПН, если у них не сформированы возбудительные связи с ДН, не могут генерировать вспышку активности. Такие реакции мало избирательны в отношении силы связи ПН с ДН – две группы ПН, сильно различающиеся по силе связи с ДН, не различаются по вероятности спонтанного возбуждения. Для избирательного возбуждения одной из групп ПН, одинаково связанных с ДН, достаточно небольшого смещения активности (затравки) со стороны специфического для этой группы сигнала.

Связи между ПН в модели изменяются в соответствии с правилом двунаправленной синаптической пластичности [9, 10] в условиях «дофаминового драйва», необходимого для индукции пластичности [11], также как для инициации и выполнения движения. Считается, что дофаминовые нейроны реагируют на уже ожидаемое вознаграждение не возбуждением, а редукцией «дофаминового драйва» [12, 13]. В соответствии с этим и с правилами выработки инструментальных условных рефлексов, правильное изменение связей

между ПН критически зависит от редукции «дофаминового драйва» сразу же после достижения целевого состояния, здесь некоторого критического уровня активности в целевой группе ПН. В работе показан возможный физиологический механизм «подкрепляющего» действия редукции (дофаминового) драйва, предохраняющей от синаптической депрессии найденных нужных связей и от синаптической потенциации ложных связей. Предложенный механизм даёт неожиданное решение существующего с 50-х годов прошлого века «drive-reward» парадокса: каким образом одна и та же (как теперь известно, возбуждающая дофаминовые нейроны) стимуляция, вызывает и «мотивацию» и «подкрепление» [14]. С точки зрения рассмотренного выше механизма дофамин, когда он выделяется в ответ на подкрепляющий стимул, ничего не подкрепляет. Дофамин выполняет функцию «внутреннего фактора подкрепления» в том же временном интервале («дофаминовом окне»), что и функцию «активации двигательной системы поведения» [1], необходимую для выполнения движения.

Список литературы

1. Graziano M.S.A., Taylor C.S.R., Moore T. Complex Movements Evoked by Microstimulation of Precentral Cortex // Neuron. 2002. Vol. 34. No. 5. P. 841–851.

2. Конорски Ю. Интегративная деятельность мозга. М.: Мир. 1970. 412 с.

3. Лис Э.Дж. По наставлениям сумасшедшего. Эксперимент Уильяма Берроуза. М. 2020. 255 с.

4. Saunders B.T., Richard J.M., Margolis E.B., Janak P.H. Dopamine neurons create Pavlovian conditioned stimuli with circuit-defined motivational properties // Nature Neuroscience. 2018. Vol. 21. P. 1072–1083.

5. Zellner M.R., Ranaldi R. How conditioned stimuli acquire the ability to activate VTA dopamine cells: A proposed neurobiological component of reward-related learning // Neurosci. Biobehav. Rev. 2010. Vol. 34. No. 5. P. 769–780.

6. Berridge K.C., Robinson T.E. What is the role of dopamine in reward: Hedonic impact, reward learning, or incentive salience // Brain Research Reviews. 1998. Vol. 28. No. 3. P. 309–369.

7. Bolles R.C. Reinforcement, expectancy, and learning // Psychological Review. 1972. Vol. 79. No. 5. P. 394–409.

8. Robinson S., Sandstrom S.M., Denenberg V.H., Palmiter R.D. Distinguishing Whether Dopamine Regulates Liking, Wanting, and/or Learning About Rewards // Behav. Neurosci. 2005. Vol. 119. No. 1. P. 5–15.

9. Майоров В.И. Пластические свойства синаптической передачи как возможный механизм обучения. *В*: Пластичность нервных клеток, М.: МГУ, 1977. С. 70–97.

10. Попов В.А. Пре- и постсинаптический механизмы депривационной потенциации популяционных ответов нейронов поля *ca1* гиппокампа крыс // Журн. высш. нервн. деят. 2016. Т. 66. № 2. С. 209–219.

11. Yagishita S., Hayashi-Takagi A., Ellis-Davies G.S.R., Urakubo H., Ishii S., Kasai H. A critical time window for dopamine actions on the structural plasticity of dendritic spines // Science. 2014. Vol. 345. No. 6204. P. 1616–1620.

12. Glimcher P.W. Understanding dopamine and reinforcement learning – the dopamine reward prediction error hypothesis // Proc Natl Acad Sci USA. 2011. Vol. 108. Suppl 3. P. 15647–15654.
13. Waelti P., Dickinson A., Schultz W. Dopamine responses comply with basic assumptions of formal learning theory // Nature. 2001. Vol. 412. No. 6842. P. 43–48.
14. Wise R.A. Dual roles of dopamine in food and drug seeking: the drive-reward paradox // Biol. Psychiatry. 2013. Vol. 73. No. 9. P. 819–826.

Д.Н. ГОЛУБЕВА[1,2], А.В. ЧИЖОВ[1,2], С.Л. МАЛКИН[2]
[1]Физико-технический институт им. А.Ф. Иоффе РАН, Санкт-Петербург
[2]Институт эволюционной физиологии и биохимии им. И.М. Сеченова РАН, Санкт-Петербург
daria.10281615@gmail.com

МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ВЛИЯНИЯ ТРАНСПОРТЕРОВ ГЛУТАМАТА EAAT2 НА ПОСТСИНАПТИЧЕСКИЕ СИГНАЛЫ

Ключевую роль в удалении глутамата из внеклеточного пространства играет его обратный захват астроцитами посредством специфического транспортера EAAT2. Целью данной работы стало математическое описание вклада EAAT2 в работу AMPA- и NMDA-рецепторов. Показано, что процессы быстрого удаления глутамата из синаптической щели посредством диффузии, и последующего удаления из внеклеточного пространства посредством транспортера EAAT2, играют ключевую роль в формировании синаптического ответа.

Ключевые слова: *эпилепсия, глутамат, EAAT2, AMPA, NMDA.*

Введение

Глутамат является самым распространенным возбуждающим нейромедиатором в мозге [1]. Известно, что при эпилепсии глутамат накапливается во внеклеточном пространстве, приводя к смещению баланса торможения и возбуждения, и таким образом способствует поддержанию судорог. Одной из причин такого накопления может быть недостаточно эффективный обратный захват глутамата астроцитами [2]. Накопление глутамата во внеклеточном пространстве приводит к чрезмерной активации синаптических NMDA и AMPA-рецепторов, ответственных за быструю возбуждающую

передачу в центральной нервной системе [3], а также к его распространению за пределы синаптического бутона (спилловеру) и активации вне- и экстрасинаптических рецепторов [4]. Роль транспортеров глутамата в развитии и поддержании судорожных процессов на данный момент активно исследуется, однако для верной интерпретации и объяснения наблюдаемых эффектов необходимо построение математических моделей. В данной работе разрабатывается модель работы AMPA- и NMDA-рецепторов с учётом переноса глутамата во внеклеточном пространстве и вклада астроцитарного перерносчика глутамата EAAT2 (Excitatory amino acid transporter-2). Выбор именно этого транспортера на данном этапе работы обоснован тем, что 90% обратного захвата глутамата выполняется именно им [5].

Существует множество математических моделей эпилептического состояния, которые описывают удаление глутамата и влияние астроцитарного глутамата на поведение нейронов [6–8]. Все они детально описывают дисфункцию удаления глутамата, процессы его обратного захвата, и активацию рецепторов, однако некоторые из них совершенно не берут в расчет AMPA-рецепторы [6, 7], или не учитывают такие важные моменты как разная чувствительность AMPA- и NMDA-рецепторов [6–8] к глутамату и большая разница концентраций глутамата между синаптической щелью и остальным внеклеточным пространством [6, 8]. В данной работе разрабатывается новая модель, учитывающая все вышеупомянутые феномены.

Материалы и методы

Электрофизиологические эксперименты проводились на переживающих горизонтальных срезах головного мозга крысы, полученных в возрасте 3 недель. Регистрация ответов производилась методом локальной фиксации потенциала в пирамидных нейронах поля CA1 гиппокампа в ответ на электрическую стимуляцию коллатералей Шаффера. В течение эксперимента срезы инкубировались в искусственной спинномозговой жидкости (ИСМЖ) следующего состава (в мМ): 126 NaCl, 24 NaHCO3, 2,5 KCl 2 CaCl2, 1,25 NaH2PO4, 1 MgSO4, и 10 декстрозы. Пэтч-электроды с сопротивлением 2–4 мОм заполнялись внутриклеточным раствором на основе глюконата калия (в мМ: 114 K-глюконата, 6 KCl, 0,2 EGTA, 10 HEPES, 4 АТФ-Mg, и 0,3 ГТФ) для регистрации AMPA-опосредованных токов или на основе цезий-метансульфоната (в мМ: CsMeSO4 127, NaCl 10, EGTA 5, HEPES 10, QX314 6, АТФ-Mg 4, ГТФ 0,3) для регистрации NMDA-опосредованных токов. Регистрация AMPA-опосредованных ответов производилась при фиксируемом мембранном потенциале –80 мВ, NMDA-опосредованных – при потенциале –20 мВ. Токи через AMPA- и NMDA-

рецепторы фармакологически изолировались при помощи добавления в омывающий раствор специфических бокаторов ГАМКа рецепторов (бикукуллин, 10 мкМ), а также AMPA- (DNQX, 20 мкМ) или NMDA-рецепторов (D-AP5 50 мкМ). Блокада EAAT2 осуществлялась путём добавления в наружный раствор его специфического блокатора TFB-TBOA в концентрации 300 нМ за час до начала электрофизиологической регистрации.

Математическая модель представляет из себя двухкомпартментную модель нейрона [9], включающую в себя два уравнения для дендритного и соматического мембранных потенциалов:

$$\begin{cases} \tau_m \frac{dU}{dt} = -(U - U_L) + \frac{2\gamma}{l}(U_d - U); \\ \tau_m \frac{dU_d}{dt} = -(U_d - U_L) + \frac{2}{l}(U_d - U) + \frac{I_d}{\gamma g_s}, \end{cases} \quad (1)$$

где $g_s -$ проводимость сомы; $\gamma -$ отношение площадей мембраны дендрита и сомы; $l -$ отношение квадрата длины дендрита к квадрату характеристической длины λ; τ_m – характерное время перезарядки мембраны. Синаптический ток, регистрируемый на дендрите нейрона I_d связан с синаптическим током, регистрируемым на соме I_{syn} (т.е. I_{AMPA} или I_{NMDA}) соотношением [9]:

$$I_d = \left(\frac{l}{2}\tau_m \frac{d}{dt} + 1 + \frac{l}{2}\right) I_{syn}. \quad (2)$$

AMPA-рецепторы имеют линейную вольт-амперную характеристику, тогда как NMDA-рецепторы вследствие блока ионами Mg^{2+} при положительных мембранных потенциалах проявляют ярко выраженное выходящее выпрямление [10]:

$$I_{AMPA} = g_{AMPA}(U_{AMPA} - U), \quad (3)$$

$$I_{NMDA} = g_{NMDA} Mg(U)(U_{NMDA} - U), \quad (4)$$

где

$$Mg(U) = \frac{1}{1 + \frac{|Mg|}{3.57} exp(-0.06U)}.$$

Для описания проводимости AMPA-рецепторов используется уравнение второго порядка:

$$\left(\tau_{1A}\tau_{2A}\frac{d^2}{dt^2}+(\tau_{1A}+\tau_{2A})\frac{d}{dt}+1\right)\frac{g_{AMPA}}{\overline{g}_{AMPA}}=S_{AMPA}(glU^e), \quad (5)$$

где τ_{1A},τ_{2A} – характерные времена нарастания и убывания синаптической проводимости AMPA-рецепторов; $\overline{g}_{AMPA}$ – максимальное значение проводимости AMPA-рецепторов; $S_{AMPA}(glU^e)$ – сигмоидальная функция активации рецептора в зависимости от концентрации гутамата [11] в синаптической щели.

NMDA-рецепторы расположены в синаптической щели и во внесинаптическом пространстве. Здесь мы учитываем зависимость активации этих рецепторов только от концентрации медиатора во внесинаптическом пространстве. Поэтому для описания ответа рецептора достаточно уравнения первого порядка, т. к. скорость открытия рецептора лимитирована скоростью роста концентрации медиатора:

$$\left(\tau_N\frac{d}{dt}+1\right)\frac{g_{NMDA}}{\overline{g}_{NMDA}}=S_{NMDA}(glU^{perif}), \quad (6)$$

где τ_N – характерное время релаксации проводимости NMDA-рецепторов; $\overline{g}_{NMDA}$ – максимальное значение проводимости NMDA-рецепторов; $S_{NMDA}(glU^{perif})$ – сигмоидальная функция активации рецептора в зависимости от концентрации глутамата на периферии вблизи астроцита [11].

Попадая в синаптическую щель, глутамат воздействует на находящиеся там AMPA- и NMDA-рецепторы, и далее диффундирует наружу, где активирует пери- и экстрасинаптические NMDA-рецепторы, обладающие высокой по сравнению с AMPA-рецепторами чувствительностью к глутамату. Концентрации глутамата в синаптической щели и во внеклеточном пространстве [12] описаны релаксационными уравнениями:

$$\begin{cases}\frac{dglU^e}{dt}=\frac{glU^{perif}-glU^e}{\tau_{glU}}\,\beta^{glU}+F\,W\,\nu(t);\\ \frac{dglU^{perif}}{dt}=\frac{glU^e-glU^{perif}}{\tau_{glU}}-\frac{glU^{perif}}{\tau_{diff}}-EAAT2,\end{cases} \quad (7)$$

где β^{glU} – отношение объема внеклеточного простренства к объему синаптической щели; τ_{glU} – характерное время диффузии из синаптической щели в остальное внеклеточное пространство; τ_{diff} – характерное время диффузии глутамата из внеклеточного пространства в перфузирующий раствор; F – фактор пресинаптической фасилитации; W – вклад одного спайка в изменение проводимости медиатора.

EAAT2 транспортирует молекулы глутамата совместно с ионами Na^+ [13], поэтому его работа описана следующим образом:

$$EAAT2(glU^{perif}) = EAAT2_{max}\frac{(Na^e - Na^a)^{1.5}}{k_{1/2}^{Na}+(Na^e - Na^a)^{1.5}} * \frac{glU^{perif}}{k_{1/2}^{Glu}+glU^{perif}}, \quad (8)$$

где $EAAT2_{max}$ – максимальная скорость откачивания глутамата транспортером из внеклеточного пространства при данных концентрациях натрия; Na^e – концентрация внеклеточного натрия; Na^a – концентрация натрия на астроците; $k_{1/2}^{Na}$ – концентрация Na , необходимая для получения половины максимального тока; $k_{1/2}^{Glu}$ – концентрация глутамата, необходимая для получения половины максимального тока.

Уравнение пресинаптической фасилитации было задано следующим образом [14]:

$$\frac{dF}{dt} = -\frac{F}{\tau_F} + \frac{H(1-F)v(t)}{1000}, \quad (9)$$

где τ_F – характерное время спада фасилитации; H – увеличение F после каждого стимула.

Результаты, обсуждение и выводы

Эксперименты. Нами были проведены эксперименты по регистрации фармакологически изолированных синаптических токов через AMPA- и NMDA-рецепторы в пирамидных клетках поля CA1 гиппокампа в ответ на стимуляцию коллатералей Шаффера в срезах головного мозга крысы. Было обнаружено, что фармакологическая блокада транспортеров EAAT2 не изменяла кинетику токов через AMPA-рецепторы, в то время как фаза спада NMDA-опосредованных токов значительно замедлялась по сравнению с контролем (рис. 1. А, Б).

Моделирование. Предложенная модель качественно описывает экспериментальные данные (рис. 1). Модель отражает динамику изменения концентраций глутамата в синаптической щели и экстрасинаптическом пространстве (рис. 2, А, Б), а также работу рецепторов. Для вопроизведения результатов оказалось необходимым учитывать не только соматический, но и дендритный компартменты модельных нейронов, синаптическую фасилитацию, затрудненную диффузию между синаптической щелью и остальным внеклеточным пространством, а также разный порог чувствительности к глутамату у AMPA- и NMDA-рецепторов (рис. 2, В). Можно

также обратить внимание на то, что на экспериментальной записи AMPA-опосредованных токов (рис. 1, А) наблюдается нарастание амплитуды постсинаптических ответов при последовательной стимуляции с частотой 50 Hz. Наиболее вероятной причиной этого является пресинаптическая фасилитация глутаматергических синапсов, что также отражено в модели.

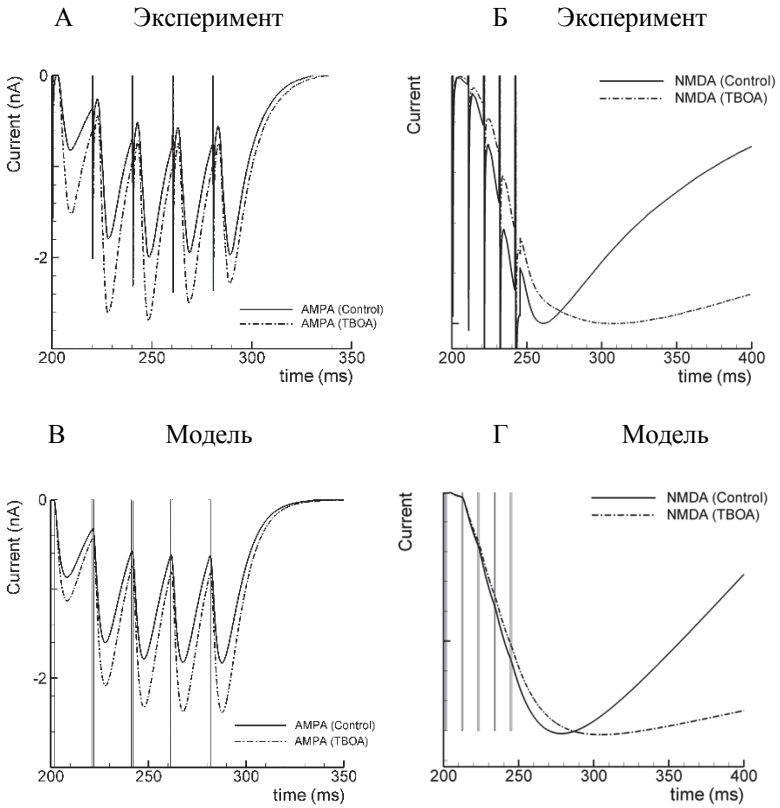

Рис. 1. Сравнение экспериментальных данных (А, Б) с моделью (В, Г)

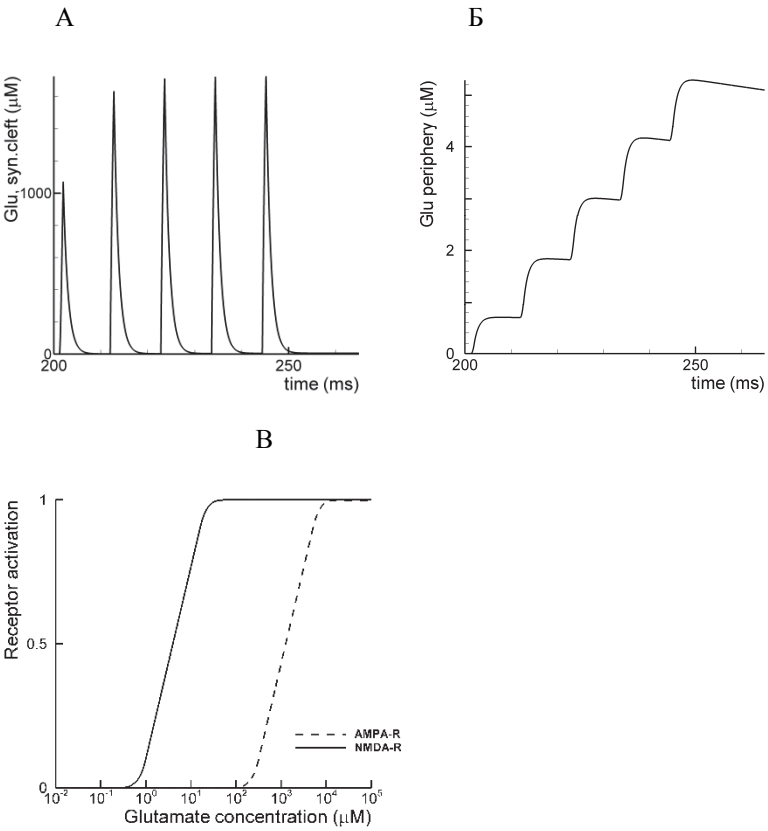

Рис. 2. Концентрации глутамата в синаптической щели (А) и на периферии (Б). Различная чувствительность к концентрациям глутамата у AMPA- и NMDA-рецепторов (В)

Таким образом, модель предсказывает, что обратному захвату глутамата транспортерами необходимо предшествует выход нейромедиатора посредством диффузии из синаптической щели в экстрасинаптическое экстраклеточное пространство. Ответ менее чувствительных к глутамату AMPA-рецепторов заканчивается ещё до пространственного выравнивания концентрации глутамата, тогда как ток через более чувствительные

NMDA-рецепторы продолжается до тех пор, пока эта концентрация не оказывается сниженной действием транспортеров и диффузией по градиенту концентрации.

Работа выполнена при поддержке грантом РНФ 16-15-10201-П.

Список литературы

1. Meldrum B.S. Glutamate as a neurotransmitter in the brain: review of physiology and pathology // The Journal of Nutrition. 2000. V. 130. No 4. P. 1007–1015.

2. Tian G., Azmi H., Takano T., Xu Q., Peng W., Lin J., et al. An astrocytic basis of epilepsy // Nature Medicine. 2005. V. 11. P. 973–981.

3. Shi S.H., Hayashi Y., Petralia R.S., et al. Rapid spine delivery and redistribution of AMPA receptors after synaptic NMDA receptor activation // Science. 1999. V. 284. No 5421. P. 1811–1816.

4. Huang Y.H., Bergles D.E. Glutamate transporters bring competition to the synapse // Current Opinion Neurobiology. 2004. V. 14, No 3. P. 346–352.

5. Lipton S.A., Rosenberg, P.A. Excitatory amino acids as a final common pathway for neurologic disorders // The New England Journal of Medicine. 1994. V. 330. P. 613–622.

6. Wade J., McDaid L., Harkin J., Crunelli V., Kelso J. Bidirectional coupling between astrocytes and neurons mediates learning and dynamic coordination in the brain: a multiple modeling approach // PLoS. 2011. V. 6. No 12. e29445.

7. De Pittà M., Volman V., Berry H., Ben-Jacob E. A tale of two stories: astrocyte regulation of synaptic depression and facilitation // PLoS CB. 2011. V. 7. No 12. e1002293.

8. Flanagan B., McDaid L., Wade J., Wong-Lin K., Harkin J. A computational study of astrocytic glutamate influence on post-synaptic neuronal excitability // PLoS CB. 2018. V. 14. No 4. e1006040.

9. Chizhov A.V., Sanchez-Aguilera A., Rodrigues S., de la Prida L.M. Simplest relationship between local field potential and intracellular signals in layered neural tissue // Physical Review E. 2015. V. 92. No 6. e062704.

10. Bezzi P., Carmignoto G., Pasti L., Vesce S., Rossi D., Rizzini B.L., Volterra A. Prostaglandins stimulate calcium-dependent glutamate release in astrocytes // Nature. 1998. V. 391 No 6664. P. 281–285.

11. Featherstone D.E., Shippy S.A. Regulation of Synaptic Transmission by Ambient Extracellular Glutamate // The Neuroscientist. 2007. V. 14. No 2. P. 171–181.

12. Hires S.A., Zhu Y., Tsien R.Y. Optical measurement of synaptic glutamate spillover and reuptake by linker optimized glutamate-sensitive fluorescent reporters // Proceedings of the National Academy of Scientists. 2008. V. 105. No 11. P. 4411–4416.

13. Cater R.J., Vandenberg R.J., Ryan R.M. Tuning the ion selectivity of glutamate transporter-associated uncoupled conductances // The Journal of General Physiology. 2016. V. 148. No 1. P. 13–24.

14. Markram H., Wang Y., Tsodyks M. Differential signaling via the same axon of neocortical pyramidal neurons // Proceedings of the National Academy of Sciences. 1998. V. 95. No 9. P. 5323–5328.

В.И. МАЙОРОВ
Московский государственный университет им. М.В. Ломоносова
vimaiorov@mail.ru

МОДЕЛЬ КОГНИТИВНОЙ КАРТЫ В ГИППОКАМПЕ: АССОЦИАЦИЯ КЛЕТОК МЕСТА И НАПРАВЛЕНИЯ

На примере простой рекуррентной нейронной сети показано, как при использовании двунаправленной ассоциативной синаптической пластичности, основанной на взаимодействии AMPA- и NMDA-рецепторов в зависимости от постсинаптического потенциала, сигнал клеток направления («head-direction cells») приобретает способность активировать ту последовательность (траекторию возбуждения) клеток места («place-cells»), с которой он ассоциировался в предшествующем опыте («replay»/«preplay»). В результате сигналы разных клеток направления становятся указателями на разные траектории (пути) на карте.

Ключевые слова: *гиппокамп, клетки места, клетки решётки, клетки направления, синаптическая пластичность, тест Морриса*.

Введение

Нейроны гиппокампа регистрируют то место, в котором находится животное («клетки места», «клетки решётки», «place-», «grid- cells») и выстраивают траекторию движения к другому, невидимому отсюда месту, по координатам, вычисляемым относительно удалённых объектов [1–4]. Существующие модели функционального механизма гиппокампа в навигации можно разделить на две группы. В градиентных моделях выбор направления производится непосредственно во время движения по градиенту синаптических связей [5] или дофаминовому градиенту [1]. В моделях, основанных на предварительном планировании траекторий, клетки направления («head direction cells») функционально сопряжены с клетками места так, чтобы вызывать предварительную активацию («preplay») той последовательности клеток места, в которой они бы возбуждались при движении в данном направлении [6–11]. Физиологический механизм такого сопряжения пока точно не установлен.

Методика

Модель состоит из 64 нейронов, полностью связанных друг с другом нормально распределёнными по величине глутаматными

(AMPAR + NMDAR) связями ($\boldsymbol{w}$) с высокой концентрацией NMDA-рецепторов в окончаниях, и тормозными ($\boldsymbol{g}$) связями. Возбуждающие связи локализованы и оканчиваются на разных дендритных ветках (рис. 1, А). Сигнал направления ($\boldsymbol{\varphi}$-) действует на все нейроны, как показано на рис. 1, А, через относительно слабые глутаматные связи только с AMPA-рецепторами в окончаниях. Как видно из рис. 1, А, матрица весов связей направляющего сигнала ($\boldsymbol{w_\varphi}$) структурно идентична матрице рекуррентных межнейронных связей ($\boldsymbol{w_r}$) – каждому элементу матрицы $\boldsymbol{w_r}$ соответствует элемент матрицы $\boldsymbol{w_\varphi}$ (как элементы 1 и 2 на рис. 1, А). Схема связей на рис. 1, А представляет собой упрощённый вариант вероятностной схемы связей (рис. 1, Б), где только некоторые нейроны контактируют с данным (a_1,a_n, c_1), и не со всеми ветками контактируют направляющие. Связи от одного нейрона оканчиваются на разных дендритных ветках. Например, аксоны нейронов A_1, C_1 контактируют соответственно с нижней и верхней веткой нейрона B_1 (рис. 1, А) и с верхней и нижней веткой нейрона B_n (рис. 1, Б). Синапсы любых двух групп нейронов в среднем равно удалены от сомы данного нейрона, что позволяет обойтись в определении модели одним уравнением интегратора с утечкой (1).

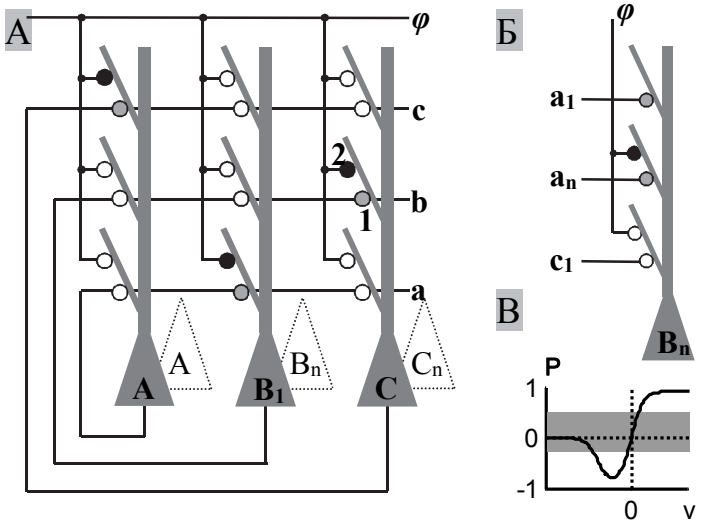

Рис. 1. Принципиальная схема модели (А) представляет собой упрощённый вариант вероятностной схемы связей (Б).
В. Функция синаптической пластичности в соответствии с уравнением (9).
Дополнительные пояснения в тексте

В начале каждой пробы состояние нейронов инициировалось нормально-распределённым случайным шумом. Каждая проба состояла из **t** шагов (интервалов), динамика активности в которых рассчитывалась функцией решения дифференциальных уравнений MATLAB ode45. Поведение нейронов описывается системой дифференциальных уравнений (в векторно-матричных обозначениях):

$$d\boldsymbol{v}/d\boldsymbol{t} = -0{,}01\boldsymbol{v} + (1-\boldsymbol{v})\big((\boldsymbol{w_r} + 0{,}25\boldsymbol{w_\varphi})\boldsymbol{e_r}\big) + (1-\boldsymbol{v})(\boldsymbol{w_\varphi} e_\varphi) - \\ - (1+\boldsymbol{v})(\boldsymbol{gi}) + (1-\boldsymbol{v})\boldsymbol{S} - 5\boldsymbol{h} - 15\boldsymbol{h}(\boldsymbol{h} > 0{,}001), \quad (1)$$

$$d\boldsymbol{w_r}/dt = 0{,}001(0{,}05 - \boldsymbol{w_r})\boldsymbol{P_r^+} + 0{,}05\boldsymbol{w_r}\boldsymbol{P_r^-}, \quad (2)$$

$$d\boldsymbol{w_\varphi}/dt = 0{,}001\big(0{,}05 - \boldsymbol{w_\varphi}\big)\boldsymbol{P_\varphi^+} + 0{,}05\boldsymbol{w_\varphi}\boldsymbol{P_\varphi^-}, \quad (3)$$

$$d\boldsymbol{e_r}/dt = -0{,}05\boldsymbol{e_r} + (1-\boldsymbol{e_r})\boldsymbol{r}, \quad (4)$$

$$d\boldsymbol{i}/dt = -0{,}25\boldsymbol{i} + (1-\boldsymbol{i})\boldsymbol{r}, \quad (5)$$

$$d\boldsymbol{h}/dt = -0{,}005\boldsymbol{h} + 0{,}0005\boldsymbol{v}, \quad (6)$$

$$\boldsymbol{r} = \left(\frac{1}{1+e^{5-10\boldsymbol{v}}}\right)(\boldsymbol{v} > 0{,}01), \quad (7)$$

$$\boldsymbol{P} = 1{,}83\left(\frac{e^{20\boldsymbol{v}}}{1+e^{20\boldsymbol{v}}} - \frac{0{,}5e^{20\boldsymbol{v}+6}}{1+e^{20\boldsymbol{v}+6}}\right), \quad (8)$$

$$\boldsymbol{P_r^+} = \boldsymbol{P}(\boldsymbol{e_r} > 0{,}3 \;\&\; \boldsymbol{P} > 0{,}5), \quad (9)$$

$$\boldsymbol{P_r^-} = \boldsymbol{P}(\boldsymbol{e_r} > 0{,}3 \;\&\; \boldsymbol{P} < -0{,}3), \quad (10)$$

$$\boldsymbol{P_\varphi^+} = \boldsymbol{P}(\boldsymbol{e_r} > 0{,}3 \;\&\; \boldsymbol{P} > 0{,}5), \quad (11)$$

$$\boldsymbol{P_\varphi^-} = \boldsymbol{P}(\boldsymbol{e_r} > 0{,}3 \;\&\; \boldsymbol{v} < -0{,}5). \quad (12)$$

Условные обозначения: $\boldsymbol{v}$ – уровень активности (потенциал) нейрона, который *без генерации потенциалов действия* преобразуется в сигнал на выходе ($\boldsymbol{r}$), пресинаптический для других нейронов; $\boldsymbol{w} > 0$, $\boldsymbol{g} > 0$ – величина возбуждающих и тормозных связей между нейронами; $\boldsymbol{w_r}$, $\boldsymbol{w_\varphi}$ – веса межнейронных (рекуррентных) и направляющих связей; $\boldsymbol{e_r}$, $\boldsymbol{i}$ – «синаптическое» возбуждение и торможение пропорциональное количеству медиатора выброшенного под влиянием $\boldsymbol{r}$, более медленное снижение возбуждения по сравнению с торможением отражает длительность NMDA-компонента ВПСП; e_φ – постоянное синаптическое возбуждение под влиянием сигнала направления φ; $\boldsymbol{h}$ – постактивационное торможение/посттормозное возбуждение; $\boldsymbol{S}$ – внешний сигнал, имитирующий действие входов, формирующих активность клеток места; $\boldsymbol{P}$ – функция пластичности (по [12], с изменениями) с дополнительными ограничениями $\boldsymbol{P^+}$, $\boldsymbol{P^-}$; $\boldsymbol{P_r}$, $\boldsymbol{P_\varphi}$, – функции пластичности, действующие на AMPA-рецепторы межнейронных и направляющих связей. В уравнении (1) межнейронное синаптическое возбуждение $\boldsymbol{e_r}$ умножается на сумму матриц весов межнейронных и направляющих связей, это

один из наиболее существенных элементов модели, разъясняемый в Результатах. (В уравнениях указаны те числовые коэффициенты, с которыми были получены данные, представленные на рисунках.)

AMPA-компонент глутаматных связей характеризуется двунаправленной NMDA- и потенциал-зависимой пластичностью. При активации NMDA-рецепторов глутаматом эффективность *активных* AMPA-связей изменяется в зависимости от постсинаптического потенциала в соответствии с функцией пластичности $\boldsymbol{P}$ (уравнения (2), (3), (8)–(12), рис. 1, В). *NMDA-компонент остаётся постоянным*. Направляющие $\boldsymbol{\varphi}$-связи характеризуются локальной ассоциативной пластичностью. Под ассоциативностью понимается усиление эффективности слабых связей, неспособных к самостоятельным изменениям, при совместной активации с более сильными связями [13, 14]. Точный механизм ассоциативности для каждого конкретного случая, по-видимому, не установлен. Здесь предполагается, что синапсы направляющих связей не имеют собственных NMDA-рецепторов. На каждом шаге *активные* ассоциативные связи изменяются вместе – одновременно и однонаправлено, с коллатеральными, оканчивающимися вблизи на той же ветке (например, *1* и *2* на рис. 1, А) в соответствии с уравнениями (2), (3), (8)–(12) (влиянием ВПСП изначально слабых направляющих связей на процесс обучения пренебрегаем). Вычисления производились в системе MATLAB, m-коды программ можно получить у автора.

Результаты

Вначале нейроны разделялись на 3 непересекающиеся группы **A**, **B**, **C** по 21 нейрону в каждой (один оставался свободным), на которые последовательно подавался сигнал $\boldsymbol{S}$, имитирующий действие входов, формирующих активность клеток места (рис. 2, *1*). Рис. 2, *2* показывают движение фокуса возбуждения (светлые участки) под влиянием $\boldsymbol{S}$ в направлении ABCA (рис. 2, А, *2*) или CBAC (рис. 2, Б, *2*). Характер и условия изменения межнейронных связей показаны на рис. 2, *3–5*. Например, при последовательном возбуждении **A** и **B** групп (рис. 2, А, *3*) связи $\mathbf{A}\rightarrow\mathbf{B_a}$ и ассоциированные $\boldsymbol{\varphi}$-связи усиливаются (рис. 2, А, *5*, чёрная сплошная), когда задний фронт (NMDA-компонент) возбуждающего синаптического сигнала из **A** (рис. 2, А, *4*, серая сплошная) совпадает на дендритной ветке $\mathbf{B_a}$ с передним фронтом постсинаптического возбуждения нейронов группы **B** (чёрная штриховая). Это единственный интервал NMDA-зависимого усиления связей для ветки $\mathbf{B_a}$. При таком направлении распространения возбуждения усиливаются связи $\mathbf{A}\rightarrow\mathbf{B_a}$, $\mathbf{B}\rightarrow\mathbf{C_b}$, $\mathbf{C}\rightarrow\mathbf{A_c}$ (рис. 2, А, *5*, чёрная сплошная, серые шипики на рис. 1, А) и ассоциированные с ними $\boldsymbol{\varphi}$-связи (чёрные шипики).

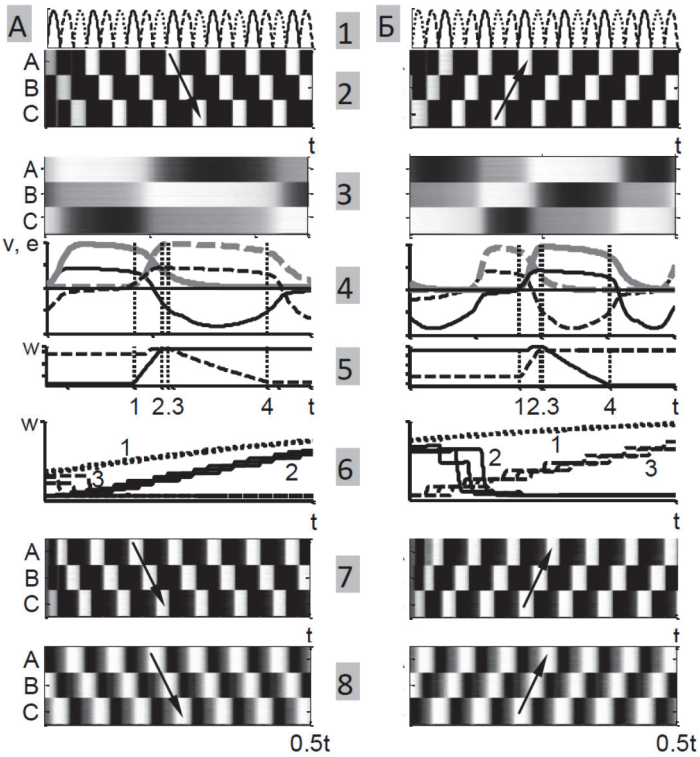

Рис. 2. Изменения связей при возбуждении нейронов в последовательности АВСА (А) и СВАС (Б): *1* – внешний сигнал ***S***, активирующий группу А – сплошная линия, В – штриховая, С – пунктирная; *2*, *3* – движение фокуса возбуждения (светлые участки); *4* – условия изменения связей, чёрные линии – постсинаптический потенциал, серые – пресинаптическое возбуждение, сплошные – А-нейроны, штриховые – В-нейроны; *5* – изменения весов связей; *6* – динамика связей при активации нейронов в последовательности СВАС (t = 500, не показано), АВСА (А, t = 1000), СВАС (Б, 1000). Внутригрупповые связи – *1*, АВСА-связи – *2*, СВАС – *3*; *7*, *8* – воспроизведение исходной последовательности после обучения

Совпадение коллатеральных ВПСП с постсинаптической деполяризацией (штриховые на рис. 2, А, *4*) вызывает усиление внутригрупповых и ассоциированных с ними направляющих связей. Активация синаптических окончаний **В**-нейронов (рис. 2, А, *4*, серая штриховая) совпадает с торможением **А**-нейронов (чёрная сплошная), что вызывает ослабление $\mathbf{B \rightarrow A_b}$

связей (рис. 2, А, *5*, штриховая) и ассоциированных с ними $\boldsymbol{\varphi}$-связей (светлые шипики). Аналогично ослабляются $\mathbf{C}\rightarrow\mathbf{B_c}$ и $\mathbf{A}\rightarrow\mathbf{C_a}$ связи.

При перемене направления движения фокуса возбуждения на противоположное – СВАС, на фоне другого сигнала направления $\boldsymbol{\pi}$ (рис. 2, Б) усиливаются связи $\mathbf{C}\rightarrow\mathbf{B_c}$, $\mathbf{B}\rightarrow\mathbf{A_b}$, $\mathbf{A}\rightarrow\mathbf{C_a}$, внутригрупповые и ассоциированные с ними $\boldsymbol{\pi}$-связи. Ослабляются связи $\mathbf{A}\rightarrow\mathbf{B_a}$, $\mathbf{B}\rightarrow\mathbf{C_b}$, $\mathbf{C}\rightarrow\mathbf{A_c}$ и ассоциированные $\boldsymbol{\pi}$-связи. В то же самое время *$\boldsymbol{\varphi}$-связи на дендритных ветках $\boldsymbol{A_c}$, $\boldsymbol{B_a}$, $\boldsymbol{C_b}$ (рис. 1, А) в отсутствие направляющего $\boldsymbol{\varphi}$-сигнала остаются без изменения.* При чередовании движений в противоположных направлениях коллатеральные межгрупповые связи остаются на низком уровне, например, связи, которые усиливаются при движении в направлении АВСА (рис. 2, А, *6*, *2*), ослабляются при движении в противоположном направлении СВАС (рис. 2, Б, *6*, *2*). Направляющие связи систематически усиливаются в направлении движения (например, связи $\boldsymbol{\varphi}\rightarrow\mathbf{B_a}$ в последовательности АВС, связи $\boldsymbol{\pi}\rightarrow\mathbf{A_b}$ в последовательности СВА) и ослабляются в противоположном направлении (например, $\boldsymbol{\varphi}\rightarrow\mathbf{A_b}$, $\boldsymbol{\pi}\rightarrow\mathbf{B_a}$). Усиливаются внутригрупповые коллатеральные и ассоциированные с ними направляющие связи (рис. 2, *6*, *1*).

Обученная нейросетка воспроизводит последовательность в соответствии с направляющим сигналом без внешнего принуждения, $\boldsymbol{S} = 0$ (рис. 2, *7*, *8*). Поскольку межгрупповые связи (AMPA-компонент) после обучения остаются слабыми, основным регулятором тока через NMDA-каналы межгрупповых связей становятся ВПСП ассоциированных направляющих связей, величина которых пропорциональна произведению постоянного синаптического возбуждения, вызванного сигналом направления, на матрицу весов, сформированную во время тренировки $\boldsymbol{v_\varphi} \propto e_\varphi \boldsymbol{w_\varphi}$. Величина тока через NMDA-канал, вызванного направляющим сигналом, на нисходящем участке вольт-амперной характеристики приблизительно пропорциональна произведению коллатерального синаптического возбуждения ($\boldsymbol{e_r}$), активирующего NMDA-рецепторы, на $\boldsymbol{w_\varphi}$-матрицу $\boldsymbol{I} \propto \boldsymbol{e_r v_\varphi} \propto \boldsymbol{e_r w_\varphi}$. Выражение для постсинаптического возбуждения в (1) можно приближенно записать как $(\boldsymbol{w_r} + \boldsymbol{w_\varphi})\boldsymbol{e_r} + \boldsymbol{w_\varphi} e_\varphi$, где $\boldsymbol{w_\varphi}$ – выученная матрица, $\boldsymbol{e_r}$, e_φ – синаптическое возбуждение через рекуррентные и направляющие связи (рис. 1, А).

Учитывая высокую концентрацию NMDA-рецепторов в синапсах коллатеральных связей и большую длительность тока через NMDA-канал, прямым, не опосредованным NMDA-каналами коллатералей, влиянием направляющих ВПСП на постсинаптические нейроны $e_\varphi \boldsymbol{w_\varphi}$, как и при обу-

чении, можно было бы пренебречь (рис. 2, *7*). Добавление к синаптическому сигналу постоянной составляющей e_{φ}, здесь равной половине максимального значения $\boldsymbol{e_r}$, не влияет на направление и структуру, но только на частоту активности (рис. 2, *8*).

Обсуждение

На примере простой нейронной сети с рекуррентными связями (этим похожей на поле CA3 гиппокампа) показано, как условный сигнал (подобный сигналу клеток направления – «head-direction cells» в энторинальной коре) приобретает способность активировать ту из последовательностей, связанных внешним сигналом S(t), групп клеток (подобных последовательностям клеток места, связанных в аллоцентрической системе координат), которую он сопровождал в предшествующем опыте («replay»/«preplay»). Запоминание и воспроизведение последовательностей основано на локальном механизме с двунаправленной NMDA – зависимой пластичностью. Усиление связей между группами последовательно активирующихся нейронов происходит при совпадении заднего фронта активации NMDA-рецепторов нейронов – источников с передним фронтом постсинаптической деполяризации нейронов – приёмников. Однако это усиление не сохраняется (стирается), когда фокус возбуждения распространяется в противоположном направлении и не может использоваться для одновременного хранения нескольких последовательностей (траекторий).

Запоминание траекторий в модели основано на локальной ассоциативной (кооперативной) пластичности [13, 14] синапсов клеток направления на клетках места. *Активные* синапсы клеток направления изменяются только в ассоциации с изменениями коллатеральных связей на той же дендритной ветке. В отсутствии «своего» сигнала направляющие связи не меняются при перемене направления распространения волны возбуждения.

Учитывая стирание *межнейронных* связей при перемене направления движения фокуса возбуждения, можно было бы контрастировать структуру модели до полного разделения типов рецепторов по принадлежности к связям – только *AMPA-рецепторы в направляющих связях*, только *NMDA-рецепторы в межнейронных*. Во время обучения *направляющие* связи используют NMDA – рецепторы *коллатеральных* связей для изменения своей эффективности, при воспроизведении – для усиления постсинаптического тока в нейронах – мишенях.

В условиях фиксации потенциала величина тока на нисходящем участке вольт-амперной характеристики NMDA-рецептора приблизительно пропорциональна величине мембранного потенциала; в физиологических условиях деполяризация в области локализации NMDAR может вызывать

генерацию NMDA-спайка [15, 16], пропорционального числу NMDAR, связанных с глутаматом, т.е. величине синаптического притока по коллатеральным связям ($\boldsymbol{e_r}$). Если, например, при воспроизведении последовательности ABC возбуждаются нейроны группы **B**, то согласно сделанным допущениям, $\boldsymbol{\varphi}$-ВПСП на дендритной ветке $\mathbf{C_b}$ достигают порога генерации NMDA-спайка на основе рецепторов коллатеральных связей $\mathbf{B \rightarrow C_b}$, оканчивающихся на той же дендритной ветке (рис. 1, А). В группе **A** окончания коллатералей из **B** (на дендритной ветке $\mathbf{A_b}$) не совпадают с окончаниями *потенцированных* $\boldsymbol{\varphi}$-связей (чёрные шипики на рис. 1, А), а активность (плотность) собственных NMDAR, согласно допущению, пренебрежимо мала по сравнению с коллатералями.

Критическим условием для предложенного здесь механизма является индукция пластичности только в активных AMPA-синапсах. Можно предложить другой вариант, при котором слабые направляющие связи изменяются в зависимости от собственных NMDA-рецепторов, условие активации которых – генерация NMDA-спайка [15, 16] при совпадении коллатерального и постсинаптического возбуждения. В таком варианте генерация NMDA-спайка в коллатеральных связях становится критическим событием как для индукции ассоциативной пластичности, так и для механизма воспроизведения последовательностей по условному направляющему сигналу.

Заключение

На примере простой нейронной сети показано, как при использовании двунаправленной ассоциативной синаптической пластичности, основанной на взаимодействии AMPA- и NMDA-рецепторов в зависимости от постсинаптического потенциала, сигнал клеток направления («head-direction cells») приобретает способность активировать ту последовательность (траекторию возбуждения) клеток места («place-cells»), с которой он ассоциировался в предшествующем опыте («replay»/«preplay»). В результате сигналы разных клеток направления становятся указателями на разные траектории (пути) на карте.

Ключевым элементом в структуре модели является разделение локализации подтипов глутаматных рецепторов – NMDA в межнейронных рекуррентных связях, AMPA – в направляющих связях. Во время обучения *направляющие* связи используют NMDA – рецепторы *коллатеральных* связей для изменения своей эффективности, при воспроизведении – для усиления постсинаптического тока в нейронах – мишенях.

Как этот механизм помогает найти скрытую мишень в «водяном лабиринте Морриса» [17]? Когда крыса в обучающей пробе в хорошо знакомом бассейне находит скрытую платформу, формируется ассоциация между

клетками места в гиппокампе и дофаминовыми нейронами среднего мозга [1, 18–20]. Если в тестовом испытании сигнал направления головы (в аллоцентрических координатах) активирует последовательность клеток места, достигающую платформы, «клетки платформы» активируют дофаминовые нейроны, а те движение в соответствии с направлением головы.

Список литературы

1. Майоров В.И. Поиск скрытой платформы в тесте Морриса по дофаминовому градиенту на клетках места // Журнал высшей нервной деятельности. 2018. Т. 68. № 4. С. 429–433.

2. Eichenbaum H. The role of the hippocampus in navigation is memory // J. Neurophysiol. 2017. Vol. 117. P. 1785–1796.

3. Lisman J., Buzsáki G., Eichenbaum H., Nadel L., Rangananth C., Redish A.D. Viewpoints: how the hippocampus contributes to memory, navigation and cognition // Nature Neuroscience. 2017. Vol. 20. No. 11. P. 1434–1447.

4. Poucet B., Lenck-Santini P.P., Hok V., Save E., Banquet J.P., Gaussier P., Müller R.U. Spatial Navigation and Hippocampal Place Cell Firing: The Problem of Goal Encoding // Rev. Neurosci. 2004. Vol. 15. No. 2. P. 89–107.

5. Ponulak F., Hopfield J.J. Rapid, parallel path planning by propagating wave fronts of spiking neural activity // Frontiers in Computational Neuroscience. 2013. Vol. 7. Article 98. P. 1–14.

6. Burak Y. Spatial coding and attractor dynamics of grid cells in the entorhinal cortex // Current Opinion in Neurobiology. 2014. Vol. 25. P. 169–175.

7. Erdem U.M., Hasselmo M.E. A goal-directed spatial navigation model using forward trajectory planning based on grid cells // Eur. J. Neurosci. 2012. Vol. 35. No. 6. P. 916–931.

8. Erdem U.M., Hasselmo M.E. A Biologically Inspired Hierarchical Goal Directed Navigation Model // J. Physiol. Paris. 2014. Vol. 108. No. 1. P. 28–37.

9. Sanders H., Rennó-Costa C., Idiart M., Lisman J. Grid Cells and Place Cells: An Integrated View of their Navigational and Memory Function // Trends Neurosci. 2015. Vol. 38. No. 12. P. 763–775.

10. Shipston-Sharman O., Solanka L., Nolan M.F. Continuous attractor network models of grid cell firing based on excitatory–inhibitory interactions // J. Physiol. 2016. Vol. 594. No. 22. P. 6547–6557.

11. Taube J.S. The Head Direction Signal: Origins and Sensory-Motor Integration // Annu. Rev. Neurosci. 2007. Vol. 30. P. 181–207.

12. Shouval H.Z., Wang S.S.-H., Wittenberg G.M. Spike timing dependent plasticity: a consequence of more fundamental learning rules // Frontiers in Computational Neuroscience. 2010. Vol. 4. Article 19. P. 1–13.

13. Larson J., Munkácsy E. Theta-burst LTP // Brain Res. 2015. Vol. 1621. P. 38–50.

14. Mehta M.R. Cooperative LTP can map memory sequences on dendritic branches // Trends in Neurosciences. 2004. Vol. 27. No. 2. P. 69–72.

15. Antic S.D., Zhou W-L., Moore A.R., Short S.M., Ikonomu K.D. The decade of the dendritic NMDA spike // J. Neurosci. Res. 2010. Vol. 88. No. 14. P. 2991–3001.

16. Brandalise F., Carta S., Helmchen F., Lisman J., Gerber U. Dendritic NMDA spikes are necessary for timing – dependent associative LTP in CA3 pyramidal cells // Nature communications. 2016. 7: 13480. P. 1–9.

17. O'Carroll C.M., Martin S.J., Sandin J., Frenguelli B., Morris R.G.M. Dopaminergic modulation of the persistence of one-trial hippocampus-dependent memory // Learn. Mem. 2006. Vol. 13. P. 760–769.

18. Buzsáki G. Hippocampal sharp wave-ripple: a cognitive biomarker for episodic memory and planning // Hippocampus. 2015. Vol. 25. P. 1073–1188.

19. Lisman J., Grace A.A. The hippocampal-VTA loop: controlling the entry of information into long-term memory // Neuron. 2005. Vol. 46. P. 703–713.

20. Zellner M.R, Ranaldi R. How conditioned stimuli acquire the ability to activate VTA dopamine cells: A proposed neurobiological component of reward-related learning // Neuroscience and Biobehavioral Reviews. 2010. Vol. 34. P. 769–780.

С.В. БОЖОКИН

Санкт-Петербургский политехнический университет Петра Великого

bsvjob@mail.ru

КОРРЕЛЯЦИЯ ВСПЫШЕК В НЕСТАЦИОНАРНОЙ ЭЭГ

Нестационарная ЭЭГ представлена как совокупность вспышек электрической активности нейронных ансамблей в различных спектральных диапазонах. Получено выражение для вейвлетной корреляционной функции двух сигналов ЭЭГ. Проанализированы корреляции вспышек для детерминистической модели ЭЭГ, в которой точно известны все спектрально-временные параметры вспышек, а также для стохастической модели ЭЭГ.

Ключевые слова: *вейвлетная корреляционная функция, корреляция вспышек нестационарной ЭЭГ.*

Введение

Деятельность мозга представляет собой активность многих нейронных ансамблей (*НА*) [1–5]. Основным механизмом, который позволяет регистрировать такую активность, является электроэнцефалограмма (*ЭЭГ*), регистрируемая со многих отведений головного мозга. Формирование *НА* происходит в тесном взаимодействии тормозных и возбуждающих нейронов. Д. Хебб в 1949 году определил *НА* как гипотетическое объединение нейронов, формирующееся в процессе обучения и выполняющее опреде-

ленную функцию [6]. Он предполагал, что взаимодействие между областями мозга, лежащие в основе памяти, основано на формировании в результате обучения специфических группировок нервных клеток (*НА*), синаптические связи между которыми усиливаются, когда они синхронно возбуждены. Элементарный (*НА*) представляет собой локальную группировку близких по своим свойствам нейронов, совместно реализующих свои функции [7–8].

Механизм формирования (*НА*) связан со способностью отдельных нейронов или их локальных групп генерировать электрическую активность в определенном спектральном диапазоне $\mu = (\delta, \theta, \alpha, \beta, \gamma)$ и синхронизировать эту активность. Синхронизация высокочастотных осцилляций обеспечивается взаимодействием возбуждений по замкнутым нейронным цепям. На этапе обучения при многократном повторении такой ситуации происходит модификация свойств синапсов, включенных в эту цепь. Пространственно-временной паттерн когерентной активности, возникающий в этой нейронной популяции в течение короткого временного интервала (миллисекунды), может рассматриваться как нейродинамический эквивалент воспринимаемого (или извлекаемого из памяти) образа. Из-за модификации свойств синапсов, включенных в эту цепь, создание этого паттерна может быть достаточно легко обеспечено даже при наличии многих помех. Многочисленные и разветвленные связи позволяют нейронным популяциям одновременно входить в состав множества функциональных *НА*.

Сигнал *ЭЭГ* отдельного отведения головного мозга можно рассматривать как систему вспышек, каждая из которых характеризуется своим временем возникновения, своей продолжительностью и поведением локальной частоты в конкретном спектральном диапазоне [9]. В структуре *ЭЭГ* можно выделить разные формы ритмической активности и осцилляторных паттернов, связанных с электрической активностью *НА* и отражающих функциональное состояние головного мозга [10, 11]. Метод сегментации сигналов *ЭЭГ* и последующее использование показателя когерентности и показателя синхронности (Phase-locking value) был применен для количественной оценки распространения возмущений *ЭЭГ* по поверхности головного мозга [12–15]. В статье [14] временные рассогласования электрической активности коры головного мозга вычисляются по сдвигу максимума кросскорреляционной функции. Однако заметим, что в работе [15] показано, что значение когерентности двух сигналов зависит от процедуры усреднения, от выбора величины окна, от функции окна, от величины сдвига шага окна. Следовательно, величину когерентности нельзя рассматривать в качестве строгой количественной меры коррелированности двух

сигналов $Z_A(t)$ и $Z_B(t)$, где A и B – два номера отведения *ЭЭГ*. Кроме того, компьютерные программы используют различные виды окон и количество усреднений, что приводит к сложности сопоставления результатов, полученных в работах многих авторов. В настоящее время большое развитие для количественного описания нестационарной *ЭЭГ* получил метод непрерывного вейвлет-преобразования (*НВП*) [6, 9, 16–21]. Метод *НВП*, в отличие от оконного преобразования Фурье, зависящего от продолжительности окна, позволяет проанализировать нестационарные свойства сигнала ЭЭГ, динамично изменяющего свои амплитудно-спектральные свойства. Однако изучение корреляции сигналов различных отведений ЭЭГ, выполненное с помощью *НВП*, требует дальнейшего усовершенствования.

Целью настоящей работы будет разработка метода корреляции нестационарной *ЭЭГ*, которая представляет собой чередование вспышек активности в различных спектральных диапазонах $\mu = \{\delta, \theta, \alpha, \beta, \gamma\}$. Первым этапом настоящей работы является разработка теоретической модели *ЭЭГ* двух отведений: сигнала $Z_A(t)$ и $Z_B(t)$. Каждый сигнал A и B представляет суперпозицию элементарных нестационарных сигналов (*ЭНС*), с известными амплитудными, временными и частотными характеристиками. Такая модель *ЭЭГ* является полностью детерминистической. Преимущество разработанной модели *ЭЭГ* состоит в известных спектрально-временных характеристиках суперпозиции всех вспышек, встречающихся в этих сигналах. Каждому сигналу сопоставляется свое (*НВП*) $V(\nu, t)$, зависящее от частоты ν и времени t: $Z_A(t) \to V_A(\nu, t)$, $Z_B(t) \to V_B(\nu, t)$. Второй этап состоит в нахождении выражения для вейвлетной корреляционной функции $WCF_{AB}(\nu, t)$, которая учитывает согласованность сдвигов вспышек, происходящих в сигналах A и B в различные моменты времени. Отличие предлагаемой функции $WCF_{AB}(\nu, t)$ от функции $CWS_{AB}(\nu, t) = V_A(\nu, t) V_B^*(\nu, t)$ [16–17] состоит в том, что $WCF_{AB}(\nu, t)$ описывает корреляцию сигналов в различные моменты времени, в то время как $CWS_{AB}(\nu, t)$ описывает лишь мгновенную корреляцию в данный момент времени. Для детерминистической модели *ЭЭГ* вид функции $WCF_{AB}(\nu, t)$ позволяет объяснить все возможные пики корреляции. Третьи этап работы состоит в построении стохастической модели *ЭЭГ* и нахождения корреляции двух сигналов.

Детерминистическая модель ЭЭГ

Рассмотрим детерминистическую модель *ЭЭГ*, в которой сигнал первого отведения $Z_A(t)$ может быть представлен в виде суперпозиции N_A элементарных нестационарных сигналов (*ЭНС*) $z_L\left(t-t_L\right)$:

$$Z_A(t)=\sum_{L=0}^{N_A-1} z_L\left(t-t_L\right), \tag{1}$$

$$z_L\left(t-t_L\right)=\frac{b_L}{2\tau_L\sqrt{\pi}}\exp\left[-\frac{\left(t-t_L\right)^2}{4\tau_L^2}\right]\cos\left[2\pi f_L\left(t-t_L\right)+\varphi_L\right]. \tag{2}$$

Каждый *ЭНС* имеет свою частоту f_L (*Hz*) и фазу φ_L (*rad*). Центр *ЭНС* находится по времени в точке t_L (*s*), имеет ширину локализации τ_L (*s*) и характеризуется амплитудой b_L. Пять параметров каждого *ЭНС* формируют одномерный массив $L=\left(b_L;f_L;t_L;\tau_L;\varphi_L\right)$. Для определения всего сигнала первого отведения $Z_A\left(t\right)$ (1) требуется $5N_A$ параметров *ЭНС*. Для такой суперпозиции весь сигнал $Z_A\left(t\right)$ может быть задан списком векторов $\vec{c}_L\left(A\right)=\left\{\vec{b}_L\left(A\right);\vec{f}_L\left(A\right);\vec{t}_L\left(A\right);\vec{\tau}_L\left(A\right);\vec{\varphi}_L\left(A\right)\right\}$, где $L=0,1,..N_A-1$. Второй сигнал *ЭЭГ* представим в виде суперпозиции: $Z_B(t)=\sum_{K=0}^{N_B-1} z_K\left(t-t_K\right)$, где список векторов $\vec{c}_K\left(B\right)=\left\{\vec{b}_K\left(B\right);\vec{f}_K\left(B\right);\vec{t}_K\left(B\right);\vec{\tau}_K\left(B\right);\vec{\varphi}_K\left(B\right)\right\}$. На рис. 1 и 2 представлены два сигнала $Z_A(t)$ и $Z_B\left(t\right)$ (табл. 1).

Набор частот $\vec{f}_L\left(A\right)=\left\{8;20;10;9;11\right\}$ и $\vec{f}_K\left(B\right)=\left\{11;20;9;10;8\right\}$ для A и B сигналов одинаковый. Это означает, что в сигнале $Z_A(t)$, и в сигнале $Z_B\left(t\right)$ существуют вспышки с одинаковыми частотами (8, 9, 10, 11, 20 Гц). Однако последовательность возникновения вспышек *ЭНС* с этими частотами, а также времена максимумов этих вспышек отличаются для сигналов $Z_A(t)$ и $Z_B\left(t\right)$: $\vec{t}_L\left(A\right)=\left\{0,5;2;4;7;9,5\right\}$, $\vec{t}_K\left(B\right)=\left\{0,75;3;4,75;7,5;9,6\right\}$. Отметим, что все фазы *ЭНС* нулевые $\vec{\varphi}_L\left(A\right)=\vec{\varphi}_K\left(B\right)=0$.

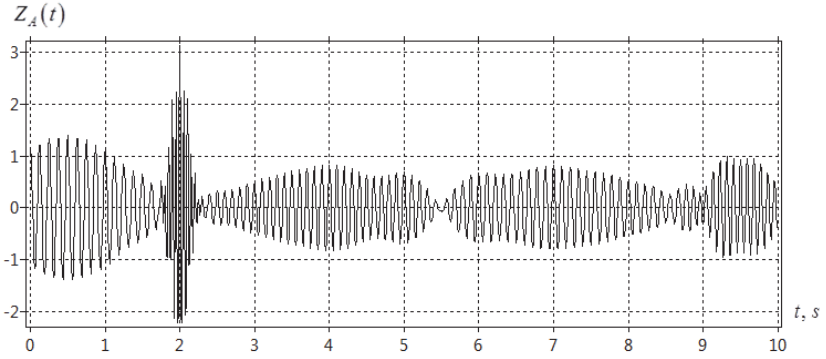

Рис. 1. Зависимость сигнала $Z_A(t)$ от времени t в секундах

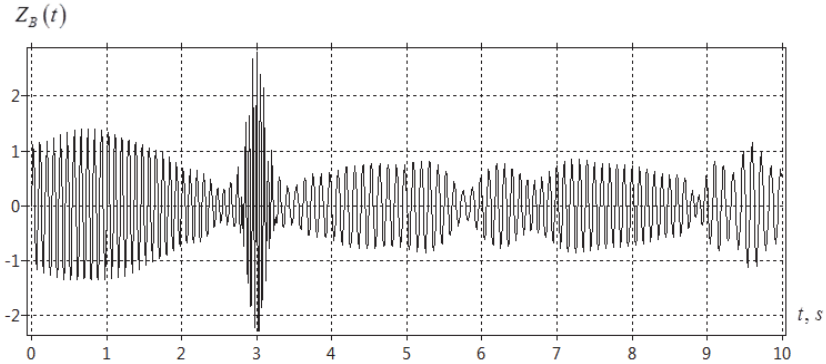

Рис. 2. Зависимость сигнала $Z_B(t)$ от времени t в секундах

Таблица 1

Параметры *ENS* $\vec{c}_L(A)$ и $\vec{c}_K(B)$ для сигналов $Z_A(t)$ и $Z_B(t)$

Сигнал	L,K	$b_L/(2\sqrt{\pi}\tau_L)$	f_L (Hz)	t_L (s)	τ_L (s)
$Z_A(t)$	0	1,4	8	0,5	0,54
	1	2,8	20	2	0,08
	2	0,8	10	4	0,74
	3	0,8	9	7	0,82
	4	1	11	9,5	0,3
$Z_B(t)$	0	1,4	11	0,75	0,8
	1	2,8	20	3	0,08
	2	0,8	9	4,75	0,8
	3	0,8	10	7,5	0,82
	4	1	8	9,6	0,3

Детерминистические модели сигналов *ЭЭГ* (рис. 1 и 2) представляют собой чередующиеся вспышки альфа активности различных частот в диапазоне [8–11 Гц], возникающие в различные моменты времени. Кроме такой альфа активности в сигнале $Z_A(t)$ есть уникальная вспышка β активности с частотой $f_1(A)$=20 *Hz*, центр которой находится в момент времени $t_1(A)$=2 *s*. Аналогичная вспышка β активности есть в сигнале $Z_B(t)$: $f_1(B)$=20 Гц. Ее центр локализован на одну секунду позже относительно вспышки в сигнале $Z_A(t)$: $t_1(B)$=3 с. Используемая в данной статье модель суперпозиции *ЭНС* с известными амплитудно-частотными характеристиками позволяет воспроизводить различные сценарии реальной нестационарной *ЭЭГ*. Точное знание корреляционных свойств двух модельных сигналов, созданных с помощью суперпозиции *ЭНС*, позволит в дальнейшем точно воспроизвести вейвлет корреляцию сложных сигналов *ЭЭГ*.

Вейвлетная корреляционная функция

Непрерывное вейвлетное преобразование (*НВП*), зависящее от частоты ν и времени t, применяется для анализа нестационарных сигналов *ЭЭГ* [5,9]. В этом случае для сигналов $Z_A(t)$ и $Z_B(t)$ находятся *НВП* $V_A(\nu,t)$ и $V_B(\nu,t)$. Выбор материнского вейвлета Морле и аналитические выражения для $V_A(\nu,t)$ и $V_B(\nu,t)$ приведены в работах [9,18-21]. Вейвлетная корреляционная функция $WCF_{AB}(\nu,t)$ имеет вид

$$WCF_{AB}(\nu,t)=\int_{-\infty}^{\infty} V_A^*(\nu,t')V_B(\nu,t+t')dt' . \qquad (3)$$

Функция $WCF_{AB}(\nu,t)$ показывает условную корреляцию двух сигналов, имеющих частоту ν, расположенных в моменты времени t' и $t+t'$. При использовании разработанной детерминистической модели *ЭЭГ* сигналы *A* и *B*, и их *НВП* имеют аналитический вид, поэтому $WCF_{AB}(\nu,t)$ также может быть вычислена аналитически. Анализ этого аналитического выражения для двух *ЭНС*: $Z_A(t)\to z_L(t-t_L)$ и $Z_B(t)\to z_K(t-t_K)$ показывает, что $WCF_{LK}(\nu,t)$ имеет абсолютный максимум, если частота ν удовлетворяет соотношению $\nu=f_L=f_K$. Этот максимум будет находиться в момент

времени $t = t_K - t_L$. Для сигналов $Z_A(t)$ и $Z_B(t)$ функция $WCF_{AB}(\nu, t)$ представлена на рис. 3.

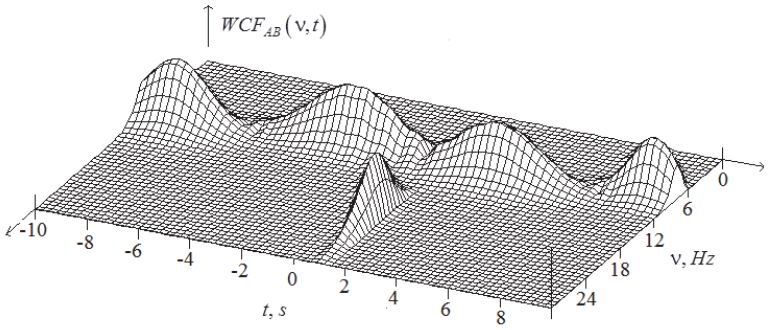

Рис. 3. Вейвлетная корреляционная функция $WCF_{AB}(\nu, t)$ для детерминированных сигналов $Z_A(t)$ и $Z_B(t)$, параметры которых представлены в табл. 1

Происхождение всех пиков в графике корреляционной функции $WCF_{AB}(\nu, t)$ можно объяснить следующим образом. Первый, самый левый пик, имеет максимальную частоту $\nu = f_4(A) = f_0(B) = 11$ *Hz*. Его максимум находится в момент времени $t = t_0(B) - t_4(A) = -8,75$ *s*. Второй левый пик имеет максимальную частоту $\nu = f_3(A) = f_2(B) = 9$ *Hz*. Он локализован в момент времени $t = t_2(B) - t_3(A) = -2,25$ *s*. Третий центральный пик локализован в точке $\nu = f_1(A) = f_1(B) = 20$ *Hz* при $t = t_1(B) - t_2(A) = 1$ *s*. Четвертый правый пик имеет параметры: $\nu = f_2(A) = f_3(B) = 10$ *Hz*, $t = t_3(B) - t_2(A) = 3,5$ *s*. Пятый, самый правый пик, имеет параметры: $\nu = f_0(A) = f_4(B) = 8$ *Hz*, $t = t_4(B) - t_0(A) = 9,1$ *s*.

Таким образом, для детерминистической модели *ЭЭГ*, в которой сигналы двух отведений A и B обладают одинаковым набором пяти частот вспышек (8,9,10,11,20 Гц), но расположенных в различном порядке и в различные моменты времени, функция $WCF_{AB}(\nu, t)$ точно определяет как корреляцию по частоте, так и корреляцию по времени *ЭНС*, входящих в суперпозицию $Z_A(t)$ и $Z_B(t)$. Если продолжительность двух сигналов $Z_A(t)$ и

$Z_B(t)$ равняется T, где T – период наблюдения, $t \in [0,T]$, то для исследования всех возможных корреляций необходимо рассматривать функцию $WCF_{AB}(\nu,t)$, для которой время $t \in [-T,T]$.

Стохастическая модель ЭЭГ

Разработаем стохастическую модель *ЭЭГ*, согласно которой сигналы $Z_A(t)$ и $Z_B(t)$ представляют собой суперпозицию *ЭНС*, причем все параметры $L=(b_L;f_L;t_L;\tau_L;\varphi_L)$ и $K=(b_K;f_K;t_K;\tau_K;\varphi_K)$ являются случайными числами, лежащими в некоторых интервалах. Пусть все случайные частоты f_L и f_K лежат в диапазоне α ритмов *ЭЭГ* [7–12 *Hz*]. Для такого случая набор частот сигнала $Z_B(t)$, в отличие от детерминистической модели, иной по сравнению с набором частот сигнала $Z_A(t)$. Сделаем одно исключение, и будем считать, что существует единственная одинаковая частота для двух наборов $f_1(A)=f_1(B)=20$ *Hz*, лежащая в диапазоне β ритма. Между двумя вспышками *ЭНС* с этой одинаковой частотой времена максимумов имеют разность времен локализации $t=t_1(B)-t_2(A)=1$ *s*. График функции для стохастической модели *ЭЭГ* представлен на рис. 4.

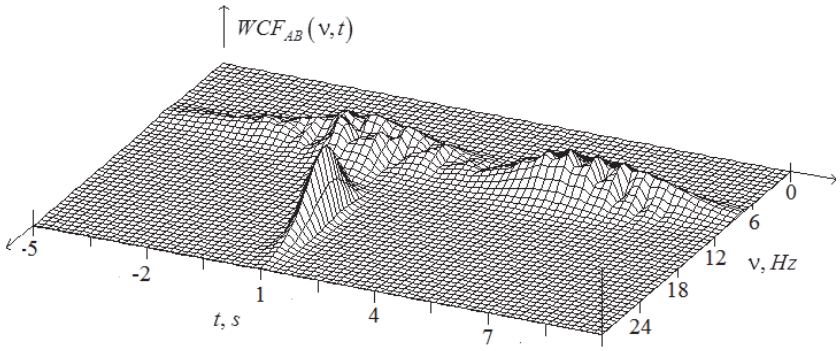

Рис. 4. Вейвлетная корреляционная функция $WCF_{AB}(\nu,t)$ для стохастической модели сигналов $Z_A(t)$ и $Z_B(t)$

Анализ этого рисунка показывает, что для данной стохастической модели *ЭЭГ* диапазон времен, для которых существенна корреляция *ЭНС*, распространяется на интервал $t \in [-5;10\ s]$. Существует целая полоса частот [7-12 *Hz*], в которой элементарные *ЭНС*, составляющие сигналы $Z_A(t)$ и $Z_B(t)$, имеющие близкие частоты, слабо коррелируют. Характерные времена, на которых наблюдается эта корреляция, разбросаны в интервале времен $t \in [-5;10\ s]$. Однако самой большой корреляцией является корреляция двух *ЭНС* с одинаковой частотой 20 *Hz*, каждый из которых входит как в сигнал $Z_A(t)$, так и в сигнал $Z_B(t)$. Такой самый высокий пик центрирован по частоте в точке $\nu = f_1(A) = f_1(B) = 20\,Hz$ в момент времени $t = t_1(B) - t_2(A) = 1\ s$.

Выводы

Предложена модель, согласно которой нестационарный сигнал *ЭЭГ* может быть представлен как совокупность вспышек *ЭНС*. Для анализа свойств таких сигналов использовано *НВП*. Рассмотрена детерминистическая модель *ЭЭГ*, в которой точно известны все параметры *ЭНС*, и стохастическая, в которой все параметры *ЭНС* − случайные числа. Для каждого сигнала $Z_A(t)$ и $Z_B(t)$ аналитически получены выражения для *НВП*: $Z_A(t) \to V_A(\nu,t)$, $Z_B(t) \to V_B(\nu,t)$. Получено аналитическое выражение для вейвлетной корреляционной функции (*ВКФ*) двух сигналов $WCF_{AB}(\nu,t)$. Построенный график *ВКФ* объясняет происхождение всех полученных пиков корреляций для двух моделей. Расчеты *ВКФ* для модельных *ЭЭГ*, позволят тестировать компьютерные программы вычисления корреляционных свойств реальных сигналов ЭЭГ. Предлагаемый метод может быть применен для вычисление времен нарастания и спадания корреляций сигналов различных отведений головного во время различных функциональных проб, а также для составления карт движения возмущений по поверхности головного мозга.

Работа выполнена в рамках Государственного задания на проведение фундаментальных исследований (код темы FSEG-2020-0024).

Список литературы

1. Зенков Л.Р. Клиническая электроэнцефалография с элементами эпилептологии. М.: МЕДПрессинформ, 2012. 356 с.

2. Кропотов Ю.Д. Количественная ЭЭГ, когнитивные вызванные потенциалы мозга человека и нейротерапия. Донецк, 2010. 512 с.

3. Иванов Л.Б. Прикладная компьютерная электроэнцефалография. 2-е изд. М.: Научно-медицинская фирма МБН, 2004. 352 с.

4. Кулаичев А.П. Компьютерная электрофизиология и функциональная диагностика. М.: Форум. ИНФРА-М, 2007. 640 с.

5. Короновский А.А., Макаров В.А., Павлов А.Н., Ситникова Е.Ю., Храмов А.Е. Вейвлеты в нейродинамике и нейрофизиологии. М.: Физматлит, 2013. 272 с.

6. Hebb D.O. The Organizationa of Behavior.-N.Y.:Wiley. 1949. 319 p.

7. Кирой В.Н., Чораян О.Г., Нейронные ансамбли мозга // Успехи физиологических наук. 2000. Т. 31. N 2. С. 23–39.

8. Абарбанель Г.Д., Рабинович М.И., Селверстон А., Баженов М.В., Хуэрта Р., Сущик М.М., Рубчинский Л.Л. Синхронизация в нейронных ансамблях // УФН. 1996. Т. 166. N 4. С. 363–390.

9. Bozhokin S.V., Suslova I.B. Wavelet-based analysis of spectral rearrangements of EEG patterns and of non-stationary correlations // Physica A: Statistical Mechanics and its Applications. 2015. V. 421(1). P. 151–160.

10. Казанович Я.Б., Теория временной корреляции и модели сегментации зрительной информации в мозге (обзор) // Математическая биология и биоинформатика. 2010. Т. 5. N 1. С. 43–97.

11. Quiles M.G., Wang D., Zhaoc L, Romeroc R.A.F., Huang D.S. Selecting salient objects in real scenes: An oscillatory correlation model // Neural Networks. 2011. Т. 24. P. 54–64.

12. Каплан А.Я., Борисов С.В. Динамика сегментных характеристик альфа-активности ЭЭГ человека в покое и при когнитивных нагрузках // Физиология высшей нервной (психической) деятельности человека. 2003. Т. 53. N 1. С. 22–32.

13. Николаев А.Р., Иваницкий Г.А., Иваницкий А.Н. Исследование корковых взаимодействий в коротких интервалах времени при поиске вербальных ассоциаций // Журнал высшей нервной деятельности. 2000. Т. 50. N 1. С. 44–66.

14. Трофимов А.Г., Колодкин И.В., Ушаков В.Л., Величковский Б.М. Агломеративный метод выделения микросостояний ЭЭГ, связанных с характеристиками бегущих волн. XVII Всероссийская научно-техническая конференция «Нейроинформатика-2015»: Сборник научных трудов. В 3-х ч. Ч. 1. М.: НИЯУ МИФИ, 2015. С. 66–77.

15. Kulaichev A.P. The informativeness of coherence analysis in EEG studies // Neuroscience and behavioral physiology. 2011. V. 41(3). P. 321–328.

16. Kang S.H, McIver R.P., Hernandes J.A. Co-movements between Bitcoin and Gold: A wavelet coherence analysis // Physica A: Statistical Mechanics and its Applications. 2019. V. 536. P. 120888.

17. Chavez M., Cazelles B. Detecting dynamic spatial correlation patterns with generalized wavelet coherence and non-stationary surrogate data // Sci. Rep. 2019. V. 9. P. 7389.

18 Bozhokin S.V., Suvorov N.B. Wavelet analysis of transients of an electroencephalogram at photostimulation // Biomed. Radioelektron. 2008. N 3. P. 21–25.

19. Bozhokin S.V. Wavelet analysis of learning and forgetting of photostimulation rhythms for a nonstationary electroencephalogram // Technical Phys. 2010. V. 55. N 9. P. 1248–1256.

20. Bozhokin S.V., Suslova I.B. Instantaneous Correlation Of Spectral Integrals Related to Records from Different EEG Channels // Lecture Notes of Computer Science. 2016. V. 9719. P. 49–55.

21. Bozhokin S.V., Zharko S.V., Larionov N.V., Litvinov A.N., Sokolov I.M. Wavelet Correlation of Nonstationary Signals // Technical Physics. 2017. V. 62. N 6. P. 837–845.

А.С. РАТУШНЯК, И.А. МАЛАХИН, Т.А. ЗАПАРА
Федеральный исследовательский центр информационных
и вычислительных технологий, Новосибирск
ratushniak.alex@gmail.com

МОДЕЛИРОВАНИЕ БИОЛОГИЧЕСКИ ИНСПИРИРОВАННЫХ ИНФОРМАЦИОННЫХ СИСТЕМ ЧЕРЕЗ ЭВОЛЮЦИЮ ПРОСТЕЙШИХ АГЕНТОВ*

Для создания новых поколений биологически инспирированных информационных систем необходимы актуальные знания о структурно функциональных свойствах их биологических прототипов. Получение таких знаний осуществляется теоретическими и экспериментальными методами. Экспериментальный анализ молекулярных информационных машин, которыми, по существу, являются нервные клетки, малопродуктивны в связи с методическими трудностями, переходящими, в силу многообразия, в принципиальные. Попытки математического моделирования даже самых простых из существующих биологических систем в виду их чрезвычайной и неупрощаемой сложности ограничено возможностями методологии и производительностью существующих информационных комплексов. Все это выдвигает задачу поиска новых путей исследования биологических систем.

В данной работе предпринята попытка создания модели биологической системы как результата эволюции простого базового агента, элемента живых систем. Эта модель базируется на представлениях о физической природе живых систем их возникновения и эволюции. Разрабатывается модель среды, во взаимодействии с которой, осуществляется функционирование и эволюция агента. Проведен поиск и экспериментальный анализ вероятных доархейных элементов нервных клеток. Рассмотрена возможность создания физической модели негэнтропийного агента.

Увеличение сложности модели таких агентов и среды их существования возможно в пределах возможностей инструментального моделирования. Формирование сетей более высоких уровней из таких агентов позволит создавать системы, обладающие мотивационными, прогностическими и другими когнитивными свойствами близкими к биологическим прототипам.

Ключевые слова: *нейронаука, нейробиология, информационные процессы в нейронах и нейронных системах, биоинформатика, компьютерная биология.*

* В работе использованы материалы, полученные при выполнении базового проекта фундаментальных исследований РАН VI.35.2.6 и проекта РФФИ № 17-04-01440-а.

Введение

Для получения знаний о принципах и механизмах функционирования биологических информационных систем необходим экспериментальный и теоретический анализ. Проблемы, возникающие в таких исследованиях, обусловлены, прежде всего, чрезвычайной и практически неупрощаемой сложностью таких систем. Даже самые простые из существующих сейчас биологических систем состоят из многих тысяч (например, http://wwwmgs.bionet.nsc.ru/mgs/gnw/genenet/viewer/) различных элементов порядок и динамика взаимодействия которых во многом неизвестны. Такие упрощенные карты взаимодействий элементов не позволяет сделать достаточно обоснованные заключения о функциях и принципов работы этих систем. Выявление в полном объеме принципов работы по сути молекулярных машин экспериментальными методами обусловлено отсутствием методов и технологий таких исследований. Также мало малоэффективны работы, направленные на создание моделей биологических систем. При создании таких моделей для возможности их инструментальной реализации неизбежно возникает необходимость упрощения системы. При этом известно, что отсутствие (или модификация) даже одного из элементов системы (например, белка) ведет к изменению функций системы или ее полной нежизнеспособности. Задача создания концепции систем, приближающихся к биологическим, с точки зрения набора функций, актуальна как в области компьютерных наук, так и в области коррекции патологии. Значительные силы и ресурсы сосредоточены на решении этих проблем. Однако значительного успеха в этом направлении пока не достигнуто [1]. Существующие подходы к решению этих проблем основаны, как правило, на концепциях, которые были разработаны в условиях отсутствия современных знаний и, соответственно, не учитывают физические принципы, конкретные механизмы и архитектуру нейронов как биологических молекулярных информационных машин. Основные функции биологических информационных систем и мозга в основном определяются не архитектурой межклеточной коммуникации, а функцией («программным обеспечением») клеток и динамикой их организации в процессе выполнения конкретной задачи. Некоторые животные с радикально отличной архитектурой мозга - млекопитающие, птицы и рыбы – совместимы с тестом на наличие такой сложной психологической функции, как самосознание (например, [2]). При этом молекулярная архитектура их нейронов принципиально не отличается. Понятно, что такие функции не возникают по двоичному принципу (все или ничего). Элементы довольно сложных функций могут присутствовать при разной архитектуре биологической системы. В то же время

необходимо понимать, что проблемы, близкие к психологическому уровню, решаются уже на основе молекулярной внутриклеточной архитектуры. Даже одноклеточные организмы в некоторых случаях обладают рядом свойств, близких к когнитивным [3]. Вот почему для понимания базовых принципов работы мозга требуется знание физических основ и причин возникновения таких свойств в эволюции. Эта задача может быть решена только на основе анализа различий между живыми и неживыми системами. Наиболее распространенным является представление о том, что основной функцией живой системы является возможность самовоспроизведения. Несмотря на значительные противоречия, эта «генетическая» теория жизни является доминирующей. В то же время упускается из виду другое качество живых объектов – повышение упорядоченности (снижение энтропии, сохранение гомеостаза) в таких термодинамически и информационно открытых системах. Физической основой такой функции может быть предсказание - прямое отражение [4–6]. Определение будущего состояния внешней и внутренней среды. Прогноз может быть сформирован даже чрезвычайно простой молекулярной системой, основанной на ассоциативном обучении (запоминании) или индуктивных статистических выводах [7–15]. Такие простые молекулярные системы, которые способны на основе прогноза избегать неблагоприятных воздействий и приобретать дополнительную энергию и информацию, получили эволюционное преимущество. Их эволюция направлена на расширение спектра рецептивных сигналов и эффекторных реакций. Вероятно, эти негэнтропийные модули стали основой клеток и в дальнейшем многоклеточных систем. Такие молекулярные архитектуры являются основой биологических систем разных уровней, определяющих их способность к когнитивным процессам. В то же время возможности таких систем увеличивались от уровня к уровню, но принципы и основные функции оставались неизменными.

1. Возможные подходы и методы создания биологически инспирированных когнитивных систем

Одним из возможных и наиболее перспективных подходов для разработки систем с когнитивными свойствами является создание имитационных моделей известных биологических информационных систем. Попытки сформировать такие модели обычно ограничены их неупрощаемой сложностью и отсутствием всесторонних знаний об основной функциональной роли составляющих элементов и системы в целом. Однако даже если бы такие знания были, сложность систем намного превосходит возможности инструментального моделирования. Возможности экспериментального

анализа функционирования биологических молекулярных информационных систем также крайне ограничены. В этой ситуации кажется продуктивным создавать такие модели снизу вверх. Для этого необходимо определить «предельные точки» основных функций живых систем на основе физических принципов и возможных направлений их эволюционного развития. Парадигма биологических информационных систем сводится к негэнтропийному принципу. Этот принцип, связывающий энтропию и информационные процессы, был сформулирован многими авторами (например, [16-18]). Информация может внести отрицательный вклад в энтропию. То есть негэнтропия может перейти в информацию и наоборот. Существование биологических систем как зоны устойчивости структурно-функциональных молекулярных ансамблей основано на этом физическом принципе. Такая возможность в термодинамически открытых системах существует только благодаря прогностике, основанной на хранении информации о взаимодействии с окружающей средой. Одним из основных обобщений, касающихся роли прогностики в биологии, является понятие опережающего отражения реальности, сформулированное П.К. Анохиным [19]. Суть его в том, что «многие поколения живых систем, столкнувшиеся с определенной последовательностью повторяющихся внешних событий (смена времен года, дня и ночи и т. д.), не только отражали последовательность этих событий, но и фиксировали ее в цепях химических соединений. Благодаря появлению системы биокатализаторов соответствующие цепи химических реакций приобрели способность разворачиваться и заканчиваться гораздо быстрее, чем последовательности внешних событий. Но содержание этих реакций определяется внешними событиями и является их отражением (в прошлом). По отношению к текущей ситуации это «ведущее отражение», определяющее реакцию, предшествующую самому событию. Фактически, живая система остается живой, пока она совершает такие «обгоны» (опережения). Вероятно, это структуры с такими свойствами, которые сформировались на этапе возникновения жизни. Вероятность самопроизвольного образования молекулярных систем, обладающих этими качествами, возможна только в том случае, если такие системы предельно просты. Более того, у них уже должен быть какой-то «запас», избыток упорядоченности. Формирование «ассоциативной памяти» в таких ансамблях может вызвать появление в них неэнтропийных функций. В этом случае информация, полученная системой, позволяет повысить ее энергетическую стабильность и служит для создания эволюционного преимущества. Интеграция таких систем расширяет информационный канал, возможность получения боль-

шего количества сигналов и реакций на них. Выбор средой таких надмолекулярных комплексов привел к их эволюции и приобретению качеств, лежащих в основе когнитивности.

В связи с этим наиболее перспективным подходом для создания биологически инспирированных когнитивных систем, по-видимому, является создание негэнтропийных модулей (в виде простых имитационных моделей) и построение из них систем более высокого уровня на основе существующих биологических прототипов. Конструируя из таких базовых элементов системы, которые имеют большее разнообразие рецепторных и эффекторных блоков, можно адаптировать их к модели среды в направлении увеличения «выживаемости». Т.е. при этом могут формироваться системы подобные их клеточным прототипам. Дальнейшее наращивание сложности подобных комплексов возможно на основе создания прототипов многоклеточности. Это, в свою очередь, позволит формировать многоуровневые системы подобные мозгу. При этом внутренние “клетки” могут играть роль подобную отделам мозга ответственных за формирование разнообразия когнитивных функций.

2. Роль в создания биологически инспирированных когнитивных систем внешней среды

При моделировании биологически инспирированных информационных систем редко учитывается роль окружающей среды. Не учитывается, что граница между живым и не живым зачастую определяется именно средой. Например, вирусы обладают свойствами живого только при наличии в среде клеточных систем. Свойства той среды, в которой возникают и эволюционируют биосистемы, являются одним из важнейших факторов приведшим к существующим формам таких систем. Одним из главных условий и факторов возникновения биологических систем можно считать наличие в среде градиентов, которые могут позволить возникающим молекулярным системам концентрировать энергию в некотором внутреннем пространстве. Это могут быть градиенты температур, концентраций, давлений, освещенности и т.д. Примеры существования биологических систем в таких условиях встречаются повсеместно. Черные курильщики (как и другие места наличия устойчивых градиентов) можно рассматривать как наглядный пример возможных условий возникновения и существования сообществ биологических систем. При моделировании биосистем необходимо наряду с созданием их моделей и создание модели среды, в которой предполагается их существование. Модификации биосистем возможны при

наличии в окружающей среде свойства вариабельности. Такая вариабельность может быть индуцирована энтропийными и другими процессами. Однако при этом важен баланс устойчивости и вариабельности. Уровень вариабельности определяет формируемые средой параметры биосистем связанные со скоростью запоминания предшествующих событий и формирования прогноза. Важным является набор факторов, которые могут играть сигнальную роль для биологических информационных систем. Существенное значение имеет анизотропия среды, прозрачность для звука, света, вязкость, электропроводность, теплопроводность и др. При этом биосистемы подстраиваются под изменяющиеся условия на основе обратных связей. В этих условиях возможно возникновение, как новых свойств биообъектов, так и разных форм, занимающих определенные ниши. Ограниченность вариабельных параметров среды определяет уровень возможных изменений биосистем и в конечном итоге уровень их универсальности, устойчивости при смене внешних условий. Узкоспециализированные формы таких систем, занимающие ограниченные ниши, в целом могут быть менее устойчивыми при коррекции границ таких ниш.

3. Результаты

На базе естественно научных представлений о возникновения живых систем и их негэнтропийной природе [16–18] разработана модель ассоциативного логического агента как их доархейного прототипа. Сформирована модель среды с определенным наполнением элементами, из которых могут спонтанно формироваться агенты, сигнальным наполнением различной модальности и уровнем энтропии. В процессе моделирования в среде оптимизировано количество элементов (обладающих логическими функциями) определяющих вероятность возникновения агента. Определен набор условий, коэффициентов и правил взаимодействия агентов и среды, стабилизирующих систему в целом. Определен ряд свойств: агент формируется в среде с определенным запасом lifeEnergy изначально равное INITIAL_LIFE_ENERGY. Агент обладает рядом разномодальных рецепторов сигналов из внешней среды и эффекторов, влияющих на взаимодействие агента со средой. При активации рецептора сигналом среды осуществляет определение его влияние на запас lifeEnergy. При наличии нескольких сигналов происходит логический анализ их ассоциативности. Определяются сигналы, ведущие к уменьшению и увеличению lifeEnergy. В случае если определена ассоциация нескольких сигналов происходит запоминание такой ассоциации. Определяются сигналы, ведущие к максимальным и минимальным затратам или увеличению lifeEnergy. Если сигнал

с меньшими затратами предшествует сигналу с большими затратами, то реакция агента на первый сигнал в ассоциативной паре исключает реакцию на второй сигнал. Если первый сигнал предшествует сигналу с приобретением lifeEnergy, то реакция агента на первый сигнал в ассоциативной паре реагирует приобретением lifeEnergy. В результате оптимизации значений коэффициентов удалось получить устойчивое состояние агента во внешней среде. Изменения параметров среды индуцирует эволюцию агентов.

Исходя из общих законов биологии возникновения архей, последующих клеточных элементов и других уровней биосистем происходило, видимо, путем формирования их из доархейных элементов. На базе таких концепций представляет интерес поиск доархейных элементов в существующих сейчас клетках. Нами предпринята попытка такого поиска. На изолированных нервных клетках проведена выработка ассоциативной реакции на молекулярных комплексах, состоящих из нескольких рецепторов и ионного канала (NMDA рецептор-эффекторного комплекс). Положительные результаты ассоциативной реакции на молекулярном уровне могут свидетельствовать о верности этих предположений.

Рассмотрена возможность создания физической модели доархейных негэнтропийных агентов на базе наноконструкций и молекулярной электроники.

Заключение

Таким образом, концепция негэнтропийной прогностической природы когнитивных биосистем, вероятно, должна лежать в основе создания биологически инспирированных когнитивных систем. В рамках такой концепции биологические информационные системы решают основную для них задачу определения значимости сигналов для увеличения или уменьшения энтропии. При этом они ориентированы не на вычислительные процессы, а на прогнозирование. Разные уровни организации таких систем различаются количеством принимаемых сигналов и глубиной прогнозирования.

Наиболее перспективным подходом к созданию биологически инспирированных когнитивных систем, по-видимому, является создание негэнтропийных агентов (в виде простых имитационных моделей или физических молекулярных конструкций). Развитие таких базовых элементов системы, возможно за счет возрастания разнообразия рецепторных и эффекторных блоков. В целом в модели может быть организована адаптация агентов (в направлении увеличения «выживаемости») к расширению перечня параметров внешней среды приближая ее к реально существующим средам.

Наращивать сложность модели биологически инспирированных когнитивных систем путем объединения их при сетевом или матричном подходах возможно вплоть до пределов возможности инструментальных средств. Построение из них систем более высокого уровня возможно на основе существующих биологических прототипов и понимания принципов их эволюции. Создавая иерархию таких комплексов, можно добиться появления в одном из блоков внутренней модели всей системы, то есть внешние блоки, по отношению к ней, станут ее средой обитания. В целом, это может привести к формированию своего рода внутреннего «наблюдателя», принимающего решения, в зависимости от прогноза поведения остальной системы. По сути, для выполнения действий, приближающих такие системы к возникновению свойств, близких к функции сознания.

Список литературы

1. Stern P // Science. 2017. 358 (6362): 464–5.

2. Frans B. M. de Waal, Fish, mirrors, and a gradualist perspective on self-awareness, PLoS Biol 17 (2): FBM (2019) e3000112. https://doi.org/10.1371/journal.pbio.3000112.

3. Thomas A. Richards & Suely L. Gomes, How to build a microbial eye // Nature. 2015. V. 523. P. 166–167, doi:10.1038/nature14630.

4. Anokhin P.K. Principal issues of the theory of functional systems // Philosophical aspects of the theory of functional systems. M.: Science, 1978. with. 49–106. In Russian.

5. Vityaev E.E. Semantic probabilistic inference of predictions // News of Irkutsk State University. Series Mathematics. 2017. Vol. 21. P. 33–50, doi / 10.26516 / 1997-7670.2017.21.33.

6. Vityaev EE, Kharlamov E. Yu. Formalization of the concept of prediction // Probabilistic ideas in science and philosophy, materials of the regional conference, Novosibirsk. 2003. P. 79–82.

7. Hempel, C.G. Aspects of Scientific Explanation, In: C.G. Hempel, Essays in the Philosophy of Science. The Free Press. New York, 1965.

8. Hempel, C.G. ‘Maximal Specificity and Law law in Probabilistic Explanation, Philosophy of Science. 1968. 35. P. 16–33.

9. Popper K.R. The Logic and Growth of Scientific Knowledge. M.: Progress, 1983. 604 p.

10. Popper K.R. The Logic of Scientific Discovery. London, 1959.

11. Popper K.R. Objective Knowledge, Evolutionary Approach. M.: URSS, 2002. 363 p.

12. Hempel C.G. Deductive-Nomological vs. Statistical Explanation. // Minnesota Studies in Philosophy of Science III, University of Minnesota Press, Minneapolis, 1962.

13. Caporale, N., Dan, Y. Spike timing-dependent plasticity: a Hebbian learning rule Annu Rev Neurosci 31: 25–46. 2008. doi: 10.1146/annurev.neuro.31.060407.125639.

14. Lehn J.-M. Supramolecular Chemistry: Concepts and Perspectives. Morrisville, NC: Wiley-VCH. 1995.

15. Hirst, A.R., Escuder, B., Miravet, J.F., Smith, D.K. High-tech applications of self assembling supramolecular nanostructures gel phase materials : From Regenerative Medicine to Electronic Devices. Angew. Chem. Int. Ed., 47, (2008). doi: 10.1002/anie.200800022.

16. Brillouin L. Science and Information Theory Academic Press, 1962. 351 p.

17. Schrödinger E. What is Life? The Physical Aspect of the Living Cell, Cambridge: University Press, 1944. 92 p.

18. Krushinsky A. Payment for solving the problem: biophysical prerequisites and possible evolutionary consequences // Russian Journal of Cognitive Science. 2015. T. 2. No. 1.

19. Anokhin P. K. Anticipatory reflection of reality // Vopr. philosophy. 1962. No. 6. P. 97–109.

S.I. BARTSEV[1,2], G.M. MARKOVA[2]
[1]Institute of Biophysics Siberian Branch of RAS, Krasnoyarsk
[2]Siberian Federal University, Krasnoyarsk
bartsev@yandex.ru

ON DETECTING NEURAL CORRELATES IN SIMPLE RECURRENT NEURAL NETWORKS PASSED THE DELAYED MATCHING TO SAMPLE TEST

According to the concept of neural correlates of consciousness, it is important to determine the minimum sufficient number of neurons that accompany conscious experience. Reflection is considered as the key property of consciousness inherent in organisms even with a fairly simple nervous system. The possibility of detecting neural correlates of reflection is investigated in a simple recurrent neural network trained to pass the delayed matching to sample test. An attempt to identify the portraits of neural correlates of reflection was made in computational experiments.

Keywords: *neural correlates of consciousness, neural correlates of reflection, neural network passing DMTS test.*

1. Introduction

The nature of consciousness is one of the most exciting and the hardest problem of modern science. Despite the efforts of many scientists and philosophers to understand the nature of consciousness, there is no significant progress. A fairly complete picture of the variety of approaches and points of view about the problem of consciousness is given, for example, by A. Revonsuo's book [1]. The goal of our paper is to evaluate the possibilities of neural network modeling in the direction of the study of consciousness, proposed by F. Crick with co-author [2].

Their idea is to abandon attempts to understand what consciousness is, and focus on the association of certain phenomena of consciousness with brain activity that can be objectively recorded. According to the authors, these studies should determine what is the **minimum** sufficient number of neurons or the **minimum** activity of the nervous system, which necessarily accompanies this or that conscious experience. The above is a definition of the concept of "Neural Correlates of Consciousness" (NCC) [2, 3]. it is pertinent to note that this orientation to the **minimum** number of neurons, which ensures the realization of phenomena of consciousness directly corresponds to the scientific approach.

Physics generally uses elementary models as starting points to construct complex models, which describe real objects. Elementary models are usually extremely simple, and they describe nonexistent ideal objects such as material point, ideal gas, perfect black body, etc. In spite of their perfect simplicity, they provide an adequate approximate description of a number of physical systems [4, p. 1–3].

But how to apply this approach to human consciousness, which seems to be inseparable from the human brain, one of the most complex systems? Within the framework of the NCC concept, various models of neural organization are developed that provide the appearance of phenomena of consciousness [5–10], conditions for its existence are evaluated [11] and even measures are proposed to assess the degree of awareness [10, 12]. All these models try to explain the emergence of consciousness in almost all the complexity of its manifestations, which greatly complicates the verification of their adequacy.

However, if you follow the message of the NCC concept and the spirit of physics, you can concentrate on key individual phenomena, manifestations or functions of consciousness without which consciousness, as a phenomenon, is impossible. One of these functions is reflection, which can be understood in a broad and narrow sense.

In a broad sense, reflection is an internal representation of the external world, used by organisms to solve survival problems. One of the vivid proofs of the existence of such representation, independent of current perception, is bee dancing, when a bee passes on to its colleagues an information on the path to nectar.

In the narrow sense that psychologists and human scientists usually use, reflection refers to the ability to look at oneself from the outside, to evaluate one's own behavior, from the perspective of an outside observer.

The theoretical arguments in favor of the possibility of an extremely simple formal description of the phenomena of consciousness are V. Lefebvre' studies (for example [13]). He postulated that subjectivity (consciousness, mind) is closely associated with an internal representation of external world and a subject itself in it. This kind of representation Lefebvre called reflection. Proposed by him simple model based on simple axioms explains the results of a number of psychological experiments, which had no satisfactory explanation before.

Taking reflection as an object of study we can greatly simplify the task (searching for Neural Correlates of Reflection (NCR) instead of searching for Neural Correlates of Consciousness (NCC)) and can make an attempt to outline behavioral patterns that are possible only with reflection. We will return to the question on behavioral patterns of reflection later, and now we need to answer the question about the configuration of the neural network necessary for the implementation of reflection in the broad sense of the word. Reflection in the narrow sense is more complicated, so for now (in this paper) we will not consider it.

Studies conducted with even very simple organisms [14–17] showed that feedback between most neurons is an important property of the system. It has been shown the so-called recurrent structure of a neural network, which potentially ensures the autonomous existence of internal mappings of the previous state of receptors, is realized in these organisms.

This experimental argument for using recurrent neural networks to model reflection can be supported by a theoretical argument based on the fact that the network structure has to provide the interaction of information coming from outside with some dynamic information inside the system. Multilayer feed forward neural networks are not able to provide this kind of interaction. The fundamental inability of a multilayer network to solve effectively problems requiring an internal representation of the outside world for its solution was demonstrated by the example of the reflexive game [18]. It was shown a multilayer neural network, even equipped with a shift register that stores the previous moves of the opponent, was losing as a rule to a recurrent neural network with less number of neurons.

A natural question arises as to how adequate is modeling consciousness and its properties (for example, reflection) by means simple neural networks. Experiments with insects showed that the internal representation of the external world and even itself in it is possible even in relatively simple neural structures compared to the human brain [19–24]. These works demonstrated the presence in insects (ants, bees, bumblebees) internal mapping of the external world, as well as their ability to categorize and abstract.

However, modeling the work of even a miniature brain of 1 million neurons (versus 14 billion in humans) is difficult to implement and impossible for analysis. More promising is von Neumann's heuristic model approach [25] which is based on the construction of heuristic models that are not intended for detailed reproduction of the properties of a particular living system, but are focused on the reproduction of the essential characteristics of systems of one kind. The experience of using heuristic neural network models to study the general properties of structural-functional correspondence and the results obtained is described in a number of works [26–29].

Someone may ask: how experiments with small neural networks can contribute to the development of the NCC project? Concerning any scientific approach, questions always arise about the limits of its applicability, its capabilities and limitations.

Working with the key property of consciousness – reflection using extremely simple artificial neural networks, makes it possible to study the methods of the operational internal representation of the external world by a neural network, and what mechanisms ensure the use of this representation when making decisions. In the context of NCC-concept we can test possibility to reconstruct what neural network is doing now on the base of neuron firing pattern.

Following the logic of heuristic modeling, in order to highlight the essence of reflexive processes, it is necessary to study such behaviors that contain the minimal contribution of other cognitive functions - logical reasoning, pattern recognition, memory, etc.

In psychology, there is so-called «Delayed Matching To Sample» (DMTS) test, which can only be passed only if an information system can generate correct internal mapping of outside world and use it for making decisions. This test is used for comparative studies of the cognitive abilities of children and animals, to study the interaction between short-term working and long-term memory, as well as for the diagnosis of Alzheimer's disease, as well as depressive disorders. DMTS allows to unambiguously judge the presence of an internal representation of the external world, sufficient to solve the problem.

So the aim of the paper is to evaluate the possibility of revealing neural correlates of the internal representation of external stimuli during the passing DMTS test by simple neural network.

2. Method and materials

Recurrent neural networks (RNN) with two inputs, two output neurons and different number of internal neurons were used. The RNN output – $y_o^{(t)}$ at a time step t is calculated using the following equations:

$$y_h^{(t)} = f_h\left(W_h \cdot y_h^{(t-1)} + W_i \cdot x^{(t)}\right),$$
$$y_o^{(t)} = f_o\left(W_0 \cdot y_h^{(t)}\right),$$

where W_h, W_i, W_o are the hidden, input and output weight matrices, $x^{(t)}$ is the input vector at time step t, vectors $y_h^{(t)}$ and $y_h^{(t-1)}$ represent the hidden neuron activations at time step t and t-1. Functions $f_h(.)$and $f_o(.)$ are the non-linear activation functions. For simplicity, neuron biases are omitted in the equations.

Activation functions of neurons are:

$$f_h(x) = \frac{1}{2}\left(\frac{x}{a+|x|}+1\right), \quad f_o(x) = \begin{cases} 0, & if\ x \le 0, \\ b \cdot x, & if\ x > 0\ \&\ x < 1, \\ 1. & if\ x \ge 1. \end{cases}$$

Special output neurons with piecewise linear activation function are chosen to provide an accurate 0/1 output signal, and the activation function of hidden neurons is quite traditional.

Neural networks were trained to distinguish in a continuous stream of events matching apairs of stimuli spaced by arrival time. Specifically, one of three randomly selected short-term stimuli – input vectors: A – (01), B – (01) and C – (11) received at the input of the neural network at a random moment in time. Then there was a pause, the duration of which could randomly vary from 3 to 6 clock cycles, and then a second stimulus, also randomly selected, entered. After this, the neural network at the third step after the presentation of the second stimulus produced a single signal on the first output neuron, if these stimuli coincided and a single signal on the second output neuron, if the stimuli did not match. After this, the response cycle was repeated. A fragment of the input signal and the response of the neural network is shown in Fig. 1.

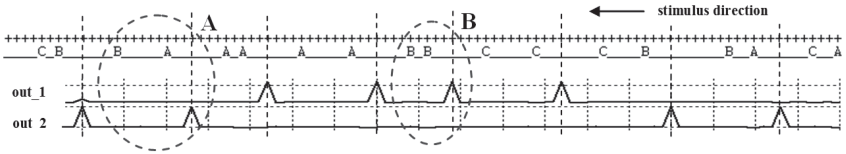

Fig. 1. A fragment of continuously generated sequence of input signals and responses of the neural network. The plus chain at the top displays the quality of matching the objective function. The second line of symbols depicts the flow of stimulus signals entering the neural network input. Out_1 and out_2 lines represent signals taken from the output neurons. The circles with dashed lines mark examples of neural network responses to different (A) and coinciding (B) stimuli

To modify the synapses the back-propagation algorithm was used with the error propagation depth to the past equal to 6 clock cycles. It should be noted right away that for RNN DMTS-test is rather difficult task. The maximum duration of a pause between stimuli, which was achieved with a neural network of 25 neurons, is 6 cycles, and for a neural network of 30 neurons, 8 cycles. We note also that the task was not to find an effective structure or effective options for the learning algorithm – it was important to prove the feasibility of the internal representation of the external world in small RNNs with a simple.

After achieving good training quality a comparative analysis of neuron excitation patterns for various stimuli was performed for several neural networks. Obviously, with these input signals, neuronal firing patterns are determined by the structure of the RNN. However, there is one complication - we are dealing with fully-connected RNNs, where all neurons are equal and not arranged. For definiteness, we assign to neurons numbers when we form matrices of weight coefficients. It means we can have completely identical trained neural networks that perform this function equally well, but there will be no portrait similarity of the weighting matrices. However we can apply special procedure for modifying the synapse matrix that preserves the functioning of the RNN [26-28] at the transposition of neurons. Then we can choose the appropriate criterion to rank the neurons and bring the different RNNs performing the same function to a similar form.

In this work the criterion of total contribution of each neuron to the functioning of a trained RNN was used for ranking. It was determined as follows: 1) the average signal of each neuron was calculated in the course of sufficiently long sequence of signals; 2) the sum of absolute values of outgoing (axon) synapses of each neuron was found; 3) the product of these two quantities for each neuron was found. The neurons of RNN were renumbered according to the rating of their contribution to the RNN operating. This procedure led to a certain ordering of neuronal firing patterns.

3. Results

Since the RNN «makes the decision» on the coincidence of stimuli by comparing the received stimulus with that exist in dynamical (firing) memory, the question on form of this dynamic image of the stimulus is of fundamental importance. Another principal for NCC concept questions are 1) whether the internal representation formed by one neural network coincides with the representation of the same stimulus by another network, and 2) is it possible to determine what stimulus is stored in the neural network using firing pattern.

The answer to the first question can be obtained without experimenting. Earlier it was shown that the structures (expressed in the matrix of weight coefficients) of RNN performing the same function can be transformed into each other using functionally invariant transformations [26-28]. And since a neural network is a deterministic machine this means that the patterns of neuronal excitation, which depend only on the input signals and the structure of the neural network, after the appropriate transformations must coincide in neural networks performing the same function. So it means we can detect similar firing patterns only after finding corresponding functionally invariant transformations of comparing of neural network structures.

The answer to second question seems to be rather trivial – «yes», and this positive answer underlies NCC approach. However computational experiments have shown not everything is so simple. As an example, Fig. 2 shows the firing patterns of one of the RNN in the period of waiting for the second stimulus. The appearance of these patterns was a surprise - there was a feeling that the similarity of the patterns corresponding to the preservation of the image of a given stimulus (from top to bottom in the columns) is less than the similarity of the patterns corresponding to the storage clock cycle (tact) (rows).

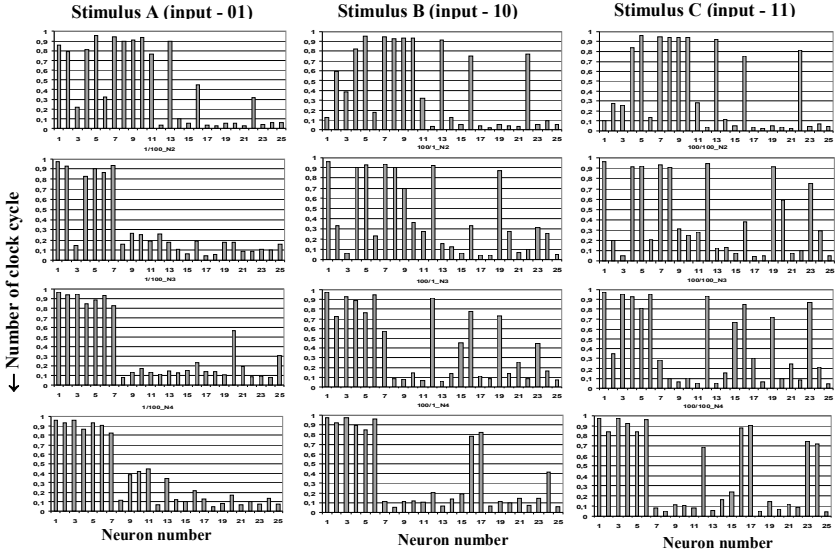

Fig. 2. Neuron firing patterns for different stimuli (from left to right – A, B, C) for different waiting cycles (from top to bottom - from first to fourth)

Corresponding calculations of the average Euclidean distances between the patterns of the same stimulus, but differing by the tact, and the patterns of different stimuli at the corresponding time step showed that indeed, the average distance between the patterns of different stimuli is 18 % less than the average distance between consecutive patterns of the same stimulus.

Here we do not conduct rigorous statistical estimates about the reliability of these differences – it is important to demonstrate the problem of neural correlates detecting even at the level of these extremely simple RNNs. The result does not mean that it is impossible to find these correlates at all; because the RNN itself somehow manages to distinguish firing patterns passes DMTS-test. This means for recognition of these correlates the neural network should also be used, which on the basis of multiple repetitions will learn to compare patterns with «meaning» or «content».

But this opportunity is not very encouraging. Why? The fact is that the patterns of the internal representation of the external stimulus are different for different neural networks, and having trained the RNN to recognize patterns in one experimental neural network, we will not be able to use it to identify «meanings» of firing patterns in other neural networks even performing the same function [33].

For real neural networks interacting with an actively opposing and «tricky» external world the situation seems to be worse (if it is possible). It has shown [18, 31, 32] to win in reflective game RNN must permanently change its synaptic weights, and this will lead to constant change in the dynamic pattern of neuron firing. Therefore it seems hardly possible to build a neural network correlator for recognizing pairs of «firing pattern-sense of action» for neural network of real organism permanently undergoing changes.

4. Conclusion

It is shown a primitive internal representation of an external dynamically changing world can be implemented on recurrent neural networks with a simple homogeneous initial structure. It allows to this kind of neural networks pass the Delayed Matching To Sample test which is used for comparative studies of the cognitive abilities of children and animals.

A comparison of the function performed with the corresponding patterns of neuronal firing showed that the identification of portrait neural reflection correlates for the same neural network is not possible.

This result raises the question of the possibility detecting neural correlates of consciousness associated with specific meaning and content in the brain of humans and higher animals. It seems necessary to work out the technique of detecting neural correlates with model artificial neural networks which are transparent for investigator and everyone can always re-reproduce the desired dynamics and gather any statistical material.

5. Acknowledgments

The reported study was funded by FASIE, project number 138ГРЦТС10-D5/61873.

References

1. Revonsuo A. Consciousness: The Science of Subjectivity. Psychology Press. 2010. 352 p.
2. Crick F., Koch C. Towards a neurobiological theory of consciousness // Seminars in Neuroscience. 1990. Vol. 2. P. 263–275.
3. Crick F., Koch C. A framework for consciousness // Nature Neuroscience. 2003. Vol. 6. No. 2. P. 119–126.
4. Rashevsky N. Mathematical Biophysics: Physico-mathematical Foundations of Biology. Chicago: University of Chicago Press, Chicago. 1938.
5. Dehaene S. Conscious and Nonconscious Processes: Distinct Forms of Evidence Accumulation? // Seminaire Poincare. 2009. Vol. XII. P. 89–114.
6. Dehaene S., Changeux J.P. Experimental and Theoretical Approaches to Conscious Processing // Neuron. 2011. Vol. 70. No. 2. P. 200–227.
7. Kiefer M., Pulvermüller F. Conceptual representations in mind and brain: Theoretical developments, current evidence and future directions // Cortex. 2012. Vol. 48. No. 7. P. 805–825.
8. Min B.K. A thalamic reticular networking model of consciousness // Theoretical Biology and Medical Modelling. 2010. Vol. 7. No. 1. P. 1–18.
9. Mehta N., Mashour G.A. General and specific consciousness: a first-order representationalist approach // Frontiers in Psychology: Consciousness Research. 2013. Vol. 4. P. 407–410.
10. Tononi G., Boly M., Massimini M., Koch C. Integrated information theory: from consciousness to its physical substrate // Nature Reviews: Neuroscience. 2016. Vol. 17. P. 450–461.
11. Lamme V.A.F. Towards a true neural stance on consciousness // Trends in cognitive sciences. 2006. Vol. 10. No. 11. P. 494–501.
12. Seth A.K., Izhikevich E., Reeke G.N., Edelman G.M. Theories and measures of consciousness: An extended framework // PNAS. 2006. Vol. 103. No. 28. P. 10799–10804.
13. Lefebvre V. Reflexion. M.: Kogito-tsentr, 496 p. 2003. (in Russian).
14. Kaplan H.S., Nichols A.L.A., Zimmer M. Sensorimotor integration in Caenorhabditis elegans: a reappraisal towards dynamic and distributed computations // Philosophical Transactions of the Royal Society B: Biological Sciences. 2018. Vol. 373. No. 1758. P. 20170371.
15. Hirayama K., Gillette R. A Neuronal Network Switch for Approach-Avoidance Toggled by Appetitive State // Current Biology. 2003. Vol. 22. P. 118–123.
16. Gillette R., Brown J.W. The Sea Slug, Pleurobranchaea californica: A Signpost Species in the Evolution of Complex Nervous Systems and Behavior // Integrative and Comparative Biology. 2015. Vol. 55. No. 6. P. 1058–1069.

17. Brown J.W. et al. Implementing goal-directed foraging decisions of a simpler nervous system in simulation // Eneuro. 2018. Vol. 5. No. 1.

18. Bartsev S., Markova G. Recurrent and multi-layer neural networks playing «Even-Odd»: reflection against regression // IOP Conf. Ser.: Mater. Sci. Eng. 2020. Vol. 734. No. 1. P. 012109.

19. Alem S. et al. Associative Mechanisms Allow for Social Learning and Cultural Transmission of String Pulling in an Insect // PloS Biology. 2016. Vol. 14. No. 10. P. e1002564.

20. Avarguès-Weber A., Giurfa M. Conceptual learning by miniature brains //Proceedings of the Royal Society B: Biological Sciences. 2013. Vol. 280. No. 1772. P. 20131907.

21. Barrona A.B., Klein C. What insects can tell us about the origins of consciousness // PNAS. 2016. Vol. 113. No. 18. P. 4900–4908.

22. Giurfa M. Behavioral and neural analysis of associative learning in the honeybee: a taste from the magic well //Journal of Comparative Physiology A. 2007. Vol. 193. No. 8. P. 801–824.

23. Howard S.R. et al. Numerical ordering of zero in honey bees // Science. 2018. Vol. 360. No. 6393. P. 1124–1126.

24. Loukola O.J. et al. Bumblebees show cognitive flexibility by improving on an observed complex behavior // Science. 2017. Vol. 355. No. 6327. P. 833–836.

25. Von Neumann J., Burks A.W. Theory of self-reproducing automata // IEEE Transactions on Neural Networks. 1966. Vol. 51. P. 388.

26. Bartsev S.I., Bartseva O.D. Symmetric Structures and Equifinality of Evolution Outcomes in Simple Neural Network Models // Doklady Biochem. and Bioph. 2002. Vol. 386. P. 235–238.

27. Bartsev S.I., Bartseva O.D. Functional Invariant Approach to the Biological System Uniqueness: a Simple Neuronet Model // Doklady Bioch. and Bioph. 2006. Vol. 406. P. 15–18.

28. Bartsev S.I., Bartseva O.D. Heuristic Neural Network Models in Biophysics: Application to the Problem of Structural and Functional Conformity. Krasnoyasrk: Sib. Fed. Univ. 2010. (in Russian)

29. Bartsev S., Baturina P. A heuristic neural network model in the research of properties of evolutionary trajectories // IOP Conf. Ser.: Mater. Sci. Eng. 2019. Vol. 537. No. 4. P. 042001.

30. Camerer C.F., Ho T.H., Chong J.K. A Cognitive Hierarchy Model of Games // The Quarterly Journal of Economics. 2004. Vol. 119. No. 3. P. 861–898.

31. Bartsev S.I., Okhonin V.A. Self-learning neural networks playing «Two coins» // Neurocomputers and attention: Connectionism and neurocomputers. 1991. Vol. 2. P. 453–458.

32. Dolgova T., Bartsev S. Neural networks playing ‘matching pennies’ with each other: reproducibility of game dynamics // IOP Conf. Ser.: Mater. Sci. Eng. 2019. Vol. 537. No. 4. P. 042002.

33. Koch C., Massimini M., Boly M., Tononi G. Neural correlates of consciousness: progress and problems // Nature Reviews Neuroscience. 2016. Vol. 17. P. 307–321.

G.F. MALYKHINA[1], V.Y. SALNIKOV[1], V.B. SEMENYUTIN[2]
[1]St. Petersburg Polytechnic University of Peter the Great, Russia
[2]Almazov National Medical Research Centre, St. Petersburg, Russia
g_f_malychina@mail.ru

NEURAL NETWORK ALGORITHM FOR THE DIAGNOSIS OF IMPAIRED CEREBRAL AUTOREGULATION

A neural network algorithm has been developed to identify in the statistical properties of coherent biological signals present in a mixture with other signals and interference. The algorithm includes real-time determination of the coherence function of signals between fluctuations in systemic blood pressure and blood flow velocities in the left and right middle cerebral arteries and the phase shift function between these signals in the Mayer wavelength range. To reduce the influence of noise, it is proposed to use the technique of a sliding frame, divided into windows. The coherence and phase shift functions obtained in the windows are averaged within the frame boundaries. As a result, smoothed functions can be obtained in the time-frequency domain. To detect infractions of the cerebral autoregulation process, it is proposed to use trained neural feedforward network, which generalizing property can be improved as new experimental data are obtained while maintaining a balance between individual and general characteristics of patients.

Keywords: *Neural network. coherence of signals, diagnostics of cerebral autoregulation.*

1. Introduction

Analysis of the coherence of biological signals in a critical frequency range allows us to solve important problems of medical diagnostics such as determining the physiological state of the body, analysis of thinking processes, diagnosing the circulatory system, and other physiological processes. Among these problems, it is important to continuously monitor the cerebral autoregulation in the clinic for the most rapid detection of emerging disorders. Existing control methods are based on continuous measurement of systemic blood pressure and blood flow velocity in the cerebral arteries [1], but they do not use reliable methods of machine diagnostics that would allow obtaining objective results in real time. Therefore, the aim of the study is to develop a neural network (NN) algorithm for machine diagnostics of cerebral

autoregulation disorders based on time-frequency functions of coherence and phase shift of signals in the Mayer wavelength range.

2. Signal preprocessing

Real-time measurement results are time series. There are many publications devoted to the processing of time series, the closest seems to be publications [2], [3]. Diagnosis of physiological processes must be performed in real time, therefore, the analysis of signals is performed within a frame sliding along the signals [4]. For signals $x(n)$, $y(n)$, $n = 1,..,N_{frame}$, received in a frame of length N_{frame}, it is necessary to select coherent components belonging to a given frequency range (f_1, f_2), to determine the coherence coefficient and phase shift between signals $x(n)$ and $y(n)$ in this frequency range.

The signals $x(n)$ and $y(n)$ are present in a mixture with other signals and with noise, so when calculating their characteristics, smoothing is required. To suppress noise, it is necessary to divide the frame into windows, and determine the average signal characteristics for all windows of this frame. The amount of displacement depends on the type of window. Thus, the rectangular window should be shifted by ½ length, and the Hamming window by ¼ length [6]. The frame offset is chosen equal to the window offset. This allows faster calculations within the frame. The offset of frames and windows is shown in Fig. 1.

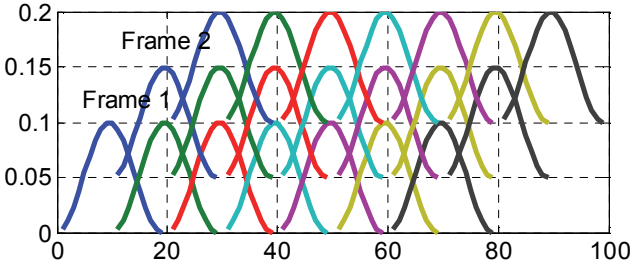

Fig. 1. Offset frames and windows when analyzing signal coherence

When digital processing signals $x(n)$, $y(n)$ inside frames of length N_{frame} are divided by windows of length N_{win}. Windows are shifted by $N_{shift} = \frac{1}{2} N_{win}$, then the number of windows in every frame equals to $L = N_{frame} / N_{shift}$.

The sequence of signal samples is multiplied by the Hann window:

$$\tilde{x}_1(n) = 0.5\left(1-\cos\left(2\pi\frac{n}{N_{win}-1}\right)\right)x(n), \quad n = 1...N_{win}, \tag{1}$$

$$\tilde{y}_1(n) = 0.5\left(1-\cos\left(2\pi\frac{n}{N_{win}-1}\right)\right)y(n), \quad n = 1...N_{win}. \tag{2}$$

For centered sequences: $x(n) = \tilde{x}_1(n) - mean(\tilde{x}_1)$, $y(n) = \tilde{y}_1 - mean(\tilde{y}_1)$, the mutual spectra are calculated by N_{win} - the point Fourier transform of the complex sequence of the sum of signals $x(n) + jy(n)$:

$$Z(k) = \sum_{n=0}^{Nwin-1}\left(x(n) + jy(n)\right)\exp\left(-j\frac{2\pi kn}{N_{win}}\right) \tag{3}$$

and a complex conjugate sequence with the reverse order the N_{win} - point Fourier transform of the complex difference of the signals $x(n) - jy(n)$:

$$Z^*(N_{win}-k) = \sum_{n=0}^{Nwin-1}\left(x(n) - jy(n)\right)\exp\left(-j\frac{2\pi kn}{N_{win}}\right). \tag{4}$$

Fourier transform of signals:

$$X(k) = \frac{Z(k) + Z^*(k)}{2}; \tag{5}$$

$$Y(k) = \frac{Z(k) - Z^*(k)}{2j}. \tag{6}$$

The mutual spectral density $S_{x,y}(k) = X^*(k)Y(k)/N_{win}$, its modulus $\left|S_{x,y}(k)\right|$, and phase $\Theta_{x,y}$ are determined by the formula: $S_{x,y}(k) = \left|S_{x,y}(k)\right|\exp\left(-j\Theta_{x,y}\right)$.

Proper spectral density of signals $x(n)$ and $y(n)$:

$$S_{x,x}(k) = X(k)X^*(k) / N_{win}; \quad (7)$$

$$S_{y,y}(k) = Y(k)Y^*(k) / N_{win}. \quad (8)$$

We repeat the calculations for each shifted position of the window; as a result, we obtain K values of the mutual and intrinsic spectral densities. The frame is characterized by smoothed averaged values of spectral densities obtained for each window inside the frame:

$$\hat{S}_{x,x}(k) = \frac{1}{L}\sum_{l=1}^{L} S_{x,x}(k),\ \hat{S}_{y,y}(k) = \frac{1}{L}\sum_{l=1}^{L} S_{y,y}(k),\ \hat{S}_{x,y}(k) = \frac{1}{L}\sum_{l=1}^{L} S_{x,y}(k). \quad (9)$$

The coherence function is calculated from the smoothed spectral densities for each frame:

$$\gamma_{x,y}(k) = \sqrt{\frac{\left|\hat{S}_{x,y}(k)\right|^2}{\hat{S}_{x,x}(k)\hat{S}_{y,y}(k)}}. \quad (10)$$

The average phase shift $\hat{\Theta}_{x,y}$ between the signals is obtained based on the ratio $\hat{S}_{x,y}(k) = \left|\hat{S}_{x,y}(k)\right|\exp\left(-j\hat{\Theta}_{x,y}\right)$

After calculating the coherence function and phase shift of the signals for all L windows of the current frame, we make the frame shift by the number of samples $N_{shift} = N_{win}/2$. Then the m-frame contains the following signal samples:

$$Frame(m) \to \left(\tilde{x}_1\left(\frac{(m-1)N_{win}}{2}\right)...\tilde{x}_1\left(N_{frane} + \frac{(m-1)N_{win}}{2}\right)\right). \quad (11)$$

We obtain the coherence function and the phase shift for each next frame based on the corresponding values of the previous frame by deleting the values obtained in the first window and adding the values obtained in the last window of the next frame. Then, for each m-th frame, we obtain the coherence function

$\gamma_{x,y}(k,m)$ and the phase shift function $\hat{\Theta}_{x,y}(k,m)$, where k is the number of the sample in frequency domain, and m is the number of the sample in time domain. Resolution in the time domain is $N_{shift} = N_{win}/2$. Therefore, the result of the preprocessing algorithm is a two-dimensional time-frequency function of signal coherence $\gamma_{x,y}(k,m)$ and a two-dimensional time-frequency phase shift function $\hat{\Theta}_{x,y}(k,m)$.

3. Characteristics of cerebral autoregulation

The objective of the study is to diagnose a violation of cerebral autoregulation, which ensures constant blood supply to the brain with changes in systemic blood pressure (BP). The system of cerebral autoregulation damps BP fluctuations in the Mayer wavelength range (M-waves) 0.08–0.12 Hz [6–9], which is manifested by the presence of coherence between BP fluctuations and blood flow velocity (BFV) in the left and right middle cerebral arteries in this range. The measurement of blood flow parameters is an important a separate issue addressed by publications [10, 11].

One of the most informative indicators is the phase shift between the fluctuations of the BP and the BFV in the M-wave range. BFV and BP data were obtained under conditions of forced respiration with a frequency corresponding to the average frequency of M-waves (0.1 Hz) and in conditions of spontaneous respiration that externally affect the cerebral circulation [12, 13, 14]. Thus, performed in real time-frequency cross-analysis of M-waves of BP and BFV in conditions of forced and spontaneous breathing is an adequate non-invasive method for assessing the state of the cerebral circulatory system and can be used to diagnose and predict cerebral autoregulation disorders.

The results of the measurement of BP, BFV in the left and in the right middle cerebral arteries were obtained with an interval of 0.01 s. When processing digital signals BP $y(n)$, $n = 1,...,35000$ and BFV of the left $x_1(n)$, $n = 1,...,38000$ and right $x_2(n)$, $n = 1,...,38000$ arteries, the length of the sliding window is 1024 samples, the overlap is 512 samples. The frame length of 16384 samples includes 32 windows, which reduces the random error of the spectra estimation by approximately 5 times.

Fig. 2 shows the results of calculating the coherence function and phase shift in the M-wave range for forced breathing at one window position.

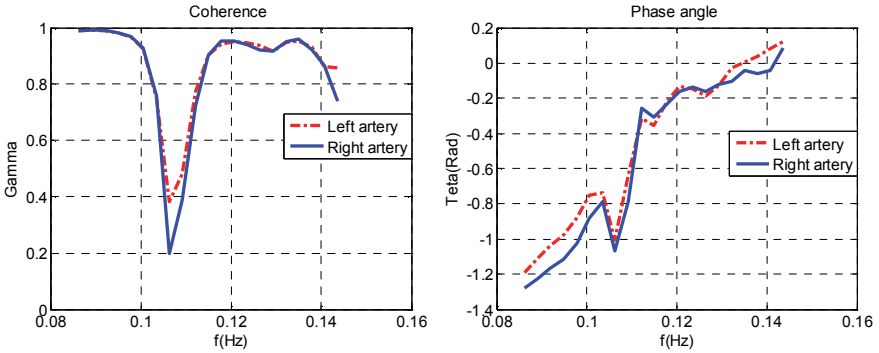

a *b*

Fig. 2. The coherence and phase shift functions between the BP and BFV signals of the left middle cerebral artery and the between BP and BFV of the right middle cerebral artery, calculated within a single window:
a – the coherence function of the BFV and BP;
b – phase shift function of BFV and BP

The result of applying the moving frame algorithm for real-time signal analysis is two-dimensional coherence and phase shift functions, depending on frequency and time. Moreover, the frequency resolution is 0.0028 Hz, the time resolution is 5.12 seconds. Fig. 3 shows an example of the coherence and phase shift functions of the signals in time and frequency.

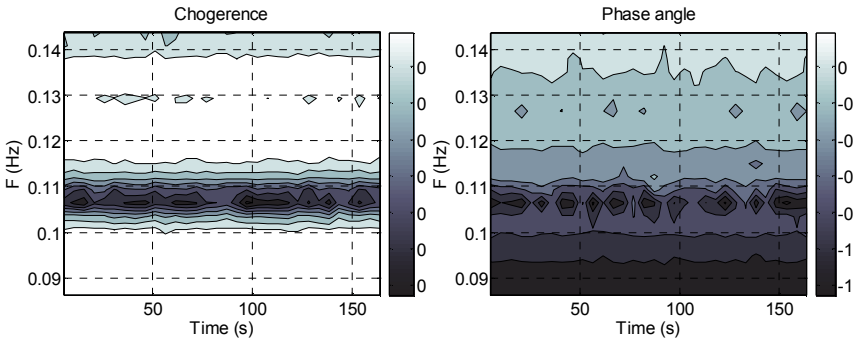

a *b*

Fig. 3. Functions depending on time and frequency:
a – coherence function; *b* – phase shift function

4. Neural network algorithm

To diagnose a violation of cerebral autoregulation, a predicative expression is usually used that determines the relationship between the value of the coherence function of the BFV and BP signals and the phase shift in the M-wave range. In our study, it was proposed to use neural networks. This approach has the following advantages.

- A learning mechanism that makes it possible to tune the algorithm to the individual characteristics of a certain person, or to general characteristics common to all healthy people or groups of people of a certain age, gender, etc. For this purpose, we use for training many sequences of results of measuring BP and BFV for one volunteer or for a group of volunteers.
- Temporal neural networks make it possible to solve the problem of detecting impaired cerebral autoregulation as quickly as possible, which will allow the use of emergency measures to restore abnormalities.
- The ability to perform training in a mixture of various signals and interference present in physiological signals, which are a mixture of signals generated by various processes, pulse waves, Mayer waves, B-waves, temperature noise, instrument noise.
- Implementation of a more complex algorithm for diagnosing cerebral autoregulation disorders.
- Continuous improvement of the algorithm characteristics, the possibility of finer tuning as new experimental data arrives, which can be interpreted as continuous training and the ability of a NN to generalize data that has not been used in training.

Various architectures of classical neural networks [14] of the following types are considered:

- feed forward neural networks;
- temporal feed forward neural networks with input delays, simulating nonlinear moving average (MA) processes,
- recurrent neural networks with feedbacks that simulate nonlinear autoregressive processes (AR),
- nonlinear autoregressive neural networks with exogenous inputs, characterizing nonlinear autoregressive moving average (ARMA) processes.

The choice between the models MA, AR, ARMA is determined by a priori knowledge about the transfer function of the modeled system. In the absence of a priori knowledge, it is necessary to solve the system identification problem. MA models with an increased number of parameters can substitute AR models and vice versa, AR models can substitute MA models. Therefore, in practice, the choice of

the type of neural network that simulates nonlinear processes depends on the volume of the training samples. Often, when solving medical problems, individual models are used for each patient, for which the amount of data is not large.

Modern deep neural networks [15] Long Short-Term Memory (LSTM) can be used to diagnose physiological processes. This network is well suited to solving problems of classification, processing and forecasting of time series. The LSTM network contains recurrent modules capable of storing values for both short and long periods of time. Modules can have three or four gates, which are used to control the flow of information at the inputs and outputs of the memory of these blocks. These gates are implemented as a logistic function, multiplication by which is used to partially admit or deny the current data into and out of memory. The input gate controls the arrival of a new value in the memory, the forget gate controls the storage of the value in the memory, and the output gate controls the flow of values from the memory to the block output. LSTM neural networks adapted to solving problems of classifying specific signals are presented in Matlab and in machine learning libraries.

The use of LSTM neural networks in the problem of diagnosing cerebrovascular accidents is impractical due to the need to estimate an increased number of network parameters based on a relatively small amount of training data.

We have chosen a class of classical temporal NN with input delays, having a relatively small number of weights and not having stability problems.

When solving the problems of analyzing physiological signals, supervised, unsupervised [16], semi-supervised learning methods [17] can be used. We adopted supervised learning method for diagnosis of impaired cerebral autoregulation. Gradient supervised NN training methods have not yielded good results. Therefore, further comparison was made between the conjugate gradient method and quasi-Newtonian methods. Quasi-Newtonian methods, which seek to approximate Newton's method, provided faster convergence than conjugate gradient methods. The computational complexity of the quasi-Newtonian methods $O(W^2)$ is higher than the complexity of the conjugate gradient method $O(W)$. Since the dimension of the vectors W of the weights in our NN is not very large, the conjugate gradient method is not preferable. Quasi-Newton methods are less sensitive to linear search accuracy than the conjugate gradient method. These considerations made it possible to choose the quasi-Newton Broyden–Fletcher–Goldfarb–Shanno algorithm (BFGS) method.

The use of a general model for the regulation of cerebral circulation, which is typical for many volunteers, does not correspond to the modern principle of personalized medicine. Personal data training has limitations in the amount of training data. This determines the choice of the perceptron with input delays and the supervised learning method.

To train the neural network, we used the results of preprocessing the sequence of results of measuring SBP and BFV in the left and right arteries in a narrow M-wave range for unhealthy and healthy volunteers. An example of input data for one of the volunteers is shown in Fig. 3. To improve the training of the neural network, a method of expanding the set of training data by adding random Gaussian noise was used.

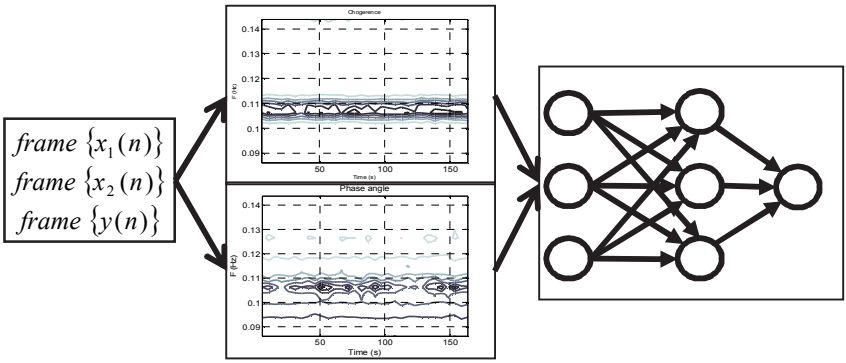

Fig. 4. Neural network structure for diagnosing cerebral autoregulation disorders

The structure of the NN is shown in Fig. 4.

To train the neural network, we used data from two studies obtained for each of five healthy volunteers, and data from two studies for five patients with impaired cerebral autoregulation. The duration of continuous registration ranged from 8 to 12 minutes. The results of the measurement of BP, BFV in the left and in the right middle cerebral arteries were obtained with an interval of 0.01 s. When processing digital signals BP $y(n)$, $n = 1,...,35000$ and BFV of the left $x_1(n)$, $n = 1,...,38000$ and right $x_2(n)$, $n = 1,...,38000$ arteries, the length of the sliding window is 1024 samples, the overlap is 512 samples. The frame length of 16384 samples includes 32 windows. According to the study, preliminary signal processing was performed, the coherence functions and phase shift functions for the BP and BFV signals in the left and right middle cerebral arteries in time were calculated, and the NN was trained. We used the *BFGS* backpropagation *algorithm* for epoch-vise learning with a limit of 300 epochs.

The test results showed that with a sufficient amount of the training sample, which was artificially expanded by adding random Gaussian noise. The probability of correct detection of cerebral autoregulation disorders on average was not less than 0.9.

5. Conclusion

Since the signals of cerebral autoregulation are present in a mixture with other physiological signals and interference, it is advisable to carry out signal processing using sliding frames, which, in turn, are divided into windows sliding along the frame. Averaging the results of processing the signals over the windows made it possible to obtain robust coherence and phase shift estimates with a frequency resolution of 0.0028 Hz and a time resolution of 5.12 s.

The developed algorithm is proposed to be used in the processing of signals of the BP and BFV of the left and right middle cerebral arteries, which characterize the processes of cerebral autoregulation.

To detect violations of the cerebral autoregulation process, it is proposed to use trained temporal feedforward neural network, which generalizing property of can be improved as new experimental data are obtained while maintaining a balance between individual and general characteristics of patients.

Acknowledgments

This research work was supported by project No. 19-29-01190\19 on the topic "Development and application of methods of mathematical analysis of physiological parameters for the operational diagnosis of pathological conditions of patients with an assessment of the risks of their transition to critical conditions in real time proposed by Russian Foundation for Basic Research, and the Academic Excellence Project 5–100 proposed by Peter the Great St. Petersburg Polytechnic University.

References

1. Claassen Ju., Meel-van den Abeelen A., Simpson D., Panerai R. Transfer function analysis of dynamic cerebral autoregulation: A white paper from the International Cerebral Autoregulation Rsearch Network // Journal of Cerebral Blood Flow & Metabolism. 2016. Vol. 36(4). 665–680.

2. Bendat And Piersol – Random Data – Analysis And Measurement Procedures (2-nd ed.), John Wiley & Sons, 1986.

3. Shumway R.H. Applied statistical time series analysis. Englewood Cliffs, NJ: Prentice Hall. 1988.

4. Lin J., Keogh E., Lonardi S., Chiu B. A symbolic representation of time series, with implications for streaming algorithms, Proceedings of the 8th ACM SIGMOD workshop on Research issues in data mining and knowledge discovery. New York: ACM Press. 2003. P. 2–11.

5. Rabiner L.R. and Schafer R.W. Digital Processing of Speech Signals, Prentice-Hall Inc., 2011.

6. Payne.S. Cerebral Autoregulation Control of blood flow in the Brain. XV 125h. Springer, 2016.

7. Czosnyka M., Smielewski P., Piechnik S., Pickard JD. Clinical Significance of Cerebral Autoregulation Acta Neurochir Suppl. ;81:117–9. 2002.

8. Lewis M., Smielewsky P., Rosenfeld J.V., Pickard J.D., Czosnyka M. The correlation between Intracranial Pressure and Cerebral Blood Flow Velocity During ICP Plateau. Waves International Pressure and Brain Monitoring XV. Springer, 2016.

9. Kim JM., Choi JK., Choi M., Ji M., Hwang G., Ko SB., Bae HM. Assessment of cerebral autoregulation using continuous-wave near-infrared spectroscopy during squat-stand maneuvers in subjects with symptoms of orthostatic intolerance, Sciense Report. Sep 5;8(1), 2018.

10. Tgavalekos K., Pham Th., Krishnamurthy N., Sassaroli A., Fantini S. Frequency-resolved analysis of coherent oscillations of local cerebral blood volume, measured with near-infrared spectroscopy, and systemic arterial pressure in healthy human subjects. Department of Biomedical Engineering, Tufts University, Medford, Massachusetts, United States of America PLOS ONE https://doi.org/10.1371/journal.pone.0211710 February 12, 2019.

11. Fantini S., Sassaroli A., Kristen T., Tgavalekos T., Kornbluth J. Cerebral blood flow and autoregulation: current measurement techniques and prospects for noninvasive optical methods. Neurophotonics. Jul; 3(3), 2016.

12. Semenyutin V.B., Panuntsev G.K., Aliev V.A., Patzak A. Cerebral Autoregulation in Perinidal Area of Brain Arteriovenous Malformation. Translational Medicine; 2016. 3(1):89–97. (In Russ.)

13. Semenyutin V.B., Aliev V.A., Bersnev V.P., Patzak A., Panuntsev G.K., Nikiforova A.A., Ramazanov S.S., Pechiborsch D.A., Iblyaminov V.B., Asaturyan G.A., Dudanov I.P., Pavlov O.A. Diagnostic and prognostic potential of non-invasive assessment of cerebral blood flow autoregulation. Regional blood circulation and microcirculation. 2015. 14(1):4-14. (In Russ.)

14. Semenyutin V.B., Asaturyan G.A., Nikiforova A.A., Aliev V.A., Panuntsev G.K., Iblyaminov V.B., Savello A.V., Patzak A. Predictive Value of Dynamic Cerebral Autoregulation Assessment in Surgical Management of Patients with High-Grade Carotid Artery Stenosis. Front. Physiol. 2017.

15. Haykin S. Neural Networks and Learning Machines, 3rd Edition, Prentice Hall, 2009.

16. Goodfellow J., Bengio Y., Courville A. Deep Learning. The MIT Press Cambridge, Massachusetts London, England, 2018.

17. Yakovenko A., Malykhina G. Bio-inspired Approach for Automatic Speaker Clustering Using Auditory Modeling and Self-Organizing Maps, 8th Annual International Conference on Biologically Inspired Cognitive Architectures, BICA, 2017.

18. Yakovenko A., Sidorenko E., Malykhina G. Semi-supervised Classifying of Modelled Auditory Nerve Patterns for Vowel Stimuli with Additive Noise. NEUROINFORMATICS 2018. Studies in Computational Intelligence. Springer, Cham 2018. Vol. 799.

С.А. ПЕРМЯКОВ[1], А.А. КУЗНЕЦОВ[2]
[1]ООО НПФ «Реабилитационные Технологии», Нижний Новгород
[2]Владимирский государственный университет имени А.Г. и Н.Г. Столетовых
permiakov.s@madin.ru

КЛАССИФИКАЦИЯ ФУНКЦИОНАЛЬНЫХ СОСТОЯНИЙ СЕРДЕЧНО-СОСУДИСТОЙ СИСТЕМЫ НА ОСНОВЕ ПАТТЕРНОВ АМПЛИТУДНО-ФАЗОВОГО СОПРЯЖЕНИЯ ЭКГ

Рассматриваются подходы к описанию функциональных состояний сердечно-сосудистой системы человека с помощью динамических паттернов амплитудно-фазового сопряжения электрокардиографического сигнала для выделения информативных признаков отличия и закономерностей работы механизмов регуляции и управления, полезных для анализа результатов диагностических и реабилитационных процедур.

Ключевые слова: *ритм сердца, амплитудно-фазовое сопряжение, регуляция, ЭКГ.*

Введение

Малые обратимые отклонения функционального состояния организма (ФСО) в фазовых переходах от «нормы здоровья» к донозологическому и далее, к преморбидному состоянию относят к малоизученным разделам физиологии человека. Корректное использование исходного понятия «нормы здоровья» возможно при соблюдении стационарности физиологического процесса во времени, что практически возможно даже в условиях системности ФСО [1–6].

Организм человека как полуоткрытая динамическая система в своей иерархии подсистем использует непрямые «мягкие» механизмы управления фазовыми переходами подсистем от одного режима функционирования к другому с сохранением системности. Структурам каждого последующего все более низкого уровня «иерархической лестницы» непрерывно предлагается проходить через динамическую операцию перебора вариантов событий с обязательным и достоверным результирующим выбором. Непрерывность с обязательностью предполагает наличие регулирующих и управляющих биоритмов, а при малых отклонениях от нормы ФСО – еще и контролирующих «нормы здоровья» как наиболее вероятный уровень

ФСО. Определив конкретную иерархическую цепочку системного алгоритма (прошлое и настоящее), может статься вероятностное прогнозирование динамики показателей зависимых биоритмов на основе данных управляющих биоритмов. На практике симптоматическая диагностика и основанные на ней управленческие решения отстают на несколько фазовых шагов от причины – функционального отклонения. Это снижает эффективность прогноза лечебно-диагностического процесса. Диагностика высокоиерархических биоритмов требует иных сложных подходов и в том числе моделирования физиологических моделей синхронизации и десинхронизации биоритмов, и в частности, ритма сердца [7]. Несмотря на современный арсенал математических и технических средств, огромную роль в диагностическом процессе по-прежнему играет наработанная интуиция специалиста. Крайне важно снабдить систему его поддержки всеми возможными не дублирующими информацию данными о функциональном состоянии сердечно-сосудистой системы (ССС) обследуемого.

Цель работы – представление метода амплитудно-фазового сопряжения составляющих электрокардиограммы (ЭКГ) для решения задач поиска физиологических паттернов ФСО условно-здоровых обследуемых.

Постановка задачи

В норме работа ССС находится под контролем симпатического сегмента вегетативной нервной системы (ВНС) с широким интерфейсом внутренних и внешних стимулов, обеспечивающих набор факторов влияний и соответствующих реакций. Деятельность ВНС выражается в вариабельности и ритма сердца, и амплитуд зубцов желудочкового комплекса QRS [1]. Авторы полагают, что поиск взаимосвязей или даже сопряжения RR-интервалов и соответствующих амплитуд R зубца желудочкового комплекса на электрокардиограмме (ЭКГ) позволит судить о формировании электрической структуры кардиосигнала в текущем функциональном контроле состояния ССС.

По принципу частотного кодирования амплитуда воспринятых внешних влияний разной природы трансформируется в частоту электрического генераторного потенциала, а длительность внешних влияний – в длительность генераторного потенциала [8]. Следовательно, о динамике интенсивности внешних стимулов можно судить по вариациям сердечного ритма. Вариабельность сердечного ритма (ВСР) – универсальная оперативная реакция целостного организма в ответ на любое воздействие внешней и внутренней среды с сохранением баланса влияний симпатического и парасимпатического сегментов [1, 8–10]. Однако, остается открытым вопрос об амплитуде генераторного потенциала, и, в частности, о динамике уровня

плато потенциала действия. Малоизученными остаются системные корреляции амплитудной и фазовой составляющей [11–14]. Так для ЭКГ и ритмограмм в теории профилактической и доказательной медицины предложено множество методов анализа [15]. Но для цифрового ряда последовательностей амплитудных значений зубца R, обозначенных авторами как R-грамма [14], и представляющего динамику QRS-комплекса такие методики малочисленны [14–16].

Приоритетным направлением исследования ВСР является анализ медленных (длинных) волн 1-го и 2-го порядков [3, 9] в диапазоне от 0 до 0,015 Гц. Однако, этот же диапазон выделяется и в R-граммах ЭКГ [17]. Принимая во внимание различные биофизические процессы в миокарде, в частности, характеризуемые хроноинотропным эффектом, законом Франка – Старлинга и рядом других, можно сделать вывод о наличии «особых» процессов, обуславливающих корреляционное сопряжение амплитуды R-зубца и фазы кардиоцикла в форме длительности RR-интервала. Можно ожидать, что новый ракурс исследования динамической связи энергетики и ритма позволит по-новому оценить уровень ФСО.

Длинноволновые сопряжения составляющих ЭКГ

В качестве формата исследования медленных волн 2-го порядка авторами предложены диаграммы зависимости систолического потенциала ЭКГ от длительности RR-интервала молодых условно здоровых обследуемых (УЗО). При ортогональном сопряжении длинноволновых составляющих ЭКГ удобен метод «скользящих средних» [14, 17] для R-грамм и ритмограмм с фильтрацией высокочастотных компонент. Принятая ширина окна сканирования n = 400 отсчетов соответствует рекомендуемой стандартной 5-минутной регистрации [9]. Сглаженные параметрические диаграммы (RRs и Rs), полученные с применением скользящего среднего с шагом смещения 1 отсчёт, представляют динамику соответствующих процессов ритмограммы и R-граммы в частотных диапазонах очень низких (VLF) и ультранизких (ULF) частот [9, 10]. Так становится возможным визуализировать амплитудно-фазовое сопряжение ЭКГ-сигнала диаграммой, названной авторами [11, 14, 17] «регуляционной кривой» (рис. 1).

При ортогональном сложении диаграмм процессов в единой системе координат получен образ фигуры Лиссажу с признаком кросскорреляционной функции, т.е. с возможностью выделения временной сдвижки между амплитудной и фазовой составляющими одного сигнала. Если медленная волна захватывает сигнал целиком, то на диаграмме получится регуляционная кривая в форме окружности.

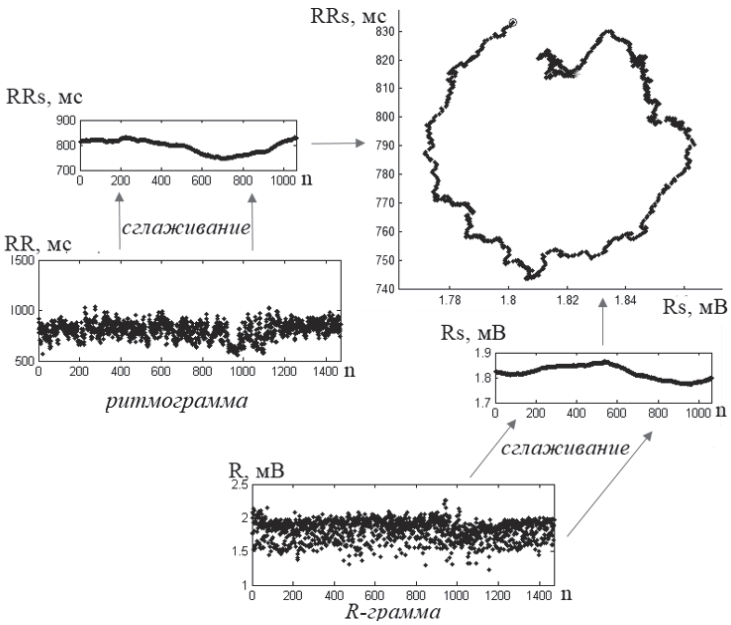

Рис. 1. Формирование диаграммы распределения R(RR)

Замыкание кривой определяет период медленной волны. При относительном запаздывании амплитудной и фазовой составляющих ЭКГ, кривая деформируется, принимая форму эллипса с информационным наклоном, указывающим знак сдвига фазы [18].

Исследование амплитудно-фазового сопряжения УЗО

За период 2008–2018 гг. на базе Владимирского государственного университета им. А.Г. и Н.Г. Столетовых было проведено более 1000 регистраций условно здоровых студентов 2-го курса в двух видах: групповых и серийных. Для исследования было отобрано 504 двадцатиминутных регистраций ЭКГ у 117 условно-здоровых обследуемых, из них 413 групповых и две серии из 30 и 61 регистрация. По результатам расчёта диаграмм RRs(Rs) была предложена первичная классификация (рис. 2).

Разнообразие паттернов в регуляционных кривых здоровых обследуемых свидетельствует о превалировании индивидуальных особенностей сопряжения. Предложенную классификацию следует считать условной, так как наибольшую сложность для анализа представляет класс кривых без формирования устойчивых циклических элементов (рис. 2, в).

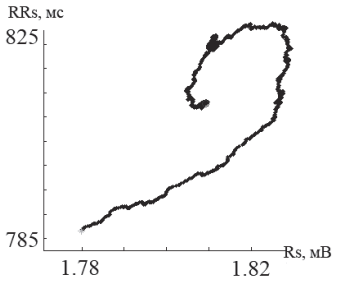

а – замкнутый или полузамкнутый цикл с постоянной закруткой

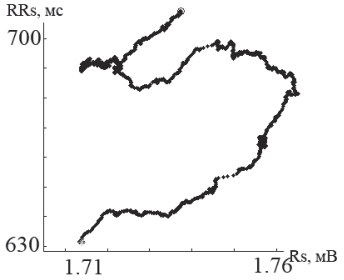

б – замкнутый или полузамкнутый цикл с изменением закрутки

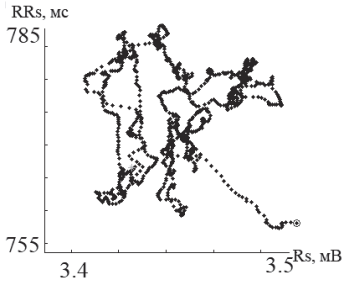

в – кривая без формирования устойчивых циклических элементов

Рис. 2. Виды регуляционных кривых

Кривые, относящиеся к первым двум классам с представительными замкнутыми или полузамкнутыми циклами, составляют приблизительно 60 % от общего числа групповых регистраций и около 80 % в каждой из серий регистраций.

По данным групповых регистраций ЭКГ медленная волна влияния выделяется на большинстве диаграмм в формах одного полного или, что чаще, неполного колебания с индивидуальным ситуативным периодом для разных обследуемых. В среднем выделяемые циклы были замкнуты на 70%

(σ = 15,9 %). Для определения длительности незавершённых циклов использовался метод интерполяции эллиптических элемента.

Распределение длительностей циклов имеет форму логнормального распределения с модой 517 с и средним значением 813,9 с (σ = 312,5 с, вариационный размах = 1582 с). Предпринимались попытки параметрического прогнозирования образования циклических структур с использованием статистических, спектральных и вариационных параметров ВСР и методик анализа многомерных данных, в том числе классификационных деревьев. Точность классификации моделей с использованием различных алгоритмов по критерию «образование цикла – отсутствие образования цикла» не превышала 40 %.

Параметры регуляционной кривой

Для перехода к анализу функциональных паттернов амплитудно-фазового сопряжения необходимо выделить значимые для каждой регуляционной кривой параметры. В качестве примера для анализа выбрана одна из представительных серийных регистраций условно-здорового обследуемого, относящихся к классу кривых с замкнутый или полузамкнутыми циклами и изменениям закрутки (рис. 3).

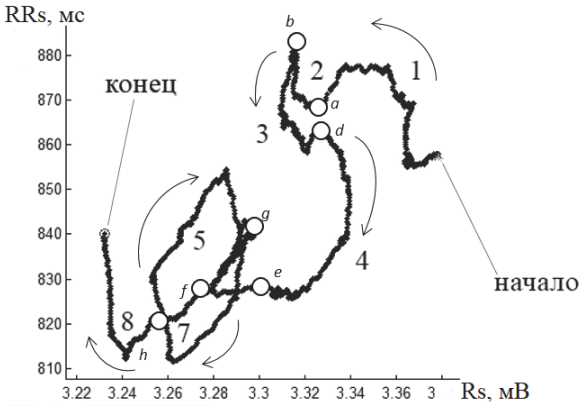

Рис. 3. Регуляционная кривая УЗО в состоянии покоя
с выделенными для анализа этапами и элементами.
Стрелками указаны направления закрутки.
Длительность регистрации 26 мин

Таблица 1

Поэтапный анализ регуляционной кривой УЗО

Этап	*t*, с	Описание
1	338	В начале регистрации формируется цикл с закруткой против часовой стрелки с ростом среднего значения RR на фоне амплитудной регуляции в пределах 0,04 мВ. В точке *a* происходит изменение направления закрутки
2	302	После события изменения закрутки начинает формируется второй незамкнутый цикл, который ограничивается максимальным при максимальном среднем значении RR интервала 885 мс в точке *b*, в которой происходит изменение закрутки
3	389	Незамкнутый цикл на третьем этапе по форме повторяет элемент цикла 2-го этапа по наблюдаемой сдвижке при сопоставимой длительности. В точке *d* происходит изменение закрутки и начало следующего цикла
4	449	Формируется более продолжительный по сравнению с предшественниками цикл. При амплитудной регуляции происходит плавное снижение среднего RR-интервала на 30 мс. Незавершенный цикл к заканчивается в своей низкой точке е выходом на «плато» с постоянным значением RR = 829 мс, длительность «плато» составляет 58 с
5	456	В точке е формируется полный замкнутый цикл по часовой стрелке в рамках амплитудной регуляции 0,05 мВ и изменением среднего значения ритма на 32 мс. Цикл заканчивается возвращением в точку *f*, после которой происходит переход к точке g длительностью 40 с
6	272	В точке *g* начинает формироваться новый незамкнутый цикл с амплитудно-фазовой задержкой сопоставимой с циклом по этапу 5. Закрутка происходит по часовой стрелке, цикл завершается после прохождения своей нижней точки, соответствующей минимальному среднему значению RR-интервала 811 мс при амплитудной регуляции 0,05 мВ
7	298	В точке *h* начинает формироваться цикл с закруткой по часовой стрелке аналогичный циклу по этапу 6 по всем параметрам кроме диапазона амплитудной регуляции, который сдвинут на 0,03 мВ

В рамках анализируемой регистрации (см. рис. 3) зафиксировано 7 циклических этапов, каждый из которых длился от 4,5 до 7,6 мин (табл. 1). Во второй половине регистрации незамкнутые циклы представляли собой монотонную релаксацию RR-интервалов в узких диапазонах амплитудной регуляции 0,04–0,05 мВ. Зафиксировано три события изменения закрутки в первой трети регистрации.

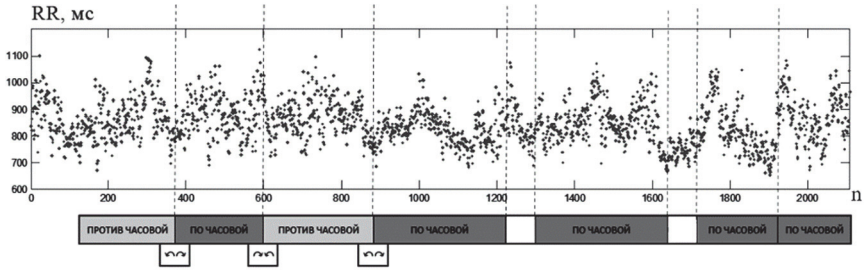

Рис. 4. Разделение ритмограммы обследуемого
по данным анализа регуляционной кривой

Преимущественное направление закрутки циклов – по часовой стрелке. Таким образом при использовании методик оценки вариабельности в течении всей регистрации при использовании стандартного окна регистрации существует вероятность выбрать нестационарный участок регистрации (рис. 4), содержащий переходы между циклами или изменение закрутки, что негативно повлияет на интерпретацию результатов.

Выводы

1. Задержка и вид сопряжения между амплитудным и фазовым компонентами ЭКГ формируют паттерны механизмов регуляции и мягкого управления. Их изменение соответствует режиму поиска оптимальных условий функционирования сердечно-сосудистой системы.

2. С помощью анализа регуляционной кривой текущий уровень ФСО может быть описан набором функциональных паттернов:

- Формирование устойчивого цикла или его элемента. Постоянная временная сдвижка в диапазоне диапазон медленных волн. Устойчивое прогнозируемое состояние.
- Направление закрутки кривой зависимости сглаженных ритмограмм и R-грамм определяет бинарный паттерн взаимосвязи компонент ЭКГ.
- Направление закрутки по часовой стрелке означает режим управления работы сердца, при котором энергетическая составляющая ЭКГ является сопряженной для фазовой. Механизмы регуляции работы сердца подстраиваются по информации внешней среды.
- Направление закрутки цикла против часовой стрелки означает режим управления работы сердца, при котором фазовая составляющая ЭКГ является сопряженной для энергетической. Механизмы регуляции сердца подстраиваются по информации из внутренней среды.

• Смена направления закрутки соответствует торможению регуляции одного из сопрягающих процессов относительно сопрягаемого, для изменения ролей функциональной зависимости между ними.

• Постоянное изменение закрутки без формирования устойчивого цикла соответствует условиям нестационарного режима адаптации сердечно-сосудистой системы с ростом расхода функциональных резервов организма.

Предложен подход выделения новых информативных признаков на основе исследования паттернов амплитудно-фазового сопряжения ЭКГ-сигнала у здоровых обследуемых для диагностического процесса, среди которых длительность цикла, направление закрутки, точка изменения закрутки. Алгоритмы анализа регуляционных кривых в перспективе позволят разработать системы оценки качества лечения пациентов в условиях реанимации.

Программа дальнейших исследований будет включать в себя разработку алгоритмов автоматического анализа регуляционных кривых в режиме мониторинга, исследование фрактальных свойств, а также изучение специфики амплитудно-фазового сопряжения ЭКГ в зависимости от психологического статуса обследуемого.

Список литературы

1. Физиология человека: В 3-х т. Т. 2: Пер. с англ. / Под ред. Р. Шмидта и Г. Тевса. М.: Мир, 1996. 313 с.

2. Инструментальные методы исследования сердечно-сосудистой системы. Справочник / Под ред. Т. С. Виноградовой. М.: Медицина, 1986. 416 с.

3. Баевский Р.М., Берсенева А.П. Введение в донозологическую диагностику. М.: Слово. 2008. 176 с.

4. Кузнецов А. А. Метод оценки вариабельности ритма сердца и его интерпретации при определении функционального состояния организма // Биомедицинская радиоэлектроника. 2011. № 12. С. 11–18.

5. Кузнецов А.А. Определение норм параметрических оценок вариабельности ритма сердца при донозологическом состоянии организма человека // Биомедицинская радиоэлектроника. 2013. № 6. С. 3–12.

6. Кузнецов А.А. Числовой классификатор функционального состояния организма // Измерительная техника. 2013. № 8. С. 58–62.

7. Биологические ритмы. В 2-х т. Т. 1: Пер. с англ. / Под ред. Ю. Ашоффа. М.: Мир, 1984. 414 с.

8. Биофизика: учеб. / Под общ. ред. акад. АН СССР П. Г. Костюка. Киев: Выща шк., 1988. 504 с.

9. Heart rate variability. Standards of measurement, physiological interpretation, and clinical use // European Heart Journal. 1996. V. 17. P. 354–381.

10. Кузнецов А.А. Применение метода оценки вариабельности сердечного ритма в до-нозологической диагностике функционального состояния организма // Измерительная техника. 2010. № 6. С. 50–55.

11. Кузнецов А. А. Структурно-топологический анализ диаграмм электрокардиосигналов // Успехи современной радиоэлектроники. 2010. № 1. С. 27–43.

12. Кузнецов А.А. Связь между временными и структурно-топологическими характеристиками диаграмм ритма сердца здоровых людей // Информатика и ее применения. 2010. Т. 4. Вып. 4. С. 39–48.

13. Кузнецов, А. А. Оценка взаимосвязи амплитудных, фазовых и интегральных характеристик электрокардиограмм здорового человека // Метрология (Измерительная техника). 2011. № 4. С. 36–48.

14. Кузнецов А. А. Системная связь между процессами ритма сердца и динамики систолического потенциала // Информационные технологии. 2011. № 8. С. 69–74.

15. Кузнецов А. А. Информационные технологии донозологической диагностики // Информационные технологии. 2010. № 8. С. 68–73.

16. Кузнецов А.А. Определение количественных характеристик в морфологии комплексов на электрокардиограмме. Интегральный метод анализа // Измерительная техника. 2010. № 9. С. 65–68

17. Кузнецов А.А. Исследование взаимосвязи ритма сердца и динамики амплитудных значений зубца R на электрокардиограмме // Инфокоммуникационные технологии. 2012. Т. 10. № 1. С. 55–60.

18. Пермяков С.А., Кузнецов А.А., Сушкова Л.Т. К анализу циркуляционных кривых ЭКГ здоровых людей // 13-я Международная научная конференция «Физика и радиоэлектроника в медицине и экологии – ФРЭМЭ 2018». Владимир-Суздаль, Россия, Доклады, Кн. 1. С. 158–162

А.Л. ПРОСКУРА, С.О. ВЕЧКАПОВА, А.С. РАТУШНЯК
Федеральный исследовательский центр информационных и вычислительных технологий, Новосибирск
annleop@mail.ru

МОЛЕКУЛЯРНЫЕ МЕХАНИЗМЫ КОНТРОЛЯ ЭФФЕКТИВНОСТИ ВОЗБУЖДАЮЩЕЙ СИНАПТИЧЕСКОЙ ПЕРЕДАЧИ ЛЕПТИНОМ В ГИППОКАМПЕ*

В работе рассматривается задача реконструкции белок-белковых взаимодействий в интерактоме возбуждающих синапсов гиппокампа под контролем гормона лептина. Ряд эффектов этого гормона реализуется через накопление на мембране трифосфоинозитидов, но при этом молекулярные механизмы этих процессов и их включенность в регулирование синаптической пластичности в поле CA1 гиппокампа изучены не полно.

Ключевые слова: *лептин, глутаматные рецепторы, синаптическая пластичность, гиппокамп.*

Введение

В настоящее время общепризнано, что ключевую роль в осуществлении таких процессов как когнитивность, мышление, память играют сенсорные структуры клеток – синапсы. По современным представлениям, глутаматные рецепторы различного субъединичного состава вносят весомый вклад в возбуждающую нейротрансмиссию взрослого мозга [1–3]. Исследование их динамики между компартментами синапса в зависимости от функциональных условий, в том числе воздействия гормонов, является актуальной темой современной нейробиологии.

Гормон лептин вырабатывается клетками белой жировой ткани и участвует в регулировании потребления пищи [4, 5]. Однако в настоящее время появляется все больше данных о прокогнитивной функции этого гормона, его возможной протекторной роли для ряда нейропатологий [6]. Эффекты лептина осуществляются через его рецепторы [7], которые экспрессируются в гиппокампе [8, 9]. В гиппокампе лептин влияет на синаптическую

* В работе использованы материалы, полученные при выполнении базового проекта фундаментальных исследований РАН VI.35.2.6.

пластичность, облегчает формирование пространственной памяти у мышей, а лептинорезистентность коррелирует с нарушениями в поведении и депрессивно-подобными состояниями [10–14].

Вклад лептина в регулирование транскрипции ранних генов и запуск Ras-MAPK сигнального каскада хорошо представлен в литературе [7, 15–17]. Помимо этого лептин вовлечен в сигнальный каскад фосфоинозитид-3 киназы (ФИ3К). Ряд авторов считает, что при этом задействуется часть сигнального пути другого гормона, который синтезируется периферическими тканями, а именно инсулина. Инсулин запускает сигнальный путь ФИ3К, однако его влияние на синаптическую пластичность в гиппокампе отличается и даже противоположно эффектам лептина [18, 19]. В данной работе на основе анализа имеющихся литературных данных проведена реконструкция молекулярных процессов функциональной ассоциации сигналов глутаматных и лептиновых рецепторов на синапсах пирамидных клеток гиппокампа, предложен возможный механизм, обеспечивающий пропотенцирующий эффект лептина на регулирование эффективности синаптической передачи.

1. Модуляция возбуждающей нейротрансмиссии лептином в гиппокампе

Долговременная потенциация (ДВП) или длительное усиление синаптической эффективности является общепринятой клеточной моделью синаптической пластичности *in vitro* [20]. В гиппокампе она контролируется макрокомплексами ионотропных глутаматных рецепторов, в частности, НМДА (N-метил-D-аспартат) и АМПА (α-амино-3-гидрокси-5-метил-4-изоксазолпропионовая кислота) типов. АМПАР с субъединицами GluR2/GluR3 определяют базовую нейротрансмиссию, а АМПАР с GluR1 – ее изменение [21–26].

1.1. Вторичные мессенджеры в регуляторных контурах синапса

Вторичные мессенджеры появляются в ответ на внеклеточные сигнальные агенты, например, гормоны. Фосфоинозитиды (ФИ) выполняют в клетке не структурную, а регуляторную функцию. Примерно по 5 % ФИ от общего количества фосфорилируется только в 4-положении (ФИ(4)Ф) и 4- и 5-положениях (ФИ(4,5)Ф2 или ФИФ2) и менее 0,25 % – в 3-положении (ФИ(3)Ф; ФИ(3,4,5)Ф3 или ФИФ3) [27].

Генерация пула вторичных мессенджеров на плазматической мембране является ключевым событием после индукции ДВП на возбуждающих синапсах гиппокампа и контролируется фосфоинозитид-специфичными киназами и фосфатазами. ФИФ2 запускают процесс клатрин-зависимого эндоцитоза, а ФИФ3 инициируют процессы локального синтеза белка [21, 22, 24, 28–30].

1.2. Сигнальный каскад рецептора лептина

Рецептор лептина (ЛР) относится к I классу семейства цитокиновых рецепторов. После взаимодействия с лептином происходит его ассоциация с Jak2 (Janus kinases), так как ЛР в отличие от рецептора инсулина не обладает собственной тирозинкиназной активностью. Jak2 фосфорилирует несколько тирозиновых остатков в цитоплазматической части ЛР – Y985, Y1077 и Y1138. Фосфорилированные Y1077 и Y1138 взаимодействуют с белками STAT (signal transducer and activator of transcription) – STAT5 и STAT3, обеспечивая запуск транскрипции ранних генов. На фосфорилированном pY985 закрепляется тирозинфосфатаза SHP2 (SH2 (Src-like homology 2) domain-containing protein tyrosine phosphatase), которая совместно с адаптерным белком Grb2 (growth factor receptor binding-2) запускает сигнальный каскад Ras/Raf/MAPK [7].

Показано, что лептин способствует генерации пула ФИ(3,4,5)Ф3, что подавляется блокаторами ФИ3К и не чувствительно к блокаторам MAPK киназ [7, 10, 13, 14]. Считается, что эти эффекты реализуются через белки IRS (Insulin receptor substrate) [7], чему, однако, нет прямых свидетельств. Установлено, что инсулин способствует эндоцитозу АМПАР и развитию долговременной депрессии, что не зависит от активности НМДАР [18]. Преинкубация с лептином, наоборот, способствует развитию зависимой от НМДА рецепторов ДВП и встраиванию в синапсы АМПАР [10, 14].

2. Пересечение регуляторных путей рецепторов НМДА типа и лептина

После индукции ДВП белки макрокомплекса НМДАР обеспечивают процесс выведения из синапсов GluR2/3-АМПАР в течение зависимого от клатрина эндоцитоза и введение GluR1-АМПАР. В базе данных GeneNet (РОСПАТЕНТ № 990006 от 15/02/1999) аккумулирована и структурирована в виде графической диаграммы «AMPA receptors delivery mechanisms in LTP” информация об основных белках, участвующих в процессах изменения и поддержания эффективности синаптической передачи в течение

экспрессии ДВП в поле CA1 гиппокампа [21,22] (http://wwwmgs.bionet.nsc.ru/mgs/gnw/genenet/viewer/AMPA.html). Ключевым при этом является увеличение пула ФИ(4,5)Ф2 под контролем фосфоинозитид-5-киназы (ФИ5К). ФИФ2 служат точками сборки клатринового покрытия эндосом [38], которые также необходимы для эндоцитоза АМПАР и их рециклирования [26]. Сортировку рецепторов и слияние ранних эндосом контролирует Rab5 [39].

В покое в клетке поддерживается низкий уровень ФИ(3,4,5)Ф3 за счет реакции ФИ(3,4,5)Ф3 → ФИ(4,5)Ф2 под контролем фосфатазы PTEN (the phosphatase and tensin homolog deleted on chromosome 10) [31].

Лептин влияет на регулирование плотности синаптических GluR1-АМПАР после зависимой от НМДАР индукции ДВП, что сопровождалось повышением уровня ФИ(3,4,5)Ф3 на плазматической мембране и усилением ингибирующего активность PTEN фосфорилирования [10]. PTEN дезактивируется путем кооперативного фосфорилирования двумя серин-треонин протеинкиназами – казеинкиназой 2 (Casein kinase 2, CK2) и киназой гликогенсинтазы 3 бета (Glycogen synthase kinase 3beta, GSK3beta) - Ser-362 и Thr-366, соответственно [32].

Таким образом, вероятно, в течение развития ДВП в протеоме синапса может возникать пересечение сигнальных путей глутаматных и лептиновых рецепторов через подавление активности фосфатазы PTEN и увеличения пула фосфоинозитолтрифосфатов под контролем ФИ3К.

ФИ3К активируется за счет объединения своей каталитической субъединицы p110 с регуляторной субъединицей p85. При этом домен SH2 (Src homology) в молекуле p85 должен закрепиться на фосфорилированных тирозиновых остатках на строго определенных мотивах **Y**XX**M** в молекулах ряда белков, в частности рецептора инсулина и его субстратах – белках IRS [19]. Сайты взаимодействия с доменами SH2 рецептора лептина отличаются от классического мотива, представленного в рецепторе инсулина и IRS: 985-YATLV, 1077-YLGVT и 1138-YMPQF (для мышиного LepR (P48356), Swiss-Prot). Таким образом, маловероятно прямое взаимодействие ЛР и p85.

GSK3b конститутивно активна в клетках. Подавление активности является основным путем ее регулирования и осуществляется за счет фосфорилирования остатка серина в позиции S9 протеинкиназой B (Akt / ПКВ), что препятствует закреплению субстрата в каталитическом центре, при этом киназная активность GSK3b не блокируется полностью и может восстановиться при увеличении концентрации субстрата [33]. GSK-3β полностью активируется путем фосфорилирования Y216, например, тирозинкиназой Fyn [34].

Fyn относится к семейству нерецепторных киназ Src и экспрессируется в зрелых синапсах. У взрослых мышей с мутациями в гене Fyn наблюдается ослабление синаптической передачи и ухудшение пространственного обучения [35]. Более того, показано, что Fyn задействована в реализации эффектов лептина и вовлечена в регуляцию синаптической пластичности [36,37]. Кроме этого, в базе данных Swiss-Prot указано, что Fyn напрямую взаимодействует с p85, формируя комплекс белков.

Парное выравнивание доменов SH2 с использованием алгоритма Смита-Уотермана (http://www.ebi.ac.uk/Tools/psa/emboss_water/) показало высокий уровень схожести данных доменов между Fyn и белками SHP2 и Grb2 (таблица). Можно сделать предположение, что Fyn, по-видимому, может конкурировать в pY-985 взаимодействиях либо напрямую, либо пристыковываясь к pY-SHP2.

Таблица

Результаты парного выравнивания доменов SH2

	Fyn Identity / similarity, %	**score**
Stat3	36.1 / 55.7	***64.0***
Stat5	24.2 / 47.0	***48.5***
Jak2	27.4 / 46.4	***65.5***
SHP2 1 SH2	34.9 / 54.7	***106.5***
SHP2 1 SH2	37.9 / 53.7	***135.0***
Grb2	38.6 / 60.2	***141.0***

У ФИ(4,5)Ф2 есть два дальнейших пути: распасться на две другие сигнальные молекулы – ФИ(4,5)Ф2 → ДАГ (диацилглицерол) + И(1,4,5)Ф3 (инозитолтрифосфат), либо стать субстратом для генерации фосфоинозитолтрифосфатов – ФИ(4,5)Ф2 → ФИ(3,4,5)Ф3.

Протеинкиназа PKC активно вовлечена в процесс перемещения АМПАР. Для ее активирования необходимы входящие через НМДАР ионы кальция и ДАГ. Активная PKC фосфорилирует сериновые остатки S880 у GluR2-АМПАР, что необходимо для их отсоединения от белков синапса и выведение во внесинаптическую зону, где они будут подвергаться сортировке и погружению в эндосомы. Кроме этого PKC фосфорилирует S818 у GluR1-АМПАР, что необходимо для установления корректных белок-белковых взаимодействий [21, 24].

Таким образом, можно предположить, что активный ЛР, вероятно, может стать площадкой для закрепления не связанной с рецепторами цитоплазматической тирозинкиназы Fyn. Как упоминалось выше, GSK-3β полностью активируется путем фосфорилирования Y216 Fyn [34].

GSK-3β, с одной стороны, может ингибировать Rab5, которая инициирует процесс сортировки АМПА рецепторов в покрытые клатрином везикулы [39], с другой – ингибировать активность PTEN и снижать пул ФИФ2, необходимый для инициации эндоцитоза рецепторов. Лептин/ЛР -> Jak2 -> pY-SHP2 -> Fyn -> Fyn / p85A -> p85 / p100-ФИ3К -> [ФИ(4,5)Ф2 -> ФИ(3,4,5)Ф3]; Лептин / ЛР -> Jak2 -> pY-SHP2 -> Fyn -> pY (216) -GSK3b -> pThr366-PTEN (рис. 1).

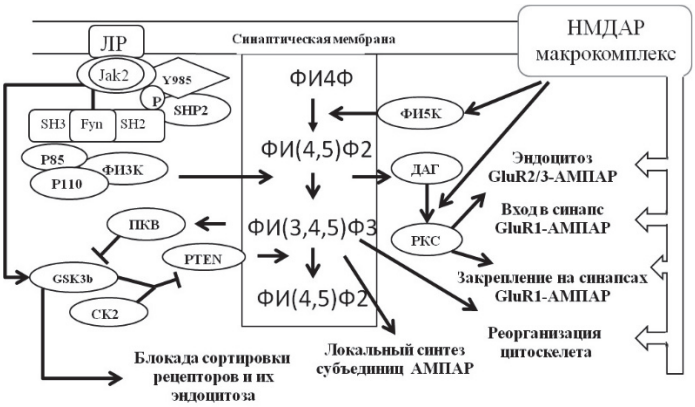

Рис. 1. Схема пересечения сигнальных путей рецепторов НМДАР и лептина: ⊣ – блокирующее влияние; стрелки – активирующее влияние. ЛР – рецептор лептина; НМДАР – НМДА рецептор; АМПАР – АМПА рецепторы; ФИ4Ф – фосфоинозитол-4-монофосфат; ФИ(4,5)Ф2 – фосфоинозитолбифосфат; ФИ(3,4,5)Ф3 – фосфоинозитолтрифосфат; ФИ5К – фосфоинозитол-5-киназа; ФИ3К – фосфоинозитол-3-киназа; ПКВ – протеинкиназа В; РКС – протеинкиназа С; P85/P110 – регуляторная и каталитическая субъединицы ФИ3К; SH2, SH3 – домены белка Fyn; Jak2 – Janus киназа ЛР; Y – тирозиновое окончание; P – фосфатная группа, обеспечивающая взаимодействие с SH2 доменами; PTEN – фосфатаза, антагонист ФИ3К; GSK3b – киназа гликогенсинтазы; СК2 – казеинкиназа 2. Описание в тексте

ФИФ3 необходимы для закрепления протеинкиназы В (ПКВ; Akt), которая является ключевой протеинкиназой, обеспечивающей процессы выживания клетки как через подавление процессов апоптоза, так и запуск син-

теза белка через mTOR сигнальный каскад [40, 41]. mTOR активно вовлечен в процесс запуска локального синтеза различных синаптических белков [30], в частности и субъединиц АМПАР [42].

Таким образом, преинкубация с лептином будет обеспечивать снижение темпа эндоцитоза и усиление локального синтеза субъединиц АМПАР. Стоит отметить, что РКС оказывает влияние на уже введенные в зону синаптического контакта GluR1-АМПАР (что контролируется НМДАР/РКА группой). Как видно на нашей схеме ФИФ3 запускают петлю обратной негативной регуляции эффекта лептина – ингибирование GSK3b протеинкиназой В (см. рис. 1), что, вероятно, может объяснить краткосрочность влияния лептина в экспериментах.

Заключение

Лептин в протеоме дендритного шипика будет способствовать перегруппировке белков с формированием временных комплексов, что может лежать в основе пропотенцирующего эффекта этого гормона на ДВП в гиппокампе. Лептин можно рассматривать как фактор предподготовки интерактома. Появление комплексов с новыми эмерджентными свойствами может быть общим механизмом гормонального контроля на процессы синаптической пластичности. Таким образом, лептин будет, вероятно, способствовать формированию временного функционального объединения сигнальных путей глутаматных и собственных рецепторов.

Список литературы

1. Lu W., Shi Y., Jackson A.C., Bjorgan K., During M.J., Sprengel R., Seeburg P.H., Nicoll R.A. Subunit composition of synaptic AMPA receptors revealed by a single-cell genetic approach // Neuron. 2009. V. 62. № 2. P. 254–268.

2. Hirano T. Visualization of exo- and endocytosis of AMPA receptors during hippocampal synaptic plasticity around postsynaptic-like membrane formed on glass surface // Front. Cell. Neurosci. 2018. V. 12. P. 1–10.

3. Proskura A.L., Ratushnyak A.S., Vechkapova S.O., Zapara T.A. Synapse as a multi-component and multi-level information system // Studies in computational intelligence. 2018. V. 736. P. 186–192.

4. Jéquier E. Leptin signaling, adiposity, and energy balance // Ann N Y Acad Sci. 2002. V. 967. P. 379–88.

5. Myers M.G., Cowley M.A., Münzberg H. Mechanisms of leptin action and leptin resistance // Annu Rev Physiol. 2008. V. 70. P. 537–556.

6. McGregor G, Harvey J. Regulation of Hippocampal Synaptic Function by the Metabolic Hormone, Leptin: Implications for Health and Neurodegenerative Disease // Front Cell Neurosci. 2018. V. 12. P. 340.

7. Frühbeck G. Intracellular signalling pathways activated by leptin // Biochem J. 2006. V. 393. P. 7–20.

8. McGregor G, Harvey J. Leptin Regulation of Synaptic Function at Hippocampal TA-CA1 and SC-CA1 Synapses: Implications for Health and Disease // Neurochem Res. 2019. V. 44. No 3. P. 650–660.

9. Yook J.S., Rakwal R., Shibato J., Takahashi K., Koizumi H., Shima T., Ikemoto M.J., Oharomari L.K., McEwen B.S., Soya H. Leptin in hippocampus mediates benefits of mild exercise by an antioxidant on neurogenesis and memory // Proc Natl Acad Sci U S A. 2019. V. 116. No 22. P. 10988–10993.

10. Moult P.R., Cross A., Santos S.D., Carvalho A.L., Lindsay Y., Connolly C.N., Irving A.J., Leslie N.R., Harvey J. Leptin regulates AMPA receptor trafficking via PTEN inhibition // J Neurosci. 2010. V. 30. P. 4088–4101.

11. Oomura Y., Hori N., Shiraishi T., Fukunaga K., Takeda H., Tsuji M., Matsumiya T., Ishibashi M., Aou S., Li X.L., Kohno D., Uramura K., Sougawa H., Yada T., Wayner M.J., Sasaki K. Leptin facilitates learning and memory performance and enhances hippocampal CA1 long-term potentiation and CaMK II phosphorylation in rats // Peptides. 2006. V. 11. P. 2738–2749.

12. Van Doorn C., Macht VA., Grillo C.A., Reagan L.P. Leptin resistance and hippocampal behavioral deficits // Physiol Behav. 2017. V. 176. P. 207–213.

13. McGregor G., Clements L., Farah A., Irving A.J., Harvey J. Age-dependent regulation of excitatory synaptic transmission at hippocampal temporoammonic-CA1 synapses by leptin // Neurobiol Aging. 2018. V. 69. P. 76–93.

14. Harvey J., Solovyova N., Irving A. Leptin and its role in hippocampal synaptic plasticity // Prog Lipid Res. 2006. V.45. No 5. P. 369–378.

15. O'Malley D., MacDonald N., Mizielinska S., Connolly C.N., Irving A.J., Harvey J. Leptin promotes rapid dynamic changes in hippocampal dendritic morphology // Mol Cell Neurosci. 2007. V. 35. No 4. P. 559–572.

16. Li X.M., Yan H.J., Guo Y.S., Wang D. The role of leptin in central nervous system diseases // Neuroreport. 2016. V. 27. No 5. P. 350–355.

17. Horie T., Park G., Inaba Y., Hashiuchi E., Iezaki T., Tokumura K., Fukasawa K., Yamada T., Hiraiwa M., Kitaguchi Y., Kamada H., Kaneda K., Tanaka T., Inoue H., Hinoi E. MAPK Erk5 in Leptin Receptor–Expressing Neurons Controls Body Weight and Systemic Energy Homeostasis in Female Mice // Endocrinology. 2019. V. 160. No 12. P. 2837–2848.

18. Huang C.C., Lee C.C., Hsu K.S. An investigation into signal transduction mechanisms involved in insulin-induced long-term depression in the CA1 region of the hippocampus // J Neurochem. 2004. V. 89. No 1. P. 217–231.

19. Huang C.C., Lee C.C., Hsu K.S. The role of insulin receptor signaling in synaptic plasticity and cognitive function // Chang Gung Med J. 2010. V. 33. No 2. P. 115–125.

20. Bliss T.V., Collingridge G.L. A synaptic model of memory: long-term potentiation in the hippocampus // Nature. 1993. V. 361. P. 31–39.

21. Проскура А.Л., Малахин И.А., Турнаев И.И., Суслов В.В., Запара Т.А., Ратушняк А.С. Межмолекулярные взаимодействия в функциональных системах нейрона // Вавиловский журнал генетики и селекции. 2013. Т. 17. С. 620–628.

22. Proskura A.L., Ratushnyak A.S., Zapara T.A. The protein-protein interaction networks of dendritic spines in the early phase of long-term Potentiation // J Comput Sci Syst Biol. 2014. V. 7. P. 40–44.

23. Gan Q., Salussolia C.L., Wollmuth L.P. Assembly of AMPA receptors: mechanisms and regulation // J Physiol. 2015. V. 593. No 1. P. 39–48.

24. Newpher T.M., Ehlers M.D. Glutamate receptor dynamics in dendritic microdomains // Neuron. 2008. V. 58. P. 472–497.

25. Tanaka H., Hirano T. Visualization of subunit-specific delivery of glutamate receptors to postsynaptic membrane during hippocampal long-term potentiation. Cell. Rep. 2012. V. 1. P. 291–298.

26. van der Sluijs P., Hoogenraad C.C. New insights in endosomal dynamics and AMPA receptor trafficking. Semin. Cell. Dev. Biol. 2011. V. 22. P. 499–505.

27. Rameh L.E., Cantley L.C. The role of phosphoinositide 3-kinase lipid products in cell function // J Biol Chem. 1999. V. 274. No 13. P. 8347–8350.

28. Traub L.M. Sorting it out: AP-2 and alternate clathrin adaptors in endocytic cargo selection // J Cell Biol. 2003. V. 163. No 2. P. 203–208.

29. Fernández-Monreal M., Sánchez-Castillo C., Esteban J.A. APPL1 gates long-term potentiation through its plekstrin homology domain // J Cell Sci. 2016 V. 129. No 14. P. 2793–2803.

30. Chesnokova E.A., Kolosov P.M. Local Protein Synthesis in Dendrites and its Regulation Normally and During Plastic Changes // Zh Vyssh Nerv Deiat Im I P Pavlova. 2016 V. 66. No 2. P. 163–180.

31. Maehama T., Dixon J.E. The tumor suppressor, PTEN/MMAC1, dephosphorylates the lipid second messenger, phosphatidylinositol 3,4,5-trisphosphate // J Biol Chem. 1998. V. 273. No 22. P. 13375–13378.

32. Al-Khouri A.M., Ma Y., Togo S.H., Williams S., Mustelin T. Cooperative phosphorylation of the tumor suppressor phosphatase and tensin homologue (PTEN) by casein kinases and glycogen synthase kinase 3beta // J Biol Chem. 2005. V. 280. No 42. P. 35195–35202.

33. Beurel E., Grieco S.F., Jope R.S. Glycogen synthase kinase-3 (GSK3): regulation, actions, and diseases // Pharmacol Ther. 2015. V. 148. P. 114–131.

34. Bhat R.V., Shanley J., Correll M.P., Fieles W.E., Keith R.A., Scott C.W., Lee C.M. Regulation and localization of tyrosine216 phosphorylation of glycogen synthase kinase-3beta in cellular and animal models of neuronal degeneration // Proc Natl Acad Sci U S A, V. 97. No 20. P. 11074–11079.

35. Grant S.G., O'Dell T.J., Karl K.A., Stein P.L., Soriano P., Kandel E.R. Impaired long-term potentiation, spatial learning, and hippocampal development in fyn mutant mice // Science, V. 258. No 5090. P. 1903–1910.

36. Brigidi G.S., Santyr B., Shimell J., Jovellar B., Bamji S.X. Activity-regulated trafficking of the palmitoyl-acyl transferase DHHC5 // Nat Commun., V. 6. P. 8200.

37. Bland T., Zhu M., Dillon C., Sahin G.S., Rodriguez-Llamas J.L., Appleyard S.M., Wayman G.A. Leptin Controls Glutamatergic Synaptogenesis and NMDA-Receptor Trafficking via Fyn Kinase Regulation of NR2B // Endocrinology. 2020. V. 161. No 2. pii: bqz030.

38. Krauss M., Kinuta M., Wenk M.R., De Camilli P., Takei K., Haucke V. ARF6 stimulates clathrin/AP-2 recruitment to synaptic membranes by activating phosphatidylinositol phosphate kinase type Igamma // J Cell Biol. 2003. V. 162. No 1. P. 113–124.

39. Wei J, Liu W, Yan Z. Regulation of AMPA receptor trafficking and function by glycogen synthase kinase 3 // J Biol Chem. 2010 V. 285. No 34. P. 26369–26376.

40. Huang J., Manning B.D. A complex interplay between Akt, TSC2 and the two mTOR complexes // Biochem Soc Trans. 2009. V. 37. No Pt 1. P. 217–222.

41. Wang Y.B., Wang J.J., Wang S.H., Liu S.S., Cao J.Y., Li X.M., Qiu S., Luo J.H. Adaptor protein APPL1 couples synaptic NMDA receptor with neuronal prosurvival phosphatidylinositol 3-kinase/Akt pathway // J Neurosci. 2012. V. 32. No 35. P. 11919–11929.

42. Ju W., Morishita W., Tsui J., Gaietta G., Deerinck T.J., Adams S.R., Garner C.C., Tsien R.Y., Ellisman M.H., Malenka R.C. Activity-dependent regulation of dendritic synthesis and trafficking of AMPA receptors // Nat Neurosci. 2004. V. 7. No 3. P. 244–253.

Г.С. ВОРОНКОВ[1], В.А. ИЗОТОВ [2]

[1]Московский государственный университет имени М.В. Ломоносова

[2]Костромской технологический университет, Кострома

av13675@yandex.ru, vlizotov@yandex.ru

НЕЙРОННЫЙ МЕХАНИЗМ КОНСТАНТНОГО ЭКРАНА

Предлагается (для компьютерного моделирования) архитектура нейронных связей в зрительной системе, обеспечивающая стабильность представительства на *константном экране* картины *зрительного пространства*, воспринимаемой сетчаткой глаза, при смещении взора (в условиях фиксированной головы). Описанная базовая нейронная модель обсуждается затем в плане возможности уменьшения её избыточности и упрощения.

Ключевые слова: *стабильность восприятия зрительного пространства, константный экран, архитектура нейронных связей, нейронный механизм константного экрана.*

Введение

Феномен восприятия *зрительного пространства* (ЗП) как константного (стабильного) был описан первоначально в психологических терминах [1]. Предполагаемая структура, ответственная за этот феномен, получила впоследствии наименование *константный экран* (КЭ) [2]. Сравнительно недавно получено нейрофизиологическое подтверждение существования КЭ

[3]. Высказывались представления о возможном общем принципе организации механизма КЭ [4, 3]. Тем не менее, организация нейронного механизма, обеспечивающего основное свойство КЭ – стабильность ЗП-картины на КЭ – до сих пор остается актуальной задачей в физиологии зрения. Также пока не было описано какое-либо *конкретное* **модельное представление** (для построения **компьютерной модели)** о нейронном механизме КЭ. В настоящей статье такое представление предлагается. При этом авторы ставят целью описать, главным образом, принцип работы ключевого механизма нейронной организации в предлагаемой базовой модели, который обеспечивает решение её основной задачи (см. следующий раздел). Основная задача решается в предлагаемом представлении, что называется, «в лоб». Видимо, поэтому базовая модель видится громоздкой (как по сложности связей в её ключевом механизме, так и по числу элементов в ней), с нейрофизиологической точки зрения - малоправдоподобной, а для компьютерного моделирования – трудно вычислимой. В разделе статьи Обсуждение делаются попытки её упрощения. Они состоят в показанной возможности заменить описанный ключевой нейронный механизм базовой модели на альтернативный ему нейронный механизм (без отмены принципиальной основы базового механизма – торможения «лишних» входов к каждому нейрону КЭ), а также в возможности уменьшить количество нейронов в управляющих экранах модели. Тем не менее, эти возможные изменения в базовой модели рассматриваются авторами как не изменяющие её качественным образом; авторы выражают сомнение в возможности существенно усовершенствовать базовую модель.

Краткое описание феномена и формулировка основной задачи.

При смещении взора по *зрительному пространству*[1] (ЗП) при неподвижной голове картина ЗП (или, другими словами, само ЗП и, следовательно, все объекты в нем находящиеся) воспринимается как *стабильная* – при этом смещается только *направление внимания* по ней. «Стабильное» означает, что если голова неподвижна то, как бы мы не смещали взор поворотом глаза, ЗП остается (видится) практически одним и тем же и на одном и том же месте (по отношению к субъекту). Изменение *направления* (смещение) *внимания*[2] по ЗП это, фактически, смещение «проекции» центра сет-

[1] ЗП – это видимое пространство, ограниченное глазницей и носом [5].

[2] Здесь под *направлением внимания* понимается проявление *внимания* (как широко понимаемого феномена) на этом, периферическом уровне зрительной системы.

чатки, точнее, её области наилучшего видения (фовеа), поэтому ЗП. Восприятие ЗП-картины как стабильной требует объяснения. Действительно, поскольку при каждом новом взоре ЗП-картина смещается по системе координат сетчатки, должна смещаться, казалось бы, и ЗП-картина-образ по системам координат ретинотопических экранов центральных структур, ответственных за восприятие ЗП-картины в виде образа, - так как сетчатка проецируется на эти экраны анатомически, жестко. Тем не менее, человек ощущает только смещение внимания по ЗП, тогда как сам образ ЗП (и образ всего находящегося в ЗП) видится ему стабильным. Эта психофизиологическая проблема была, как отмечена во Введении, сформулирована уже Гельмгольцем и остается актуальной до настоящего времени.

Сравнительно недавно получено нейрофизиологическое подтверждение существования в новой коре так называемого *константного экрана* (КЭ), ЗП-картина по которому при смещении взора не смещается [3]. В нейрофизиологических терминах это означает, что каждой данной точке ЗП поставлен в соответствие только один нейрон из множества нейронов, образующих КЭ или, другими словами, каждая точка ЗП представлена только одним, «своим» нейроном в КЭ; и что при любом взоре (то есть, независимо от направления взора) каждый нейрон КЭ получает активность всегда только от одной и той же, «своей» точки ЗП.

Если полагать, что зрительный образ генерируется центральными структурами (что общепринято), то существование КЭ, обладающего свойством воспроизводить смещающуюся по сетчатке ЗП-картину как стабильную, объясняет и стабильность ЗП-картины как образа. Следовательно, в нейрофизиологическом плане, решение данной психофизиологической проблемы – стабильность ЗП-картины как образа - состоит в описании того нейрофизиологического механизма, который обеспечивает описанное выше свойство КЭ. Изучение этого механизма, остается до сих пор актуальной задачей в нейрофизиологии зрения.

Авторы полагают, что составление модельного представления (а затем и построение самой компьютерной модели) о том, как организована нейронная сеть (здесь мы называем её «архитектура нейронных связей», или, «нейронная модель»), обеспечивающая феномен КЭ – представление ЗП-картины стабильной, является важным предваряющим условием для нейрофизиологического исследования этого феномена.

Описание нейронной модели механизма КЭ

Здесь предлагается одна из, видимо, многих *возможных,* нейронных моделей механизма КЭ. В её описании используются термины *наружный и*

внутренний взор (НВ и ВВ), или другими словами – «проекция» сетчатки на ЗП и проекция сетчатки на КЭ, соответственно. На рис. 1 изображена «проекция» центра сетчатки (фовеа) на зрительное пространство (ЗП) для трех наружных взоров (1, 2 и 3). ЗП выделено из зрительного мира толстой линией. При любом взоре ЗП практически полностью проецируется на сетчатку глаза. При смещении взора (при неподвижной голове) «проекция» фовеа смещается по ЗП; при этом в фовеа сетчатки проецируются, соответственно, разные участки ЗП. Принимается, что количество возможных взглядов фиксировано. При каждом таком взгляде каждой точке фовеа (и сетчатки в целом) соответствует «своя», определенная точка ЗП (рис. 2). НВ обеспечиваются активностью фиксированного числа нейронов окуломоторного экрана (ОМЭ). Каждый из нейронов ОМЭ обеспечивает одно из фиксированных направлений взора – активность соответствующих глазных мышц.

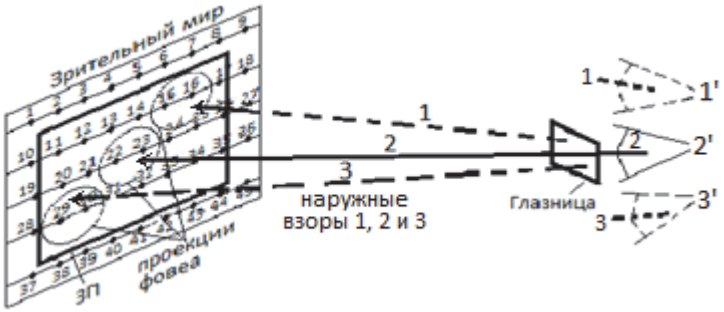

Рис. 1. Проекции «центра» сетчатки (фовеа) на зрительное пространство (ЗП): 1', 2' и 3' – три положения глазного яблока в орбите глаза, обеспечивающие три направления взора, соответственно 1, 2 и 3. Остальное описание в тексте

Чтобы на КЭ картина ЗП сохранялась постоянной (стабильной) при смене взора, необходимо, чтобы направление каждого ВВ на КЭ было «таким же», как направление соответствующего ему НВ на ЗП (рис. 2). Направление ВВ обеспечивается активностью нейронов растормаживающего (разблокирующего) тормозного экрана (РТЭ). Каждый данный нейрон РТЭ обеспечивает только одно (свое) фиксированное направление ВВ. Точки (нейроны) КЭ соответствуют точкам ЗП. Чтобы ЗП-картина сохранялась на КЭ постоянной, необходимо также, чтобы соответствующие друг другу НВ и ВВ смещались одновременно. Одновременную работу пар соответствующих нейронов – один из ОМЭ, другой из РТЭ – обеспечивают нейроны

управляющего обоими взорами экрана (УВЭ). Каждый определенный нейрон УВЭ одновременно активирует разветвлениями своего аксона только одну определенную (одноименную) пару нейронов из ОМЭ и РТЭ (рис. 2).

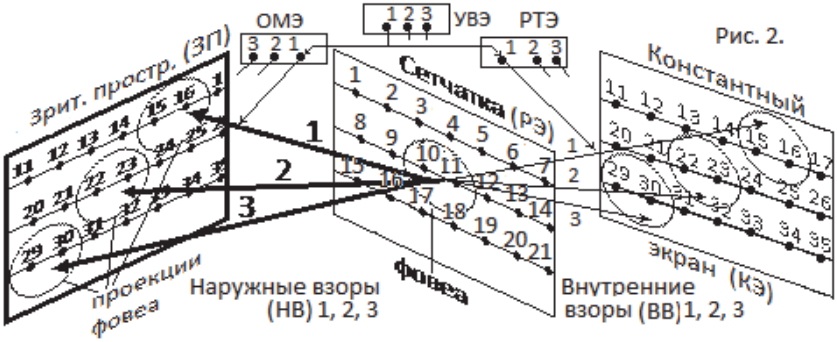

Рис. 2. Проекции наружных (НВ) и внутренних (ВВ) взоров на ЗП и КЭ, соответственно. Обозначения и описание в тексте

Проблемным в этом описании является механизм «смещения» ВВ по КЭ – ибо, в отличие от оптической «проекции» сетчатки на ЗП (НВ), анатомическая проекция сетчатки на КЭ (ВВ) не может смещаться по КЭ, как НВ по ЗП. Суть предлагаемого в данной работе решения, схематически, в следующем.

Как отмечен выше, для каждого НВ имеет место свое фиксированное соответствие между точками ЗП, с одной стороны, и выходными нейронами сетчатки, с другой. Именно, каждый выходной нейрон сетчатки (или *ретинотопического экрана* – РЭ; РЭ связан с сетчаткой топографически) соответствует (при каждом данном НВ) одной определенной, «своей» точке ЗП. Каждый выходной нейрон РЭ проецирует разветвления своего аксона на все нейроны КЭ. Эти активирующие окончания из РЭ непрерывно блокируются тормозными аксонными окончаниями нейронов из общей (для всего КЭ) *тормозной системы* (ТС). Активность к нейронам КЭ пропускается только по **избирательно разблокированным** РЭ-окончаниям. **Разблокирование** осуществляется путем торможения РТЭ-аксонами тормозных ТС-окончаний. **Избирательность** разблокирования обеспечивается за счет того, что аксон каждого данного нейрона РТЭ проецируется только на тот РЭ-вход (из множества РЭ-входов у каждого нейрона КЭ), по которому поступает

(при данном НВ) к данному нейрону КЭ активность от того нейрона РЭ, который получает (при этом НВ) активность от точки ЗП, соответствующей («своей») этому нейрону КЭ. Благодаря такой архитектуре связей между нейронами УВЭ, ОМЭ, РТЭ, ТС, РЭ и КЭ, каждый нейрон КЭ получает активность **при любом НВ** только от одной и той же, «своей» точки ЗП; это и обеспечивает стабильность ЗП-картины на КЭ. Это описание связей нейронов РЭ, РТЭ и ТС с входами к нейронам КЭ иллюстрирует рис. 3. В качестве примера, здесь изображена проекция нейронов 10 и 11 РЭ на нейроны 15 и 16 КЭ. Все входы из РЭ к нейронам 15 и 16 КЭ постоянно блокируются, как и у всех других нейронов КЭ, терминалями аксонов из ТС (темные синапсы). В момент НВ № 1 входы № 15 и № 16 к нейронам КЭ 15 и 16 (соответственно) разблокируются за счет активности от нейрона № 1 РТЭ, разблокирующие терминали аксона которого (проецирующиеся к этим нейронам) подходят именно к входам № 15 и № 16. Таким образом, в момент НВ № 1 к нейронам 15 и 16 КЭ поступает активность соответственно только от точек ЗП № 15 и № 16, соответственно. То есть так же, как если бы проекция точек 10 и 11 РЭ, получающих в момент НВ № 1 активность от точек 15 и 16 ЗП, сместилась на участок КЭ с точками 15 и 16. Очевидно, что при сдвиге взора на другие точки ЗП (например при взоре № X), у нейронов 15 и 16 КЭ окажутся открытыми входы от других нейронов РЭ, а именно, от тех, в которые проецируются при этом новом (№ X) НВ точки ЗП 15 и 16. Эти входы будут открыты благодаря проекции к ним разблокирующих терминалей аксонов от нейрона № X РТЭ, и т.д. То есть, при любом НВ нейроны 15 и 16 КЭ (на рис. 3) всегда получают активность от точек ЗП 15 и 16, соответственно, хотя и опосредуются при этом разными нейронами экрана РЭ.

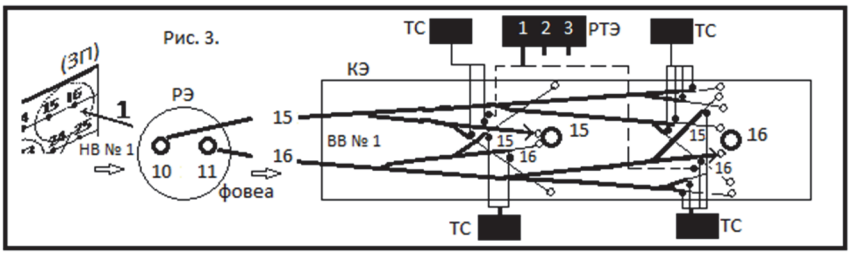

Рис. 3. Избирательное растормаживание блокированных входов из РЭ к нейронам КЭ. Обозначения и описание в тексте

Обсуждение с заключением

Количество элементов в базовой модели. Если принять, что количество выходных нейронов в сетчатке (или, что то же, в РЭ) равно N, то, согласно описанию базовой модели, количество входов (из РЭ) к каждому нейрону КЭ тоже равно N; количество тормозных окончаний (по одному на каждом таком входе) из ТС тогда тоже равно N; количество тормозных окончаний из РТЭ (по одному на каждом тормозном ТС-окончании) также равно N. Таким образом, система входа каждого нейрона КЭ содержит N+ N+ N=3N окончаний. Если каждое окончание образует только один синапс, то непосредственно на одном нейроне КЭ расположено N возбуждающих синапсов; остальные 2N синапсов являются аксо-аксональными, тормозными, они располагаются перед нейроном КЭ. Количество выходных волокон из сетчатки человека равно примерно 2 млн. (т.е., N~2 млн.). За среднее количество синапсов на одном нейроне у млекопитающих принимается обычно число 10 000. Это на два с лишним порядка меньше, чем на нейроне КЭ в базовой модели. Таким образом, учитывая даже только эти расчетные данные, с нейрофизиологической точки зрения, описанная базовая модель КЭ видится малоправдоподобной; сложность ключевого нейронного механизма – избирательный аксо-аксональный тормозной разблокирующий контакт нейрона из РТЭ с ТС-окончанием – тоже не прибавляет ей достоверности.

Можно ли упростить и усовершенствовать базовую модель?

В описанной базовой модели тотальное блокирование и избирательное разблокирование осуществляют две автономные структуры – ТС и РТЭ, соответственно. Альтернативным вариантом могло бы быть совмещение обеих этих функций в одной структуре, в РТЭ. В этом случае торможение **всех** входов (к каждому нейрону КЭ) из РЭ, кроме одного «избранного», осуществлялось бы только **одним** из (каждым из) нейронов РТЭ. «Все входы» это «лишние» входы; «избранный вход» это вход от того нейрона РЭ, к которому поступает, при данном НВ, активность от «своей» (для данного нейрона КЭ) точки ЗП. Таким образом, различие альтернативного и базового ключевых механизмов состоит в том, что альтернативный механизм обеспечивается только одной структурой (РТЭ), тогда как базовый механизм обеспечивается двумя структурами (ТС и РТЭ). В то же время, аксонные ветви нейрона РТЭ, подходящие к каждому нейрону КЭ в альтернативном варианте имеют каждая N-1 количество терминалей (они тормозят все входы из РЭ к данному нейрону КЭ, кроме одного, «избранного» входа), тогда как в базовом варианте имеет место только одна терминаль – терминаль, разблокирующая «избранный» вход из РЭ. Таким образом, в описыва-

емом альтернативном варианте упрощенной является, с нейрофизиологической точки зрения, лишь качественная сторона – пресинаптическое торможение представлено в нем в «обычном» виде; в количественном же аспекте модель при этом практически не изменяется.

Каким должно быть количество нейронов в экранах ОМЭ, РТЭ и УВЭ? Очевидно, что оно равно (в каждом экране) фиксированному количеству возможных сканирующих взглядов по ЗП. Это число не известно. Но, оно не обязательно должно быть равно числу точек в ЗП – действительно, если учесть возможность поворота головы, то каждая из точек ЗП может оказаться в центре взгляда и при сравнительно ограниченном фиксированном числе взглядов, предназначенных для сканирования ЗП.

Тем не менее, с точки зрения авторов, все описанные выше возможные варианты усовершенствования механизма базовой модели КЭ не упрощают её настолько, чтобы считать её правдоподобной. Для последнего требуется либо качественно новый принцип организации самого механизма КЭ, либо какое-то, пока не видимое, сильное упрощение описанного здесь базового механизма. Задача ждет своего решения.

Список литературы

1. Гельмгольц Г. (Helmholtz H., von) О зрении. СПб., 1896, 152 с.

2. Зенкин Г.М., Петров А.П. Преобразования последовательного образа при движениях наблюдателя, константность зрительного поля и непредметные механизмы инвариантности. // Физиология человека, 1976. Т. 2, № 6.С. 925-931.

3. Пигарев И.Н. Нейронные механизмы константности зрительного восприятия пространства. Док. дис. М., МГУ, 1989.

4. Соколов Е.Н. Нейронные механизмы памяти и обучения. М.: Наука, 1981.

5. Логвиненко А.Д. Зрительное восприятие пространства. М.: Изд-во МГУ, 1981.

S.P. KULIKOVA
National Research University Higher School of Economics
SPKulikova@hse.ru

OPTIMIZATION OF THE TMS COIL POSITION BASED ON DIFFUSION TRACTOGRAPHY DATA*

Transcranial magnetic stimulation (TMS) is a powerful diagnostic and therapeutic tool. To get the desired effect, it is necessary to select the optimal position of the stimulation coil. TMS navigation systems allow tracking the coil position with a high precision but they do not suggest the optimal coil position in a particular individual. Finding the optimal coil position experimentally is a laborious procedure. In this work we propose a stochastic region contraction approach to optimize the coil position by maximizing the TMS-induced effect for a target group of the nervous fibers reconstructed from diffusion MRI data.

Keywords: *transcranial magnetic stimulation, diffusion MRI, optimization.*

Introduction

Transcranial magnetic stimulation (TMS) is a powerful diagnostic and therapeutic approach for various neurological and psychiatric conditions [5]. TMS-related effects stem from changes in the cortical neuronal activity, following application of electromagnetic pulses, generated by a stimulation coil. Since TMS-induced changes in the neuronal activity are thought to be rather focal, to get the desired effect, it is necessary to select the optimal position of the stimulation coil.

Existing TMS navigation systems allow to track the position of a simulating coil in real time during TMS sessions with a high precision (< 1 mm). However, such navigation systems only allow precise coil positioning and do not suggest the best coil position for a particular effect in a given subject. Finding the optimal coil position could be performed manually, by probing experimentally multiple stimulations sites. However, to get reliable results, experimental sessions should include many stimulation points, making such a manual approach rather long and laborious. Furthermore, this search procedure should be performed in every subject individually because of individual differences in the brain anatomy [9, 14]. To overcome these limitations, recently an optimization approach, based on modeling of the TMS-induced electric field within brain tissues, has been introduced

* This work was supported by Russian Science Foundation grant 18-75-00034.

[16]. However, the model used there, does not take into account individual differences in the geometry of the stimulated neuronal fibers, which may significantly influence the way, in which the TMS-induced electric field interacts with the neuronal fibers. Indeed, previous experimental studies suggest that, even changing the orientation of the stimulated nervous fibers, relative to the induced electric field, may dramatically affect the observed TMS-induced effects [10]. Thus, when optimizing the TMS coil position, it is also important to take into account individual geometric characteristics of the stimulated fibers.

Existing theoretical models of neuronal excitation by the electromagnetic field [13, 4] suggest that TMS-induced effects should depend not on the absolute magnitude of the induced electric field at the stimulation site, but rather on the co-called effective electrical field, i.e. projection of the induced electrical field E_l within the brain tissues to the local orientation of the stimulated axons. At least three different mechanisms are likely to contribute to the total TMS-induced effect. The first mechanism follows from the cable equation [11] and is related to an electromagnetic induction on the membrane potential V relative to its resting state. The corresponding effect equals to $-\lambda^2 * \partial E/\partial l$(where λ stands for the length constant of the neural membrane and is equal to 2 mm). The second mechanism mainly occurs at sharp bends and fiber termination and its effect is proportional to the magnitude of the effective field $-\lambda E_l$. Finally, the third mechanism may appear at the interface between grey and white matter due to a steep change in conductivity values [7]. However, the effects corresponding to the later mechanism are at least an order of magnitude smaller that from two other mechanisms [4] and therefore, they were not considered further in this study.

In this work, we present an approach for optimization of the TMS coil position, taking into account individual geometric characteristics of the stimulated fibers that were derived from diffusion MRI data. Diffusion MRI is sensitive to diffusion of the water molecules within brain tissues [6]. Within an isotropic medium (for example, in the brain ventricles) water molecules displace in all directions with equal probability. However, in the regions with highly arranged structures, such as nervous fibers, such displacement is restricted to the direction of the local fiber orientation. Thus, by measuring diffusion in multiple directions it is possible to reveal the principal diffusion direction(s) reflecting the local orientations of the fibers passing through each point of the MRI image. These data may then be used to compute the TMS-induced effects, according to the described above theoretical models, and to perform 3D-reconstructions of the white matter fibers for their subsequent visualization.

Here, we applied a stochastic region contraction approach to optimize the TMS coil position, by maximizing the TMS-induced effect computed for a target group of the reconstructed nervous fibers. The detailed description of all used

data and experimental procedures is given below in the section Materials and Methods. The resulting coil position and its comparison to the best position, obtained during an actual experimental TMS mapping, is given in the section Results and Conclusions.

Materials and methods

Experimental data

MRI data was acquired on a 1.5T Siemens scanner and included a structural T1-weighted (T1w) image and a sequence of diffusion-weighted images. T1w image was obtained using an MPRage sequence with a 1mm isotropic spatial resolution. Diffusion-weighted images were acquired with a DW-SE-EPI sequence and the following parameters: 64 diffusion gradient orientations (b = 1500s/mm2), 4 b=0 images, TE = 72ms, TR = 14s, voxel dimensions = = 1 x 1 x 2.5 mm.

TMS mapping data was taken from the study of Novikov et al. [8]. This data was acquired using a Nexstim eXimia stimulator with nTMS-compatible electromyography (EMG) device and a figure-of-eight coil (Focal Bipulse, Nexstim Plc, Finland). Coordinates of the stimulation sites were chosen in a pseudo-random order according to a virtual MRI-based grid. The TMS session consisted of 5 subsessions with each containing 55 stimulation sites. Navigation error for each stimulation site was below 2 mm. Motor Evoked Potentials (MEP) were measured for right hand muscles and MEP amplitudes were calculated automatically using the eXimia software.

Simulation of the TMS-induced electric field

Simulation of the TMS-induced electric field within brain tissues was performed using SimNIBS software [12]. To run simulations, a volume conductor model (VCM) was created from the T1w image, using an mri2mesh algorithm [17]. This algorithm relies on segmenting T1w image into 5 tissue classes, subsequent volume meshing and assigning appropriate conductivity values [14, 15] to each mesh node. The resulting VCM file is imported to SimNIBS to compute the TMS-induced electric fields for a stimulation site. Simulation results are stored in the form of a mesh, with the electric field vector assigned to each mesh node.

Reconstruction of the nervous fibers

Diffusion MRI data was pre-processed with a standard pipeline in Diffusion Toolkit*. A whole-brain tractography and FA maps were computed, according to

* http://www.trackvis.org

a Diffusion Tensor Model [6]. The resulting streamlines were visualized in TrackVis and the target group of motor fibers was extracted by manually placed regions of interest (ROI). Diffusion MRI data were co-registered with TMS-related data using affine transformation, maximizing the mutual information between T1w image and FA maps implemented in DIPY [3].

Calculation of the TMS-induced effects

TMS-induced effects were computed for each point on each fiber from the target group using StimVis, an in-house developed software*, which implements the described above theoretical models of axonal excitation by the electromagnetic field [13, 4]. To calculate the TMS-related effects, it is first necessary to estimate an electric field vector E at each point on each fiber. To do this, for a given point, a tetrahedra, containing that point, is found within the mesh, generated by SimNIBS. Each node of this tetrahedra is associated with the previously computed electric field vector. Then, the electric field vector at the point of interest is obtained by linear interpolation from the nodes of that tetrahedra. Once the electric field is known, it is projected to the local fiber direction l to get the effective field E_l. The directional derivative of the effective field is calculated as a dot product between the gradient of the effective field E_l and the unit vector l, tangent to the fiber: $\partial E/\partial l = grad(E_l) \cdot l$. Finally, the total TMS-induced effect is obtained as a sum of the effects from the two excitation mechanisms:

$$-(\lambda * \partial E/\partial l \ + \lambda^2 E_l \ ).$$

Optimization

Optimization of the coil position was performed using a region contraction approach [1], to maximize the maximal TMS effect over the target fiber group. Optimization was performed in a 4D-space, since we had to optimize 1) the position of the coil center (x, y, z) and 2) orientation of the coil handle in the plane, tangent to the head surface at the stimulation site, coded with an angle $\varphi \in [0, 2\pi]$. The initial search region for the coil center position was restricted by the 2 following conditions: 1) the stimulation site should be outside the head volume and 2) the stimulation site should be closer than 3cm to at least one point on the target fibers. The later condition arises from the fact that TMS fields efficiently penetrate into the brain only to the depth of a couple of centimeters [2]. To make this procedure comparable to the experimental TMS session, we performed 25 contractions selecting each time 10 random stimulation points (totally 250 stim-

* https://github.com/KulikovaSofya/StimVis_TMS

ulation points were considered). Each contraction was based on the 5 best locations from the previous step. To reduce possibility of falling into local minimum, 8 points were selected at each step from the updated search region and the remaining 2 from the initial search region.

Results and conclusions

The resulting stimulation point was approximately 3cm away from the best experimental point and was located outside the region, covered by the actual experimental procedure. The maximal effect at the optimized point was almost twice higher than that for the best experimental locations (Fig. 1).

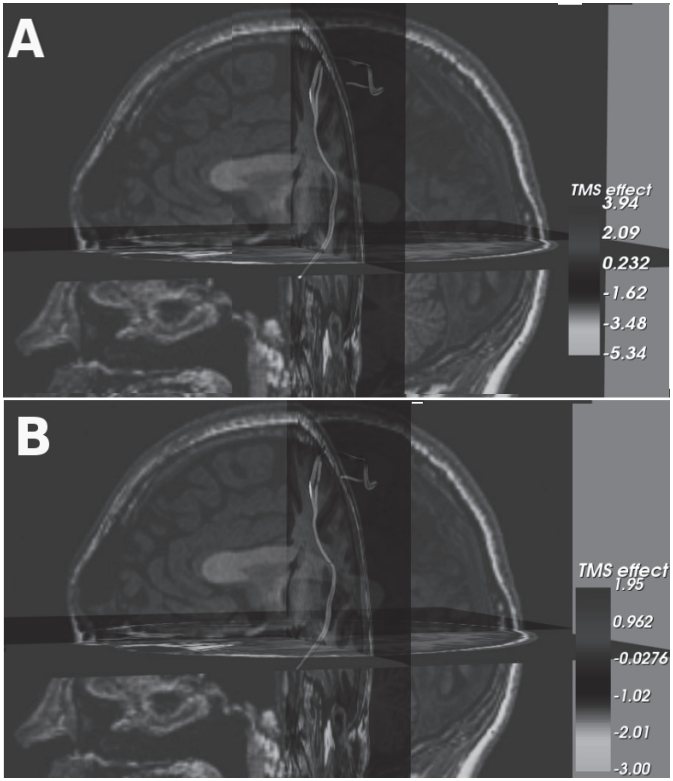

Fig. 1. Effective fields displayed over the target fibers for A. an optimized position of the stimulation coil. B the best position from the experimental session

These preliminary findings suggest that automatic optimization of the TMS coil position may help to improve the TMS efficiency. However, since the optimized point was not in the experimentally covered area, an additional experimental TMS verification is needed to confirm the obtained results and the proposed approach. Future work will include such a verification as well as testing the proposed approach on multiple subjects and different target groups of fibers.

References

1. Berger M.F., Silverman H.F. Microphone array optimization by stochastic region contraction // IEEE Transactions on Signal Processing. 1991. V. 39. No 11. P. 2377–2386.

2. Deng Z.D., Lisanby S.H., Peterchev A.V. Electric field depth-focality tradeoff in transcranial magnetic stimulation: simulation comparison of 50 coil designs // Brain stimulation. 2013. V. 6. No 1. P. 1–13.

3. Garyfallidis E., Brett M., Amirbekian B., Rokem A., van der Walt S., Descoteaux M., Nimmo-Smith I. Dipy, a library for the analysis of diffusion MRI data // Frontiers in Neuroinformatics. 2014.

4. Geeter N.D., Crevecoeur G., Leemans A., Dupré L. Effective electric fields along realistic DTI-based neural trajectories for modelling the stimulation mechanisms of TMS // Physics in Medicine and Biology. 2014. V. 60. No 2. P. 453–471.

5. Iglesias A. Transcranial Magnetic Stimulation as Treatment in Multiple Neurologic Conditions // Curr. Neurol. Neurosci. Rep. 2020. V. 1. No 20.

6. Le Bihan D., Mangin J.F., Poupon C., Clark C.A., Pappata S., Molko N., Chabriat H. Diffusion tensor imaging: Concepts and applications // Journal of Magnetic Resonance Imaging. 2001. V. 13. No 4. P. 534–546.

7. Miranda P.C., Correia L., Salvador R., Basser P.J. Tissue heterogeneity as a mechanism for localized neural stimulation by applied electric fields // Physics in Medicine and Biology. 2007. V. 52. No 18. P. 5603–5617.

8. Novikov P., Nazarova M., Nikulin V. Tmsmap – software for quantitative analysis of tms mapping results // Frontiers in human neuroscience. 2018. V. 12. No 239.

9. Opitz A., Windhoff M., Heidemann R.M., Turner R., Thielscher A. How the brain tissue shapes the electric field induced by transcranial magnetic stimulation // NeuroImage. 2011. V. 58. No 3. P. 849 – 859.

10. Richter L., Neumann G., Oung S., Schweikard A., Trillenberg P. Optimal Coil Orientation for Transcranial Magnetic Stimulation // PLoS ONE. 2013. V. 8. No 4.

11. Roth B.J., Basser P.J. A model of the stimulation of a nerve fiber by electromagnetic induction // IEEE Transactions on Biomedical Engineering. 1990. V. 37. No 6. P. 588–597.

12. Saturnino G.B., Madsen K.H., Thielscher A. Electric field simulations for transcranial brain stimulation using FEM: an efficient implementation and error analysis // Journal of neural engineering. 2019. V. 16. No 6.

13. Silva S., Basser P.J., Miranda P.C. Elucidating the mechanisms and loci of neuronal excitation by transcranial magnetic stimulation using a finite element model of a cortical sulcus // Clinical Neurophysiology. 2008. V. 119. No 10. P. 2405–2413.

14. Thielscher A., Opitz A., Windhoff M. Impact of the gyral geometry on the electric field induced by transcranial magnetic stimulation // NeuroImage. 2011. V. 54. No 1. P. 234 – 243.

15. Wagner T.A., Zahn M., Grodzinsky A.J., Pascual-Leone A. Three-dimensional head model simulation of transcranial magnetic stimulation // IEEE Transactions on Biomedical Engineering. 2004. V. 51. No 9. P. 1586–1598.

16. Weise K., Numssen O., Thielscher A., Hartwigsen G., Knsche T.R. A novel approach to localize cortical tms effects // NeuroImage. 2020. V. 209

17. Windhoff M., Opitz A., Thielscher A. Electric field calculations in brain stimulation based on finite elements: An optimized processing pipeline for the generation and usage of accurate individual head models // Human Brain Mapping. 2013. V. 34. No 4. P. 923–935.

Секция 3

Теория нейронных сетей

V.N. SHATS
Independent researcher, St. Petersburg
vlshats@hotmail.com

TWO SIMPLE CLASSIFICATION ALGORITHMS BASED ON INFORMATION GRANULATION

This paper proposes two classification algorithms for solving problems containing only quantitative or categorical features, proceeding from the assumption that the object classes are different probability distributions of individual features. The estimation of the density of these distributions is implemented by breaking down every sample feature into a set of information granules, consisting of objects that form random sequences of nearest neighbors by the value of the same feature. For the case of categorical attributes, it is proposed to use a matrix of pairwise feature frequencies.

Keywords: *classification algorithms, information granulation, sequences of the nearest neighbors, invariant matrices.*

1. Introduction

The classification problem is reduced to calculating a decision function that allows dividing a training sample (TRS) into classes while simultaneously obtaining acceptable classification accuracy for a test sample (TS). Most existing methods are used to calculate these algorithm functions with significant computational complexity [1–3]. New algorithms based on the new information granulation method (IGM) [4–5] are distinguished by their approach and simplicity. According to the method, the sample is broken into a set of feature granules, which consist of objects whose feature value falls into the intervals that breaks down the sample span of the feature into equal parts.

As was shown [6], the IGM corresponds to the sensory process models of animals, which aim to recognize an object's class by searching for a prototype in the information accumulated in the brain. Construction of calculation functions was based on the biologically inspired concept of soft calculations by L. Zadeh: the brain selects only the information that is needed to solve a particular problem and which «with a minimum degree of accuracy» corresponds to the source information [7].

In the case of quantitative features, the following calculation scheme is proposed. Each feature of the conjoint sample receives an additive random component having a uniform distribution, the density of which may differ for TRS and TS. The value range of each feature is divided into intervals of equal length, the number of which is one of the design parameters, and the sequence number serves as an index. Based on the k-nearest neighbors method, it is assumed that the objects forming the granule have close properties.

Then we can calculate the frequencies for all the granule objects in each class and establish a correspondence between the indices and granule frequencies for any class. The estimation of the object frequency in each class depends on the combination of index values of its features and is equal to the average frequency of appropriate granules. The object class is estimated using the maximum likelihood principle.

For categorical data, the role of indices plays themselves feature values, described by a sequence of integers. To reduce the influence of the increased information load on these data, in the decision function, instead of the frequencies of feature indices, pairwise feature frequencies that roughly approximate the conditional probability of features are used. In those cases where TRS has no objects with the same combination of feature values in TS, an object receives a class for which the total number of nearest neighbor objects TRS for each characteristic will be maximized.

Note that both algorithms actually take into account the relationship of objects features of the same class when implementing the assumption of independence of features, and not just the frequency of individual features. In particular, Algorithm 1 additionally introduces four parameters, and Algorithm 2 uses matrices of pairwise feature frequencies. Therefore, the effect of overfitting is unlikely.

The paper is organized as follows. Section 2 describes the formulation of the problem and its solution for quantitative features. Section 3 considers the same problem but for categorical features. Section 4 is devoted to assessing the effectiveness algorithms for seven databases. Section 5 presents a conclusion.

2. Statement and solution of the problem in Algorithm 1

Let the vectors X_k, $k \in (1, N)$ describe the values of the features, which form the TRS $\{(\boldsymbol{X}_s, y_s) | s \in (1, M)\}$, where $y \in (1, C)$ – is a set of class numbers, and M, N and C are the quantities of objects, features, and classes, respectively. All features are quantitative. The problem is to classify the TS objects.

The problem concerns real objects, somehow divided into classes, and objects $\boldsymbol{x}_s = (x_{s1}, \dots, x_{sN})^T$ are only rough patterns of real objects. Obviously, the information contained in the set $\mathbf{X}$ could be represented by another data matrix TRS.

Therefore, the given data matrix $\boldsymbol{Q}$ is one of the random realizations of the virtual set of data matrices, which can be considered invariants of the matrix $\boldsymbol{Q}$ with respect to the object class. Furthermore, instead of the matrix $\boldsymbol{Q}$, we use its invariant $\widetilde{\boldsymbol{Q}}$, which has greater informational entropy due to an increase in the variability of the feature values and a corresponding decrease in the uncertainty level of our knowledge about the object properties of individual classes. Let the transformation of features $\tilde{x}_{sk} = x_{sk} + \alpha v_s$ for all k and s lead to the map $\boldsymbol{Q} \to \widetilde{\boldsymbol{Q}}$, where v is a random variable uniformly distributed on the interval $[0,1], and$ $\alpha \geq 0$ is a constant.

Assume that the region of feature values for objects TRS in feature space is a multidimensional parallelepiped limited by $\tilde{x}_k^{max}$ and $\tilde{x}_k^{min}$, the maximum and minimum value $\tilde{x}_{sk}$, respectively. We divide this region into Mk-dimensional parallelepipeds with an edge length in each feature equal to $\Delta_k = (\tilde{x}_k^{max} - \tilde{x}_k^{max})/(n-1)$, where $n > 1$ is an integer parameter.

Let us assign the interval boundaries of numbers $1,2, \dots, n$. We consider an object s has an index m by the feature k if the integer part of the value $\tilde{x}_{sk}/\Delta_k$ is equal to m since in this case, the value of this feature falls within the interval $[m, m+1)$. Then the index vector $\boldsymbol{d}_s = (d_{s1}, \dots, d_{sN})^T$ will uniquely describe the object $\widetilde{\boldsymbol{x}}_s = (\tilde{x}_{s1}, \dots, \tilde{x}_{sN})^T$.

In the general case, each value of n corresponds to its own composition of granules. With an increase in n, step Δ_k and respectively the maximum distance between the values of granule features are decreased. According to the "k-nearest neighbors" method, it is assumed that the objects forming the information granule (k, m) have close properties. Note that, in essence, we are dealing with random sequences of nearest neighbors, since the composition of granules randomly depends on the parameters n and α.

Denote by ω_i the object lists of class i. Now, we can find granules for each class and calculate the corresponding indices matrix $\boldsymbol{D}^i = \|d_{sk}\|_{l_i \times N}$, where $l_i = |\omega_i|$. Its elements are granules (k, j), whose objects have the index $d_k = j \in (1, n), k \in (1, N)$. Their frequencies are calculated by the obvious ratio

$$(f_{kj})_i = \frac{|(k,j)|}{l_i}. \qquad (1)$$

Formula (1) gives a probability estimate of any object in granule (k, j).

Let us now turn to the TS. Note that the TRS and TS belong to a single general population and, therefore, the frequencies of these sample objects are equal in the case of equal values of their attributes.

To determine the frequency of TS indices, we use the following approach, which implements the compactness hypothesis. For each feature k of the object s, we find θ values $(\tilde{x}_{sk})_j = x_{sk} + \beta w_j$, where w is a random variable uniformly

distributed on the interval $\left(-\frac{\beta}{2},\frac{\beta}{2}\right), \beta \geq 0$ is a constant, $j \in (1,\theta)$. Then calculate the indices $m_1,\cdots,m_\theta$ of values $(\tilde{x}_{sk})_j$ and for each of them determine the frequencies $f_{km_1},\cdots,f_{km_\theta}$ in a certain class, the mean of which will be the frequency feature k of the object s of this class.

Arbitrary object s of any class is uniquely determined by the index vector $\boldsymbol{d_s}$. Since the occurrence of a certain index for each feature forms a complete group of incompatible events, according to the formula of total probability, an estimate of the probability that the object belongs to the class i is obtained:

$$p_i(\boldsymbol{d_s}) = \frac{1}{N}\sum_{k=1}^{M}(f_{kj})_i, \quad (2)$$

where j is the index of feature k for object s. Formulas (1) and (2) give probability estimates for objects TRS and TS. According to the maximum likelihood principle, the estimated value of the class object s is:

$$I(\boldsymbol{d_s}) = \arg max_{i\in(1,C)}\, p_i(\boldsymbol{d_s}). \quad (3)$$

3. Peculiarities of Algorithm 2

For categorical features, granulation can be performed by using feature values as indices, described as a sequence of integers. Naturally, Algorithm 2 uses the results obtained in Algorithm 1 without resorting to the granulating data. In Algorithm 2, between the feature values and indices, the deterministic relationship is set; therefore, the IGM efficiency is reduced.

In the present work, we propose the following method for increasing its categorical feature accuracy, based on the fact that the set of their values often has a relatively low length. Note that the probability appearance of object $\boldsymbol{x} = (x_1,\dots,x_N)^T$ of class i is equal

$$P(\boldsymbol{x}) = p_1(x_1)\, p_2(x_2|x_1)\ \dots p_N(x_N|x_1,\dots,x_{N-1}).$$

To estimate specified conditional probabilities, consider the Cartesian product of feature vectors and X_k и X_{k+1}, $k \in (1, N-1)$. Its elements are ordered pairs (x_k, x_{k+1}), where $x_k \in \{1, n_k\}$, $x_{k+1} \in \{1, n_{k+1}\}$, n_k, n_{k+1} are the value numbers of attributes k and $k+1$, respectively. Let $e^i_{k,k+1} \geq 0$ be the object numbers of class i whose features correspond to a pair (x_k, x_{k+1}). The frequency of this pair $g^i_{k,k+1} = e^i_{k,k+1}/l_i$ gives a sample estimate of its probability. The totality of these frequencies forms a matrix of pairwise frequencies (MPF) for features k and k + 1 of the objects TRS of class i: $R^i_{k,k+1}$ =approximate dependence for estimating the probability of an object x in class i

$$P^i(\boldsymbol{x}) = g^i_{x_1,x_1} g^i_{x_1,x_2} g^i_{x_2,x_3} \dots g^i_{x_{N-1},x_N}. \quad (4)$$

The estimated value of this object class is defined by an analog of formula (3):

$$\tilde{I}(\boldsymbol{x}) = \arg max_{i\in(1,C)} P^i(\boldsymbol{x}). \quad (5)$$

Sometimes, formula (5) does not allow us to determine the class of an object $\boldsymbol{x}$, since $\tilde{I}(\boldsymbol{x}) = 0$. The class of such objects can be clarified using the idea of the k-nearest neighbors method. We assume that the «indefinite» object has a class to which most of the k-nearest OB objects belong. Since the concept of the distance between objects in the MI is not defined, first the «proximity» is evaluated for each feature value of the «indefinite» object.

Let Z be the set of TS objects $\boldsymbol{z} = (z_1, \dots, z_N)^T$ whose class could not be determined using formula (5). The objects OB of class i, located in the h – vicinity z_k, form a set of $V_k = \{t \| x_{tk} - z_k| \le h, t \in \omega_i\}$. The frequency of feature k of object z in class i is equal to $|V_k|/|\omega_i|$. Then the average frequency of the object for all features is equal to $T_i(\boldsymbol{z}, h) = \frac{1}{n}\sum_{k=1}^{N} |V_k|/|\omega_i|$. Therefore, the class of the object $\boldsymbol{z}$ can be estimated by the formula

$$I(\boldsymbol{z}, h) = max_{i\in(1,C)} T_i(z, h). \quad (6)$$

Here, h is a parameter, the domain of which is the set of integers $\{1, \dots, \tilde{n}\}$, where $\tilde{n} = \min(n_k)$. Let $\mathbf{1}_i(\boldsymbol{z}, h)$ be an indicator of the class i, equal to 1 if the calculated class is not equal to the class of object z, and 0 in another case. Then the number of incorrectly classified objects on the set Z will be equal to

$$F(h) = \sum_{\boldsymbol{z}\in Z} \mathbf{1}_i(\boldsymbol{z}, h). \quad (7)$$

The calculated value of the parameter h, denoted by $\tilde{h}$, and the corresponding value of $I(\boldsymbol{z}, \tilde{h})$ is found from the condition for a minimum of the number of «undefined» objects:

$$\tilde{h} = F(h) \to min_{h\in(1,\tilde{n})}. \quad (8)$$

Algorithm 2 leads the solution to the problem of calculations by groups of formulas (3–4) and (4–8).

4. Effectiveness of algorithms

The effectiveness of the algorithms was studied with seven databases from the UCI repository [8]. The characteristics of the bases given in Table 1 cover rather wide ranges of values for the numbers of objects (267–20,000), features (3–22) and classes (2–26). All calculations were performed for 10 variants of

dividing the conjoint sample into OB and TV based on the 10-fold cross-validation procedure. In the course of the experiments, the calculation parameters of Algorithm 1 were adjusted: for each base, one of the possible combinations of parameter values was determined, which provides an acceptable level of accuracy for all options. The data in Table 1 correspond to the following parameters: for the Iris base $n = 600, \alpha = 0.1, \beta = 0.1, \theta = 10$, для базы Wine $n = 10, \alpha = 0, \beta = 0.1, \theta = 3$. The table contains the mean values E and standard deviation St for the error rate obtained for TRS and TS.

Table 1

Database characteristics and calculation results

Dataset	M	N	C	TS		TSR	
				E	St	E	St
Iris	150	4	3	0.016	0	0	0
Wine	178	13	3	0.012	0.001	0.002	0
Breast Cancer	699	9	2	0.175	0.051	0.016	0.023
Car evaluation	1728	6	4	0.076	0.015	0.069	0.003
Haberman's Survival	306	3	2	0.238	0.087	0.07	0.058
Letter Image Recogni-	20000	16	26	0.186	0.019	0.097	0.002
Spect	267	22	2	0.237	0.075	0.224	0.013

The table shows that for the considered database, Algorithm 1 provides an almost zero error. Algorithm 2 leads to less accurate results, as the average error rate minimum values for TS and TRS are 0.076 and 0.016, respectively. However, for TS, the results are quite stable since $St/E < 0.4$.

The functions $F(\square)$ were used for the Breast Cancer, Haberman's Survival and Letter Image databases, where «undefined» objects appeared. Calculations have shown that the introduction of these features can lead to a significant increase in the accuracy of decisions.

It can be assumed that the efficiency of both algorithms was confirmed experimentally.

5. Conclusions

This paper presents two classification algorithms based on considering the sample as a set of granules of features, which consist of objects that are the closest neighbors by the value of the same feature. Both algorithms proceed from the assumption that objects of each class differ in the probability distributions of

features but use different models to approximate the distributions. The decision function of both algorithms depends on the granule frequencies.

In Algorithm 1, the frequency of quantitative features is found using a function that approximates the frequency distribution for granules of TRS objects of a certain class. It depends on four parameters intended for specific TRS and TS based on cross-validation. The frequency of the TS object in each class is determined by the sum of the feature frequencies in this class, and the object class corresponds to the maximum of this frequency.

In Algorithm 2, for each pair of categorical features of OB objects of a certain class, matrices of pairwise frequencies of features proposed in the paper are calculated. They allow the frequencies of individual features of TS objects to be found, which approximately consider the relationships between the features of TRS objects. Further stages of calculations in both algorithms practically coincide, with the exception of cases concerning objects whose class could not be determined. For these objects, a method is proposed to refine the result based on the k-nearest neighbors method.

Experimental verification showed the effectiveness of both algorithms. The calculation results for two databases based on Algorithm 1 showed that it is possible to achieve almost 100% accuracy by adjusting its parameters. It seems obvious that the proposed algorithms will find applications in solving practical machine learning problems and will be further developed.

References

1. Bishop C. Pattern Recognition and Machine Learning. Springer, Berlin.2006. 738 p.

2. Hastie T., Tibshirani R. and Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd Edition, Springer, Berlin. 2009. 764 p.

3. Murphy K. Machine Learning. A Probabilistic Perspective. MIT Press, Cambridge, Massachusetts, London. 2012. 1098 p.

4. Yao J., Vasiliacos V. and Pedrycz W. Granular Computing. Perspective and Challenges, IEEE Transactions on cybernetics. 2013. V. 43. No. 6. P. 1977–1989.

5. Shats V.N. Classification algorithm based on a stochastic granulating of information. In: 18th Proceeding International Conference Neuroinformatics. 2016. V. 1. P. 113–124. MERhI, Moscow.

6. Shats V.N. The Classification of Objects Based on a Model of Perception. In: B. Kryzhanovsky, W. Dunin-Barkovski, V. Redko (eds.) Advances in Neural Computation, Machine Learning, and Cognitive Research, Studies in Computational Intelligence, 2018. V. 736. P. 125–131. DOI 10.1007/978-3-319-66604-4_1

7. Zadeh L. Fuzzy sets and information granularity. In: Gupta, N., Ragadem, R., Yager, R, (eds.) Advances in Fuzzy Set Theory and Applications. 1979. P. 3–18. North-Holland, Amsterdam.

8. Asuncion A. and Newman D.J. UCI Machine Learning Repository. Irvine University of California, Irvine. 2007.

А.Ю. ДОРОГОВ
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ»
vaksa2006@yandex.ru

РЕГУЛЯРНАЯ НЕЙРОННАЯ СЕТЬ С ФОВЕАЛЬНОЙ АРХИТЕКТУРОЙ

Рассматривается трансформация топологии быстрой нейронной сети к топологии регулярной сети с фовеальной архитектурой. Построено факторизованное представление фовеального преобразования. Показано, что построенная сеть удовлетворяет требованиям, предъявляемым к нейронным сетям, предназначенным для построения систем целенаправленного зрительного восприятия. Представлены примеры построения топологии сети с фовеальной архитектурой. Приведены оценки быстродействия при выполнении фовеального преобразования над входными данными.

Ключевые слова: *быстрая нейронная сеть, фовеальная архитектура, целенаправленное зрительное восприятие.*

Введение

Для биологических объектов характерна фовеальная организация структуры глаза. При такой структуре сетчатка глаза имеет сегментированные поля с разным разрешением: центральное поле (фовеа) – с высоким разрешением и периферические поля – с низкой разрешающей способностью. Исследователи полагают, что процесс восприятия зрительной информации в биологических объектах основан на двухэтапной схеме: первоначально восприятие ведётся в периферическом поле зрения и далее, при наличии интереса, зрительная система переводит точку внимания в фовеальную (центральную) часть поля зрения для детального анализа информации. На этом основана концепция активного зрения, используемая в робототехнике.

В работе [1] отмечалось, что фовеальную систему целенаправленного зрительного восприятия роботов можно реализовать в нейросетевом базисе. При этом по рассуждениям автора искусственная нейронная сеть должна удовлетворять ряду требований:

- отсутствие разобучения «старого» при обучении «новому»;
- нейронная сеть должна быть управляемой в пространстве параметров и функционально универсальной;

- универсальная структура должна обеспечивать, динамическую преднастройку сети на распознавание заданного класса объектов;
- обучение и перенастройка нейронной сети должна осуществляться в реальном времени;
- архитектура сети должна поддерживать фовеальное восприятие информации.

В данной работе, на основе концепции быстрых нейронных сетей (БНС), предложена архитектура регулярной фовеальной нейронной сети в той или иной мере покрывающая указанные требования. Для упрощения математических выкладок далее будет рассмотрено построение одномерной фовеальной сети. Переход к двумерной и многомерной сети не представляет принципиальных трудностей.

Быстрые нейронные сети

Быстрые нейронные сети (БНС) [2] являются разновидностью многослойных регулярных нейронных сетей, реализующих топологию межнейронных связей, подобную топологии алгоритмов быстрого преобразования Фурье (БПФ). Базовые операции БПФ типа «бабочка» соответствуют нейронным ядрам БНС. Благодаря ограниченному набору межнейронных связей достигается высокое быстродействие по сравнению с полно связанными многослойными сетями, причем с увеличением размерности сети выигрыш в быстродействии многократно возрастает.

БНС обладают уникальной возможностью аналитического представления топологической структуры сети, что позволяет построить сверхбыстрые алгоритмы обучения с конечным числом шагов. В отличии от классических многослойных сетей в которых обучающее множество состоит из набора входных и выходных векторов, БНС обучается к эталонам классов. К настоящему времени алгоритмы быстрого обучения разработаны для БНС с линейными функциями активации, такой класс БНС можно трактовать и как быстрые перестраиваемые преобразования. Число эталонов к которому может обучится БНС определяется выходной размерностью нейронных ядер. Обычно это значение не велико, например, БНС с размерностью ядер равной 2 может обучиться только к двум эталонам. При этом часть степеней свободы БНС остается не использованными. На рис. 1 показана топологическая структура трехслойного быстрого перестраиваемого преобразования размерности 8 обученного к двум эталонным векторам. Слои сети представлены топологическими матрицами, в которых единицами помечены ненулевые элементы матриц – синаптические веса

нейронов, пустые значения соответствуют нулевым элементам – т.е. отсутствию связей, а «звездочки» – обозначают не использованные степени свободы. Строки и столбцы матриц пронумерованы в двоичной системе счисления.

		V_2	0	0	0	0	1	1	1	1	0	0	0	0	1	1	1	1	0	0	0	0	1	1	1	1
		V_1	0	0	1	1	0	0	1	1	0	0	1	1	0	0	1	1	0	0	1	1	0	0	1	1
		V_0	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1
U_2	U_1	U_0																								
0	0	0	1	1							1		*						1				*			
0	0	1	1	1								1		*						1				*		
0	1	0			1	1					1		*								*				*	
0	1	1			1	1						1		*								*				*
1	0	0					1	1							1		*		1				*			
1	0	1					1	1								1		*		1				*		
1	1	0							1	1					1		*				*				*	
1	1	1							1	1						1		*				*				*

Рис. 1. Топология быстрого перестраиваемого преобразования

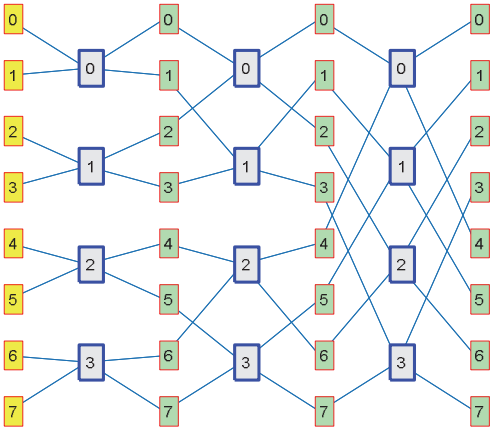

Рис. 2. Топологический граф БНС с выделенными нейронными ядрами

При настройке сети свободные параметры могут быть заполнены произвольными значениями. На рис. 2 показан граф сетевой модели соответ-

ствующий топологии показанной на рис. 1. Дополнительно на графе выделены нейронные ядра. В данной модели каждый слой содержит четыре нейронных ядра размерности 2×2.

Сетевая модель данной топологии в общем случае описывается набором кортежей [2]:

$$\begin{aligned} z^m &= \langle u_{n-1}u_{n-2}\cdots u_{m+1}v_{m-1}v_{m-2}\cdots v_1v_0\rangle, \\ U^m &= \langle u_{n-1}u_{n-2}\cdots u_{m+1}u_m v_{m-1}v_{m-2}\cdots v_1v_0\rangle, \\ V^m &= \langle u_{n-1}u_{n-2}\cdots u_{m+1}v_m v_{m-1}v_{m-2}\cdots v_1v_0\rangle, \end{aligned} \qquad (1)$$

где z^m – порядковый номер ядра, U^m, V^m – порядковые номера рецепторов и аксонов в слое m, u_m, v_m – локальные номера рецепторов и аксонов в пределах ядра слоя m. Каждый кортеж представляет собой поразрядную форму представления порядкового номера через разрядные переменные u_m, v_m. Для ядер размерности 2×2 разрядные переменные принимают значения $\{0,1\}$. В каждом нейронном ядре выполняется умножение входного вектора на матрицу синаптических весов $w_{z^m}(u_m, v_m)$. Оператор ядра может быть записан в виде:

$$y^m\left(V^m\right) = \sum_{u_m} w_{z^m}(u_m, v_m)x^m\left(U^m\right).$$

Здесь $x^m\left(U^m\right)$ – входы, а $y^m\left(V^m\right)$ – выходы нейронного слоя. Если в топологическом представлении (см. рис. 1), вместо ‘1’ и «звёздочек» поставить значения элементов нейронных ядер, то получим факторизованное представление быстрого преобразования в виде произведения слабозаполненных матриц $H = H_0H_1\cdots H_{n-1}$. Где матрица H_m соответствует нейронному слою m (для рис. 1, $n=3$). Можно показать [2, 3], что элементы матрицы H быстрого преобразования представимы произведениями элементов нейронных ядер:

$$h(U,V) = \prod_{m=0}^{n-1} w_{z^m}(u_m, v_m),$$

где $U = U^0 = \langle u_{n-1}u_{n-2}\cdots u_1u_0\rangle$, $V = V^{n-1} = \langle v_{n-1}v_{n-2}\cdots v_1v_0\rangle$. Настройка БНС основана на мультипликативной декомпозиции эталонных вектор-функций:

$$f(U) = \prod_{m=0}^{n-1} \phi_{i^m}(u_m), \qquad i^m = \langle u_{m+1}u_{m+1}\cdots u_{n-1}\rangle.$$

Алгоритм мультипликативной декомпозиции представлен в [2, 3]. Сравнивая мультипликативное представление для элементов матрицы H и эталонной функции получим правило обучения нейронных ядер:

$$w_{z^m}\left(u_m,\hat{v}_m\right)=\phi_{i^m}\left(u_m,\hat{v}_m\right),$$

где $\hat{V}=\left\langle \hat{v}_{n-1}\hat{v}_{n-2}\cdots\hat{v}_1\hat{v}_0\right\rangle$ - номер столбца в матрице H, совпадающего с эталоном. Алгоритм обучения не требует градиентных процедур и абсолютно сходится за конечное число шагов, пропорциональное числу нейронных слоёв БНС. Настройка сети на произвольный образ может быть сохранена в памяти и восстановлена в универсальной сетевой топологии по запросу. Таким образом, покрываются требования универсальности структуры, а также обучения и перенастройки нейронной сети в реальном времени.

Сеть с фовеальной архитектурой

Число не использованных при настройке БНС степеней свободы недостаточно для обучения ещё к одному эталону, но можно изменить размерность эталона и дообучить сеть к эталону меньшей размерности. Снижение размерности эталона эквивалентно уменьшению разрешения в фовеальной системе. Такое решение естественным образом приводит к фовеальной архитектуре сети.

Будем полагать, что центр фовеальной зоны определяется координатой $\hat{V}=\left\langle \hat{v}_{n-1}\hat{v}_{n-2}\cdots\hat{v}_1\hat{v}_0\right\rangle$ где $\hat{v}_m,\ \ m=0,1,\ldots,n-1$ – фиксированные значения разрядных переменных. Интервалы значений разрядных переменных u_m,v_m определяются целыми положительными числами, зададим их соответствиями:

$$\begin{pmatrix} u_0 & u_1 & \cdots & u_{n-2} & u_{n-1}\\ p_0 & p_1 & \cdots & p_{n-2} & g_{n-1}\end{pmatrix},\qquad \begin{pmatrix} v_0 & v_1 & \cdots & v_{n-2} & v_{n-1}\\ g_0 & g_1 & \cdots & g_{n-2} & g_{n-1}\end{pmatrix}.$$

Варьирование в выражении $\hat{V}$ младшего разряда v_0 - приводит к образованию фовеальной зоны $a_0=\left\langle \hat{v}_{n-1}\hat{v}_{n-2}\cdots\hat{v}_1v_0\right\rangle$. Все эталоны фовеальной зоны имеют одинаковое разрешение. Множество эталонов зоны описывается выражением:

$$f^0_{a_0}\left(U\right)=f^0_{a_0}\left\langle u_{n-1}u_{n-2}\ldots u_1u_0\right\rangle=\prod_{m=0}^{n-1}\phi^{a_0}_{i^m}\left(u_m\right). \qquad (2)$$

Количество эталонов в фовеальной зоне очевидно равно g_0. Построенную зону назовём фовеальной зоной нулевого порядка. К этой зоне отно-

сятся функции преобразования обладающие наивысшим разрешением. Варьируя теперь в $\hat{V}$ разряды v_0 и v_1, образуем фовеальную зону первого порядка: $a_1 = \langle \hat{v}_{n-1}\hat{v}_{n-2}\cdots\hat{v}_2 v_1 v_0 \rangle$. Зона a_1 полностью включает в себя фовеальную зону нулевого порядка и имеет размер $g_1 g_0$. Для этой зоны входные вектор-функции слоя запишем в виде $f^1_{a_1}\langle u_{n-1}u_{n-2}\ldots u_2 u_1\rangle$. Размерность этих функций в p_0 раз меньше размерности эталонов фовеальной области. Часть этих функций, а именно g_0 являются образующими эталонов фовеальной области нулевого порядка и уже определены декомпозицией (2), а остальные функции в количестве $g_1 g_0 - g_0$ могут быть использованы как эталоны меньшего разрешения.

Будем полагать, что БНС обучена к эталонам фовеальной области нулевого порядка. Из описания топологии БНС (1) имеем, что нумерации входов и выходов слоя $m = 1$ определяются выражениями:

$$U^1 = \langle u_{n-1}u_{n-2}\cdots u_2 u_1 v_0\rangle, \qquad V^1 = \langle u_{n-1}u_{n-2}\cdots u_2 v_1 v_0\rangle.$$

Из выражения для координаты U^1 следует, что входы этого слоя полностью задействованы под фовеальную зону нулевого порядка. Для эталонов меньшего разрешения в данной архитектуре нет возможности выделить дополнительные входы. Тем не менее, в слое присутствуют свободные элементы, количество которых в совокупности достаточно для использования эталонами меньшего разрешения. Таким образом, возникает необходимость изменения топологии БНС.

Для образования дополнительных входов выполним расщепление слоя $m = 1$ на карты по разрядным переменным v_i. Каждая карта имеет вход размерности $p_{n-1}p_{n-2}\cdots p_2 p_1$. Выходы карт привязаны к топологии БНС и определяются разрядным представлением номера аксона V^1 и позициями разрядных переменных v_i в этом представлении. Обозначим через $v^1 = \langle v_1 v_0\rangle$ - номер карты. Карта $\langle \hat{v}_1 v_0\rangle$ обслуживает фовеальную зону нулевого порядка и должна быть связана с нулевым слоем, остальные карты не задействованы и имеют свободные входы. Обозначим через $\overline{v}_1$ разрядное значение из диапазона разрядной переменной v_1, отличное от $\hat{v}_1$, тогда карты с номерами $\overline{v}^1 = \langle \overline{v}_1 v_0\rangle$ имеют свободные входы, а карты с номерами $\hat{v}^1 = \langle \hat{v}_1 v_0\rangle$ относятся к фовеальной зоне нулевого порядка и связаны с предыдущим слоем. На входы карт подаются функции $f^1_{a_1}\langle u_{n-1}u_{n-2}\ldots u_2 u_1\rangle$.

Выполним декомпозицию зоны a_1 на две подзоны, обозначив через $\hat{a}_1 = \langle \hat{v}_{n-1}\hat{v}_{n-2}\cdots\hat{v}_2\hat{v}_1 v_0 \rangle$ - область, относящуюся к фовеальной зоне, а через $\overline{a}_1 = \langle \hat{v}_{n-1}\hat{v}_{n-2}\cdots\hat{v}_2\overline{v}_1 v_0 \rangle$ - первую окрестность фовеальной зоны. Соответственно выполним декомпозицию входных функций. В отличие от полной зоны, окрестность связана только с функциями одного разрешения.

Обозначим через $x^1_{\hat{v}^1}\langle u_{n-1}u_{n-2}\ldots u_2u_1\rangle = f^1_{\hat{a}_1}\langle u_{n-1}u_{n-2}\ldots u_2u_1\rangle$ вектор-функции связанные с предыдущим слоем, а через $f^1_{\overline{a}_1}\langle u_{n-1}u_{n-2}\ldots u_2u_1\rangle$ - вектор-функции поступающие на свободные входы слоя. Добавочное обозначение $x^1_{\hat{v}^1}$ позволяет явным образом выделить входы карт связанных с предыдущим слоем. Нумерация выходов нулевого слоя БНС определяется разрядным представлением $V^0 = \langle u_{n-1}u_{n-2}\cdots u_2u_1v_0\rangle$, и из выражения (1) имеем $U^1 = V^0$. Отсюда следует, что

$$x^1_{\hat{v}^1}\langle u_{n-1}u_{n-2}\ldots u_2u_1\rangle = y^0\left(V^0\right) = y^0\langle u_{n-1}u_{n-2}\ldots u_2u_1v_0\rangle.$$

Для настройки сети к эталонам меньшего разрешения выполняется мультипликативное разложение эталонных функций окрестности 1 по правилу:

$$f^1_{\overline{a}_1}\langle u_{n-1}u_{n-2}\ldots u_2u_1\rangle = \prod_{m=1}^{n-1}\phi_{i^m}^{\overline{a}_1}(u_m).$$

Подобную операцию расщепления выполним для всех слоёв БНС. Номер карты в слое m будет определяться выражением $v^m = \langle v_m\cdots v_1v_0\rangle$. Карты имеющие свободные входы будут иметь номера $\overline{v}^m = \langle \overline{v}_m v_{m-1}\cdots v_1v_0\rangle$, а карты связанные с предыдущим слоем – $\hat{v}^m = \langle \hat{v}_m v_{m-1}\cdots v_1v_0\rangle$. Отметим, что расщеплению подлежат все слои, включая нулевой, в нулевом слое образуется g_0 карт, а в последнем $g_{n-1}g_{n-2}\cdots g_0$. Причём в последнем слое $g_{n-2}g_{n-3}\cdots g_0$ карт связаны с предыдущим слоем. На рис. 3 показана топология трехслойной сети с расщеплением слоёв. Сеть имеет тот же набор синаптических весов, что и БНС, но распадается на независимые компоненты. Каждый из компонентов настраивается на один из эталонов.

В этой сети степени свободы использованы полностью. Для многослойной фовеальной сети m-окрестности фовеальной зоны определяются выражением $\overline{a}_m = \langle \hat{v}_{n-1}\hat{v}_{n-2}\cdots\hat{v}_{m+1}\overline{v}_m v_{m-1}\cdots v_0\rangle$, а входные эталонные вектор-функций для свободных входов слоя m задаются правилом:

$$f^m_{\overline{a}_m}\langle u_{n-1}u_{n-2}\ldots u_2u_m\rangle = \prod_{r=m}^{n-1}\phi_{i^r}^{\overline{a}_m}(u_r).$$

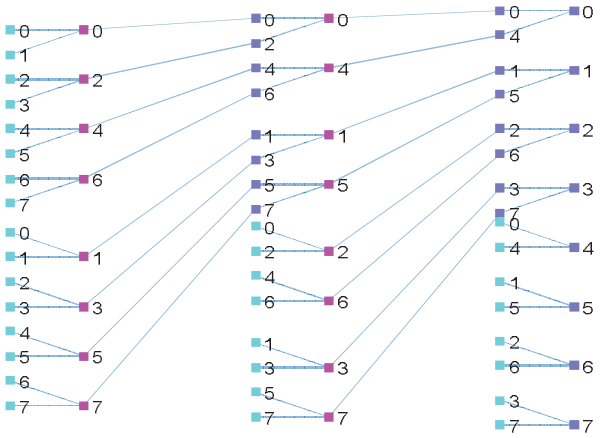

Рис. 3. Топология нейронной сети с фовеальной архитектурой

Межслойные связи определяются выражениями:

$$x^m_{\hat{v}^m}\left\langle u_{n-1}u_{n-2}\dots u_{m+1}u_m\right\rangle = y^{m-1}\left(V^{m-1}\right) = y^{m-1}\left\langle u_{n-1}u_{n-2}\dots u_{m+1}u_m v_{m-1}v_{m-1}\cdots v_0\right\rangle.$$

Поскольку фовеальная сеть является производной от БНС, то она наследует и правила обучения нейронных ядер, которые трансформируются к виду:

$$w^m_{z^m}\left(u_m, v_m\right) = \phi^{a_m}_{i^m}\left(u_m, v_m\right).$$

где

$$z^m = \left\langle u_{n-1}u_{n-2}\cdots u_{m+1}v_{m-1}v_{m-2}\cdots v_1 v_0\right\rangle, \qquad i^m = \left\langle u_{m+1}u_{m+1}\cdots u_{n-1}\right\rangle,$$

$$a_m = \left\langle \hat{v}_{n-1}\hat{v}_{n-2}\cdots\hat{v}_{m+1}v_m\cdots v_0\right\rangle.$$

Каждый компонент фовеальной сети обучается к собственному эталону, поэтому переобучение сети принципиально невозможно. Позицией фовеального центра сети, а значит и системой окрестностей можно управлять, задавая в правиле обучения значения переменных $\left\langle \hat{v}_{n-1}\hat{v}_{n-2}\cdots\hat{v}_1\hat{v}_0\right\rangle$. Фовеальное восприятие информации обеспечивается по построению сети. Таким образом, покрывается ещё ряд требований, обозначенных в работе [1].

Обработка данных в фовеальной архитектуре

Обработку данных фовеальной сетью можно выполнить следуя построенному графу многослойного алгоритма. Поскольку фовеальная сеть состоит из отельных компонент, то обработку можно выполнять для каждого

компонента независимо. Альтернативно, фовеальное преобразование можно выполнить напрямую, через функции фовеального преобразования (фовеального «базиса»). Из графа алгоритма следует, что функции фовеального «базиса» можно построить используя следующие выражения:

$$h^m\left(\left\langle u_{n-1}u_{n-2}\cdots u_m\right\rangle,\overline{a}_m\right)=\prod_{r=m}^{n-1}w_{z^m}^m\left(u_r,v_r\right),$$

$$\overline{a}_m=\left\langle\hat{v}_{n-1}\hat{v}_{n-2}\cdots\hat{v}_{m+1}\overline{v}_m v_{m-1}\cdots v_0\right\rangle.$$

Фовеальное преобразование в этом варианте можно вычислить, следуя правилу:

$$y_m^{n-1}\left(V\right)=\sum_{U=0}^{N_m-1}h^m\left(U,\overline{a}_m\right)f^m\left(U\right),\quad N_m=\left\langle p_{n-1}p_{n-2}\cdots p_m\right\rangle,$$

где m – порядок фовеальной зоны. Оценим быстродействие обоих вариантов. Вычислительные затраты определим как число операций умножения необходимое для выполнения преобразования. Для прямого преобразования с учётом размерностей фовеальных зон m-го порядка получим:

$$D=\sum_{m=0}^{n-1}\left(\prod_{r=0}^{m}g_r-\prod_{r=0}^{m-1}g_r\right)\prod_{r=m}^{n-1}p^r,\qquad\prod_{r=0}^{-1}g_r=0.$$

А число операций в варианте многослойного алгоритма равно:

$$D_f=\sum_{m=0}^{n-1}\prod_{r=0}^{m}g_r\prod_{r=m}^{n-1}p_r$$

Из сравнений последних выражений видно, что многослойный алгоритм проигрывает по числу операций, прямому выполнению преобразования. Этот вывод справедлив для процессоров с последовательным выполнением операций. Однако для процессоров с конвейерной архитектурой и массовым распараллеливанием преимущества будут у многослойного алгоритма, поскольку вычислительные затраты в этом случае будут определяться только числом слоёв алгоритма, а оно такое же как в алгоритме БНС.

Если известна матрица преобразования $H=\left\|h\left(U,V\right)\right\|$ для высокого разрешения, то функции фовеального преобразования $h^m\left(U\right)$ могут быть получены процедурой последовательной фрактальной фильтрацией [2] строк (или столбцов) матрицы H следуя правилу:

$$h^{m+1}\left\langle u_{n-1}u_{n-2}\cdots u_{m+1}\right\rangle=\underset{u_m}{\Phi}\left(h^m\left\langle u_{n-1}u_{n-2}\cdots u_m\right\rangle\right),$$

где, $h^0\left\langle u_{n-1}u_{n-2}\cdots u_0\right\rangle=h\left(U,V\right)$, и $\underset{u_m}{\Phi}\left(\cdot\right)$ – произвольный невырожденный функционал на выборке, образованной при варьировании разрядной переменной u_m. Функционалом может быть, например, вычисление среднего,

медианы, максимума, минимума и пр. Нерегулярный вариант этой операции известен также как операция субдискретизации или пулинга. На рис. 4 показаны функции $h^m(U)$, когда матрица H – единичная.

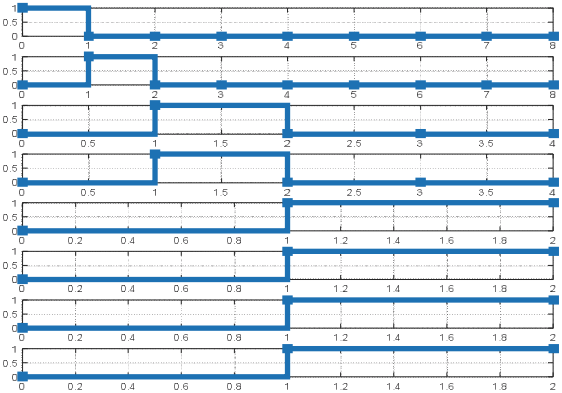

Рис. 4. Функции фовеального «базиса»

Фовеальные зоны m-го порядка выбраны по зонам многослойного алгоритма. На графиках рис. 4 функции фовеального «базиса» условно приведены к одному масштабу.

Заключение

Фовеальная архитектура нейронной сети, вводит в рассмотрение новую характеристику – переменное пространственное разрешение. Это качественное отличие создаёт точку отсчёта для пространственных измерений с помощью сети. В частности, когда все функции фовеального «базиса» порождаются одним патерном, фовеальную сеть можно использовать для быстрых корреляционных измерений [4]. Подобный алгоритм быстрой корреляции рассматривался также в работе [5].

В задачах распознавания, селектирующие функции переменного разрешения, позволяют получить дополнительный набор информативных признаков, и реализовать алгоритмы последовательного распознавания объектов.

В данной работе акцент сделан на регулярные сети, в которых размерность обрабатываемых данных и выходных векторов допускают факторизацию в набор множителей. Проведённое исследование позволило устано-

вить наследственные связи между регулярными фовеальными преобразованиям и быстрыми алгоритмами. Показано, что построенная регулярная фовеальная архитектура удовлетворяет требованиям к нейронной сети, предназначенной для использования в системах целенаправленного зрительного восприятия роботов.

Список литературы

1. Самарин А.И. Нейросетевые модели в задачах управления поведением робота // В кн.: Лекции по нейроинформатике. 3-я Всероссийская науч.-техн. конф. «Нейроинформатика 2001». М.: МИФИ, 2001. С. 60–102.

2. Дорогов А.Ю. Теория и проектирование быстрых перестраиваемых преобразований и слабосвязанных нейронных сетей. СПб.: Политехника, 2014. 328 с.

3. Дорогов А.Ю. Быстрые нейронные сети: Проектирование, настройка, приложения // В кн.: Лекции по нейроинформатике Ч. 1. В тр. школы-семинара «Современные проблемы нейроинформатики», науч.-техн. конф. «Нейроинформатика-2004» 28–30 января 2004 г. М.: МИФИ, 2004. С. 69–135.

4. Дорогов А.Ю. Фрактальный метод локализации корреляционного максимума // Материалы XIII Всероссийского семинара «Нейроинформатика и ее приложения», 7–9 октября 2005 г. Красноярск. С. 31–33.

5. Александров В.В., Горский Н.Д. Представление и обработка изображений: Рекурсивный подход. Л.: Наука, 1985. 192 с.

Б.В. КРЫЖАНОВСКИЙ, Л.Б. ЛИТИНСКИЙ, И.М. КАГАНОВА

Научно-исследовательский институт системных исследований РАН, Москва
kryzhanov@mail.ru, litin@mail.ru, imkaganova@gmail.com

МЕТОД *n*-ОКРЕСТНОСТЕЙ ДЛЯ МОДЕЛИ ИЗИНГА С ДАЛЬНОДЕЙСТВИЕМ

Метод *n*-окрестностей, позволяющий с хорошей точностью вычислять критические значения обратной температуры для модели Изинга с короткодействующим взаимодействием, обобщается на случай дальнодействия в спиновой системе. Сравнение наших теоретических оценок с результатами компьютерного эксперимента для планарной и кубической моделей Изинга демонстрируют хорошее согласие.

Ключевые слова: *свободная энергия, метод n-окрестностей, модель Изинга, дальнодействующее взаимодействие.*

1. Введение и постановка задачи

Впечатляющий пример применения методов статистической физики в нейронауках – полученная из первых принципов оценка емкости памяти модели Хопфилда [1]. Речь идет о соотношении $p_c \approx 0.138 \cdot N$, где p_c есть верхняя граница для максимального числа случайных паттернов, которые способна запомнить ассоциативная сеть с Хеббовской матрицей связи; размерность задачи предполагается большой: $N >> 1$.

В основании всех статистико-физических рассмотрений находится свободная энергия – с ее помощью вычисляют важнейшие макрохарактеристики системы. Для получения свободной энергии необходимо знать распределение энергий всех 2^N состояний системы, а оно как правило неизвестно.

Нами развит метод n-окрестностей – универсальный способ приближенного вычисления свободной энергии для большой спиновой системы. Подход основан на аппроксимации распределения энергий состояний, и может быть описан следующим образом. Зафиксируем какую-нибудь конфигурацию $\mathbf{s}_0$ в качестве начальной, а остальные конфигурации распределим по ее *n*-окрестностям Ω_n: Ω_n состоит из конфигураций, отличающихся от начальной конфигурации $\mathbf{s}_0$ противоположным значением *n* бинарных координат. Здесь n принимает значения из интервала $[0, N]$, а число конфигураций в *n*-окрестности Ω_n равно C_N^n.

Распределение энергий состояний, принадлежащих Ω_n, как правило, неизвестно. Тем не менее, можно *точно* вычислить среднее значение E_n и дисперсию σ_n^2 этого распределения, выразив их через характеристики матрицы связи $\mathbf{T} = \left(T_{ij}\right)_{i,j=1}^{N}$ и начальной конфигурации $\mathbf{s}_0$ [2], [3]. Опыт показывает – и это обосновывается с помощью центральной предельной теоремы, - что при больших значениях N распределение энергий состояний из *n*-окрестности удовлетворительно аппроксимируется гауссовым распределением со средним E_n и дисперсией σ_n^2. В этом и состоит приближение метода n-окрестностей: истинная плотность распределения энергий состояний из Ω_n аппроксимируется гауссовой плотностью с «правильными» значениями среднего E_n и дисперсии σ_n^2.

Распределение энергий всех 2^N состояний получается суммированием «парциальных» гауссовых распределений, построенных для всех *n*-

окрестностей Ω_n. Устремляя N к бесконечности переходим от суммирования по n к интегрированию по независимой переменной $m = 1 - 2n / N$, которая характеризует намагниченность состояния. Используя стандартные преобразования получаем уравнение состояния, с помощью которого для данного значения обратной температуры $\beta = 1/T$ определяется значение свободной энергии. В простейшем виде уравнение состояния имеет вид:

$$\frac{1}{2m}\ln\frac{1+m}{1-m} = \gamma b\left[1 - b + bm^2\right], \qquad (1)$$

где намагниченность $m \in [-1,1]$, а остальные параметры уравнения суть

$$b = \beta\frac{\sum_{ij} T_{ij}^2}{\sum_{ij} T_{ij}}\ , \quad \gamma = \frac{\left(\sum_{ij} T_{ij}\right)^2}{N\sum_{ij} T_{ij}^2}\ . \qquad (2)$$

Здесь b есть удобным образом нормированная обратная температура β, а безразмерный параметр γ характеризует эффективное взаимодействие каждого спина с его окружением. Отметим, что γ является внешним параметром задачи.

Уравнения (1), (2) апробировались в применении к известной модели Изинга на гиперкубе [4]. В этой модели спины сидят в узлах гиперкубической решетки, каждый спин взаимодействует только с ближайшими соседями, и все отличные от нуля взаимодействия одинаковы. Будем называть это *стандартной* моделью Изинга. Она известна в физике около 100 лет, и для нее имеется множество твердо установленных результатов.

В настоящей статье обсуждается планарный вариант модели, когда в качестве решетки выступает разбитая на квадраты плоскость, в узлах которой сидят спины. В этом случае размерность гиперкуба $d = 2$, а число ближайших соседей у каждого спина равно $q = 4$. Кроме того, изучается кубическая модель, для которой $d = 3$, а число ближайших соседей у каждого спина $q = 6$. Вообще, если размерность гиперкуба есть d, то число ближайших соседей у каждого спина $q = 2d$.

Известно, что для стандартной модели Изинга с $d > 1$ характерны фазовые переходы второго рода, а переходы первого рода отсутствуют [4]. Можно показать [3], что для нашего уравнения (1) это требование будет выполняться только когда значение параметра γ удовлетворяет ограничению:

$$\gamma > 16/3\ . \qquad (3)$$

В этом случае можно в явном виде выписать выражение для критического значения обратной температуры:

$$\beta_c = \frac{\sum_{i,j} T_{ij}}{2 \cdot \sum_{i,j} T_{ij}^2} \left(1 - \sqrt{1 - 4/\gamma}\right), \qquad (4)$$

где γ дается выражением (2). Выражения (2)–(4) принимают особенно простой вид для стандартной модели Изинга: в этом случае значение параметра γ равно числу ближайших соседей спина:

$$\gamma = q = 2d \ . \qquad (5)$$

Выражение (4) тоже становится более обозримым:

$$\beta_c = \frac{1 - \sqrt{1 - 2/d}}{2} . \qquad (6)$$

Данным выражением можно пользоваться только для размерностей гиперкуба $d > 8/3$. Это исключает из рассмотрения планарную модель Изинга (для нее $d = 2$), однако для размерностей гиперкуба $d = 3, 4, 5, 6, 7$ неравенство (3) выполняется. И оказывается, что для всех этих решеток формула (6) дает значения критической температуры, которые хорошо согласуются с результатами интенсивного компьютерного моделирования см. [3, 5–7] – результаты приведены в табл. 1.

Таблица 1

Сопоставление оценки (6) с компьютерным экспериментом

d	3	4	5	6	7
β_c из (6)	0,2113	0,1464	0,1127	0,0918	0,0774
Эксперимент	0,2216	0,1489	0,1139	0,0923	0,0777

Чем больше размерность d гиперкуба, тем лучше согласие теории с экспериментом. Если для $d = 3$ относительное расхождение между теоретической и экспериментальной оценками составляет около 2.5 %, то с увеличением размерности гиперкуба от $d = 3$ до $d = 7$ величина расхождения уменьшается до 0,25 %. Простое аналитическое выражение (6) обладает неплохой предсказательной силой.

В настоящей работе мы выходим за рамки стандартной модели Изинга, и помимо взаимодействия с ближайшими соседями учитываем взаимодей-

ствие со вторыми, а для кубической модели – и с третьими соседями. Взаимодействие с ближайшим соседом кладется равным 1, а взаимодействие с более далекими соседями варьируется от 0 до 1. Оказывается, теперь метод n-окрестностей можно использовать и для планарной модели Изинга, поскольку, начиная с некоторого значения константы взаимодействия со вторыми соседями, требование (3) будет удовлетворено. Частично результаты следующего раздела были впервые опубликованы в [8].

2. Планарная модель Изинга со вторыми соседями

В этом случае у каждого спина имеется 4 ближайших соседа, которые отстоят от него на расстояние ребра элементарного квадрата решетки. Вторых соседей у каждого спина тоже 4 – они отстоят от начального спина на расстояние диагонали элементарного квадрата. Для обозначения взаимодействия со вторыми соседями используем традиционное обозначение J_3. Для параметра γ получаем из (2):

$$\gamma = 4\frac{(1+J_3)^2}{1+J_3{}^2}. \qquad (7)$$

Когда J_3 меняется в интервале от $3-2\sqrt{2} \approx 0.2$ до 1, выражение (7) дает значения γ, большие 16/3. Таким образом, здесь можно применять метод n-окрестностей, а значение критического значения обратной температуры (4) принимает вид:

$$\beta_c = \frac{1+J_3-\sqrt{2J_3}}{2(1+J_3{}^2)}. \qquad (8)$$

Это выражения проверялось с помощью компьютерного эксперимента. Для различных значений параметра J_3 создавалась матрица связи модели Изинга со вторыми соседями размерности $N = 100\times100$, и с помощью метода Монте-Карло для каждого значения обратной температуры $\beta \sim 1/T$ вычисляли среднее значение энергии и ее дисперсию $\sigma_E^2(\beta)$. Поскольку вторая производная свободной энергии пропорциональна дисперсии $\sigma_E^2(\beta)$, критическое значение обратной температуры $\beta_c^{(\mathrm{ex})}$ отождествляли с точкой сингулярности на графике $\sigma_E^2(\beta)$. В первом столбце таблицы 1 приведены использованные значения параметра взаимодействия J_3, во втором столбце – соответствующие значения параметра γ, в третьем столбце – экспериментальные значения $\beta_c^{(\mathrm{ex})}$, в четвертом – теоретическая

оценка β_c (8), а в пятом столбце – величина β_c, помноженная на нормировочный множитель 1.3 .

Очевидно, что экспериментальные значения $\beta_c^{(\mathrm{ex})}$ заметно отличаются от теоретической оценки β_c – ср. третий и четвертый столбцы таблицы. Но столь же несомненно, что величины $\beta_c^{(\mathrm{ex})}$ и $1.3\beta_c$ практически совпадают для всех значений варьируемого параметра J_3. Относительную разницу между ними удобно характеризовать стандартным отношением:

$$\delta = \frac{1.3\beta_c - \beta_c^{(\mathrm{ex})}}{1.3\beta_c + \beta_c^{(\mathrm{ex})}} \cdot 100\ \% .$$

В последнем столбце таблицы приведены значения этой характеристики. Видно, что относительное расхождение между двумя оценками колеблется в пределах одного процента.

Таблица 2

Эксперимент $\beta_c^{(ex)}$ и теория β_c для различных J_3

J_3	γ	$\beta_c^{(ex)}$	β_c	$1.3\beta_c$	δ ,%
0,200	5,538	0,3460	0,2729	0,3547	1,24
0,268	6,000	0,3220	0,2500	0,3250	0,46
0,369	6,600	0,2900	0,2243	0,2916	0,28
0,500	7,200	0,2620	0,2000	0,2600	-0,38
0,630	7,608	0,2355	0,1817	0,2361	0,13
0,750	7,840	0,2200	0,1681	0,2185	-0,34
0,850	7,948	0,2066	0,1585	0,2061	-0,12
1,000	8,000	0,1900	0,1464	0,1904	0,11

На рис. 1 видно, что экспериментальные значения $\beta_c^{(\mathrm{ex})}$ практически ложатся на график кривой $1.3 \cdot \beta_c$. Изолированная точка на оси ординат отвечает значению критической температуры для стандартного варианта планарной модели Изинга: $\beta_c^{(0)} = 0.4407$ - точный результат, полученный Л. Онсагером в 1950 г. Невозможно продолжить наш график в данную область, но то, что он стремится к этой точке, вполне очевидно.

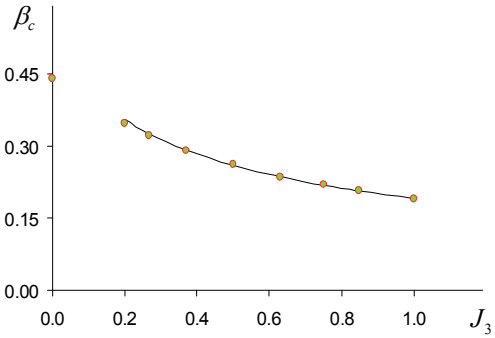

Рис. 1. Критические значения обратной температуры:
кружки – эксперимент, сплошная – $1.3\beta_c$

Обсуждение нормировочного множителя 1.3 дано в последнем разделе. В любом случае тот факт, что одним подгоночным множителем удается совместить экспериментальную и теоретическую кривые на всем интервале значений параметра J_3, не может не привлекать внимания.

3. Кубическая модель Изинга со вторыми и третьими соседями

Для кубической решетки мы учитываем взаимодействие не только со вторыми, но и с третьими соседями. У каждого спина имеется 6 ближайших соседей, 12 вторых и 8 третьих соседей. Взаимодействие с ближайшими соседями клали равным единице: $J_1 = J_2 = J_3 = 1$, и затем, в пределах от 0 до 1, варьировали сначала взаимодействие J_4 со вторыми, а затем – и взаимодействие J_5 с третьими соседями. Формулы (2), (4) дают:

$$\gamma = \frac{2\cdot\left(3+6J_4+4J_5\right)^2}{\left(3+6J_4^2+4J_5^2\right)}\ ,\quad \beta_c = \frac{3+6J_4+4J_5}{2\cdot\left(3+6J_4^2+4J_5^2\right)}\left(1-\sqrt{1-\frac{4}{\gamma}}\right). \qquad (9)$$

Компьютерный эксперимент проводился так же, как это описано в предыдущем разделе. Для фиксированных значений J_4, J_5 создавали матрицу связей, варьировали величину обратной температуры $\beta \sim 1/T$, и для каждого ее значения методом Монте-Карло вычисляли среднее значение

энергии и ее дисперсию $\sigma_E^2(\beta)$. Критическое значение обратной температуры $\beta_c^{(\mathrm{ex})}$ определялось как точка сингулярности на графике $\sigma_E^2(\beta)$.

На рис. 2, для размерности $N = 20\times 20\times 20$, показаны графики нормированной дисперсии $\sigma^2(\beta)/\sigma_0^2$ при различных значениях параметра J_4 (здесь $J_5 = 0$). Нормировочный множитель $\sigma_0^2 = 3\cdot(1+2\cdot J_4^2)$ есть приведенная сумма квадратов матричных элементов; нормировка на него позволяет собрать все графики на одной панели, что иначе было бы невозможно.

Поясним, что отыскивалась не точка разрыва функции $\sigma_E^2(\beta)$ (при конечной размерности обнаружить разрыв невозможно), а точка максимума на графике $\sigma_E^2(\beta)$. Найденное значение $\beta_{\max}$ принималось в качестве приближения к $\beta_c^{(ex)}$: $\beta_c^{(ex)} \approx \beta_{\max}$. Для $N = 8000$ у нас получилось, что экспериментальная оценка $\beta_{\max}$ и теоретическое значение β_c (9) связаны коэффициентом пропорциональности 1.11: $\beta_{\max} \approx 1.11\cdot\beta_c$.

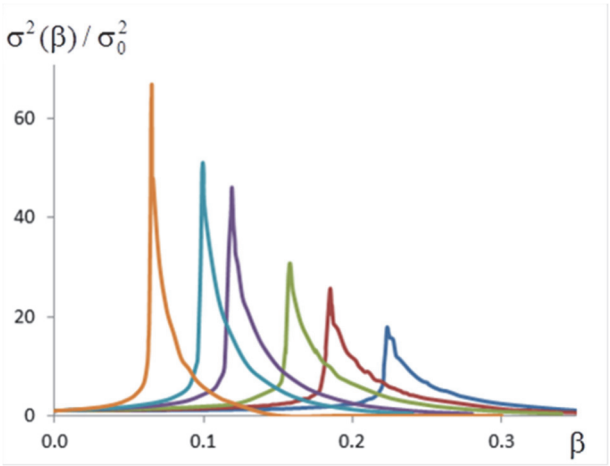

Рис. 2. Графики нормированной дисперсии
для J_4 = 0, 0.0815, 0.16227, 0.35425, 0.5 и 1 (справа налево)

Финальный эксперимент был проделан для размерности задачи $N = 64\times 64\times 64$, включал варьирование сначала коэффициента J_4, а затем

и коэффициента J_5, и продемонстрировал лучшее согласие между теоретической и экспериментальной оценками критической температуры: $\beta_{\max} \approx 1.08\beta_c$. Результаты эксперимента приведены в табл. 3.

В первом и втором столбцах даны значения варьируемых параметров взаимодействия J_4 и J_5, а в третьем столбце – отвечающие им значения γ (9). Эффективное число соседей монотонно увеличивается с 6 до 26. В четвертом столбце приведены значения теоретической оценки β_c (9), в пятом – значения $1.08\beta_c$, а в шестом столбце – экспериментальная оценка $\beta_{\max}$ критической температуры. В последнем столбце таблицы приведены величины относительной разницы между $1.08\beta_c$ и $\beta_{\max}$: величина относительной ошибки составляет доли процента.

Таблица 3

Эксперимент $\beta_{\max}$ и теория β_c для различных J_4 и J_5

J_4	J_5	γ	β_c (9)	$1.08 \cdot \beta_c$	$\beta_{\max}$	δ, %
0	0	6,000	0,21132	0,22823	0,22201	-1,38
0,08114	0	8,000	0,16800	0,18144	0,18080	-0,18
0,16228	0	10,000	0,14181	0,15315	0,15330	0,05
0,25000	0	12,000	0,12234	0,13212	0,13343	0,49
0,35425	0	14,000	0,10574	0,11420	0,11640	0,96
0,50000	0	16,000	0,08932	0,09646	0,09800	0,79
0,70000	0	17,455	0,07396	0,07987	0,08031	0,27
0,85000	0	17,890	0,06563	0,07088	0,07070	-0,12
1	0	18,000	0,05904	0,06376	0,06400	0,18
1	0,06375	19,000	0,05721	0,06179	0,06190	0,09
1	0,13070	20,000	0,05543	0,05987	0,06014	0,23
1	0,20228	21,000	0,05366	0,05796	0,05799	0,03
1	0,28063	22,000	0,05187	0,05602	0,05609	0,06
1	0,36935	23,000	0,05000	0,05400	0,05398	-0,02
1	0,47549	24,000	0,04795	0,05179	0,05171	-0,07
1	0,61765	25,000	0,04549	0,04913	0,04889	-0,24
1	1	26,000	0,04007	0,04327	0,04310	-0,20

На рис. 3 показан график зависимости характеристик $\beta_{\max}$ и $1.08\beta_c$ от величины параметра γ, который нелинейным образом соединяет в себе оба варьируемых параметра J_4 и J_5. Характерный изгиб графика происходит в районе значения $\gamma = 18$, где заканчивается варьирование параметра J_4 (достигшего максимального значения 1), и начинается варьирование параметра J_5. Видно, что экспериментальные значения $\beta_{\max}$ ложатся в точности на прихотливо изогнутую кривую.

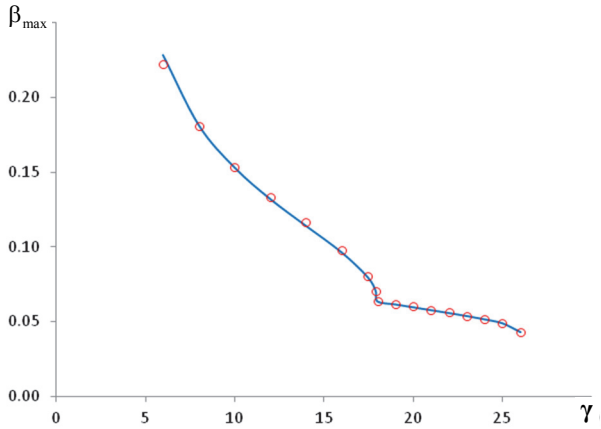

Рис. 3. Критические значения обратной температуры:
кружки – эксперимент $\beta_{\max}$, сплошная линия – $1.08\beta_c$

4. Заключение

Метод *n*-окрестностей продемонстрировал эффективность при исследовании модели Изинга с наращиванием числа соседей, взаимодействие с которыми учитывается. Формулы типа (8) и (9), выражающие критическую температуру через параметры решетки, по-видимому не имеют аналогов.

Из результатов для кубической решетки следует, что значение корректирующего множителя, совмещающего экспериментальные точки с теоретической кривой, зависит от размерности задачи: чем больше число спинов, тем лучше согласие эксперимента с теорией. Мы убеждены, что компьютерный эксперимент с числом спинов, скажем, $N = 128 \times 128 \times 128$ еще больше приблизит экспериментальные значения к теоретическим (9). Ду-

мается, то же самое справедливо и для планарной модели, для которой корректирующий множитель имеет слишком большое значение 1,3. Необходимо на 1-2 порядка увеличить размерность задачи, перейдя от решетки 100×100 , скажем, к решетке 1000×1000 . Есть основания полагать, что величина корректирующего множителя станет заметно ближе к 1.

Работа выполнялась при поддержке грантом РФФИ 18-07-00750.

Список литературы

1. Hertz J., Krogh A., Palmer R. Introduction to the theory of neural computation, Boston, Addison-Wesley. 1991.

2. Крыжановский Б.В., Литинский Л.Б. Обобщенное уравнение Брэгга-Вильямса для систем с произвольным дальнодействием // ДАН. 2014. Т. 459. № 6. С. 1–5.

3. Kryzhanovsky B., Litinskii L. Applicability of n-vicinity method for calculation of free energy of Ising model // Physica A. 2017. Vol. 468. P. 493–507.

4. Бэкстер Р. Точно решаемые модели статистической физики. М.: Мир, 1985.

5. Häggkvist R., Rosengren A., Lundow P.H., Markström K., Andren D., Kundrotas P. // On the Ising model for the simple cubic lattice. Advances in Physics. 2007. Vol. 56. No. 5. P. 653–755.

6. Lundow P.H., Markstrom K. The critical behavior of the Ising model on the 4-dimensional lattice // Phys. Rev. E. 2009. Vol. 80. P. 031104.

7. Lundow P.H., Markstrom K. The discontinuity of the specific heat for the 5D Ising model // Nuclear Physics B. 2015. Vol. 895. P. 305–318.

8. Kryzhanovsky B., Litinskii L. Phase transition in 2D Ising model with NN interaction // J. of Physics: Conference Series. 2019. Vol. 1391. P. 012077.

А.Н. МАЦУКАТОВА[1,2], А.В. ЕМЕЛЬЯНОВ[1], А.А. МИННЕХАНОВ[1], Б.С. ШВЕЦОВ[1,2], Д.А. САХАРУТОВ[1], А.А. НЕСМЕЛОВ[1], В.А. ДЕМИН[1], В.В. РЫЛЬКОВ[1,4], П.А. ФОРШ[1], С.Н. ЧВАЛУН[1,3], П. К. КАШКАРОВ[1,2,5]

[1]Национальный исследовательский центр «Курчатовский институт», Москва
[2]Московский государственный университет им. М.В. Ломоносова
[3]Институт синтетических полимерных материалов им. Н.С. Ениколопова РАН, Москва
[4]Фрязинский филиал Института радиотехники и электроники им. В.А. Котельникова РАН
[5]Санкт-Петербургский государственный университет
an.matcukatova@physics.msu.ru

ЭФФЕКТЫ ВТОРОГО ПОРЯДКА В МЕМРИСТОРАХ НА ОСНОВЕ ПОЛИ-*П*-КСИЛИЛЕНА*

Исследованы эффекты резистивного переключения 2-го порядка в мемристорах на основе чистого поли-п-ксилилена (PPX) и PPX с наночастицами серебра. Обнаружено уменьшение времени переключения, вызванное эффектами 2-го порядка, при предварительном разогреве мемристора электрическими импульсами. Полученные результаты указывают на возможность использования обнаруженных эффектов при создании нейроморфных вычислительных систем.

Ключевые слова: *мемристор, эффекты второго порядка, органическая электроника, поли-п-ксилилен.*

Введение

В последнее время существенно вырос интерес к разработке и созданию биоподобных *нейроморфных вычислительных систем* (НВС), что обусловлено их чрезвычайно низким энергопотреблением и высокой вычислительной эффективностью в решении так называемых антропоморфных задач (распознавание образов, текста и речи, принятие решений, обобщение, предсказание и т.д.) [1]. Ключевую роль в построении НВС играют *синапсы* (контакты между *нейронами*), которые могут эффективно моделироваться

* Данная работа выполнена при частичной поддержке РФФИ (проекты № 18-37-20014, 20-07-00696, 18-29-19047) и Фонда развития теоретической физики и математики «БАЗИС» (№19-2-6-57-1) с использованием оборудования ресурсных центров НИЦ «Курчатовский институт».

мемристивными элементами, способными под действием электрических импульсов изменять свое сопротивление в некотором окне между *высокоомным* (R_{OFF}) и *низкоомным* (R_{ON}) резистивными состояниями и сохранять его в течение длительного времени [2, 3].

Обычно мемристор представляет собой конденсаторную структуру металл-диэлектрик-металл (МДМ), в которой переключение между резистивными состояниями происходит в объеме диэлектрика или на его контакте с металлом [3]. Преимуществом мемристоров являются: их высокая масштабируемость (до ~ 2 нм), низкое энергопотребление при записи/считывании информации (до ~ 10 фДж), энергонезависимое хранение состояния более 10 лет, высокое быстродействие (< 1 нс) и совместимость с КМОП-технологией [4, 5]. За прошедшее десятилетие были продемонстрированы мемристоры на основе различных материалов, как неорганических (TiO_2, ZrO_2, HfO_2, нанокомпозитов [6–9]), так и органических (например, полианилина [10]). Последние не уступают неорганическим по основным характеристикам; более того, они дешевле в производстве, биосовместимы и могут быть сформированы на гибких подложках [11].

Одним из перспективных типов мемристоров являются мемристоры, *резистивное переключение* (РП) в которых проходят по механизму *электрохимической металлизации* (electrochemical metallization, ECM). РП в таких мемристорах обусловлено образованием проводящего металлического мостика между верхним и нижним электродами МДМ структуры [12]. РП большинства мемристивных структур по ECM механизму переключения можно объяснить в рамках модели, основанной на изменении одной переменной состояния w - размера (диаметра или длины) проводящего мостика [13]. Такая переменная состояния w называется переменной 1-го порядка, а мемристоры, функционирующие в рамках данной модели, называются *мемристорами 1-го порядка*. С другой стороны, в недавних исследованиях были обнаружены так называемые *мемристоры 2-го порядка* [13]. Переменная состояния 2-го порядка такого мемристора не определяет его сопротивление напрямую, но влияет на динамику изменения переменной w во время электрической стимуляции и некоторое время после нее. Для филаментного механизма РП за переменную 2-го порядка можно принять температуру проводящего мостика [14]. Тогда изменение состояния мемристора при приложении некоторого импульса будет зависеть от степени его разогрева предыдущими импульсами. Данная модель является более биоподобной, так как синапс в биологической системе контролируется переменной 2-го порядка, а именно постсинаптической концентрацией ионов кальция [15]. Изменение синаптического веса в этом случае зависит не только от амплитуды и длительности поступающих на него импульсов, но

и от их частоты. Таким образом, переменная 2-го порядка становится важным фактором, ответственным за динамические процессы в биологических системах.

Перспективным органическим материалом для создания мемристоров представляется *поли-n-ксилилен* (PPX). Мемристоры на основе PPX демонстрируют характеристики, приемлемые для нейроморфных приложений (многоуровневое РП при отношении $R_{OFF}/R_{ON} > 10^3$, времена хранения резистивных состояний более 10^4 с) [16]. Более того, стохастичность РП таких мемристоров может быть уменьшена путем нанесения барьерного слоя графена на слой PPX [17] или внедрения в слой PPX металлических наночастиц, например, серебра (PPX-Ag) [18]. Была продемонстрирована также возможность использования мемристоров на основе PPX для построении простейших НВС [19], способных к обучению по механизму пластичности, зависящей от времени прихода импульсов (*spike-timing-dependent plasticity*, STDP) [20]. Однако, в данных структурах до сих пор не были исследованы мемристивные эффекты 2-го порядка, что и инициировало настоящую работу.

Исследуемые образцы и методика измерений

В работе изучались характеристики двух типов мемристивных МДМ структур на основе PPX-Ag или PPX, которые осаждались на стеклянную подложку, порытую слоем оксида индия-олова (ITO). Последний выступал в роли нижнего электрода. Верхний металлический электрод был получен термическим напылением Ag или Cu через теневую маску с размером отверстий 0,2×0,5 мм^2. Далее исследуемые структуры будут обозначаться как Cu/PPX/ITO и Ag/PPX-Ag/ITO.

Мемристивные характеристики структур исследовались с использованием аналитической зондовой станции Cascade Microtech PM5. Импульсы напряжения подавались на верхний электрод (при заземленном нижнем электроде) от источника-измерителя National Instruments PXIe-4140. При измерениях *вольт-амперных характеристик* (ВАХ) устанавливалось ограничение по току на уровне +1 мА и –50 мА для предотвращения теплового разрушения мемристоров.

Для изучения эффектов РП 2-го порядка на верхний электрод МДМ структур импульсы напряжения подавались от генератора Keysight 81150A (вставка к рис. 1). Контроль изменения сопротивления МДМ структуры осуществлялся по напряжению падения на последовательно подключенном к ней нагрузочном сопротивлении R = 50 Ом с помощью 2-х канального осциллографа Agilent Technologies MSO6052A. Сигнал от генератора

подавался на один из его входов, а на второй - сигнал с нагрузочного сопротивления. Оба входа осциллографа были заземлены через сопротивления 50 Ом.

Все эксперименты программировались в среде LabView и выполнялись при комнатной температуре.

Экспериментальные результаты

На рис. 1 представлен типичный набор циклических ВАХ мемристивных структур Ag/PPX-Ag/ITO и их медианная кривая. Последняя демонстрирует характерное поведение мемристора: при приложении положительного напряжения U_{set} мемристор переводится из состояния R_{OFF} в состояние R_{ON}, а отрицательного напряжения U_{reset} – обратно в состояние R_{OFF}. Напряжения переключения U_{set} и U_{reset} варьируются от цикла к циклу и от образца к образцу в силу стохастической природы РП. Переключение между резистивными состояниями мемристивной структуры Ag/PPX-Ag/ITO происходит предположительно по ECM механизму [18]. При приложении положительного напряжения к структуре образуется металлический мостик из ионов Ag, мигрирующих из верхнего электрода через слой PPX, а при приложении напряжения обратной полярности мостик разрушается в своей самой тонкой части из-за джоулева разогрева и/или эффекта электронного ветра и структура переключается состояние R_{OFF}. Наночастицы Ag, внедренные в слой PPX, формируют перколяционные цепочки, которые концентрируют электрическое поле и задают направление образования проводящего мостика, что стабилизирует РП данных мемристоров. Аналогичный механизм РП наблюдается и в мемристивных структур Cu/PPX/ITO. В этом случае, однако, структуры демонстрируют бóльшие значения U_{set}, U_{reset} и бóльший их разброс из-за отсутствия металлических наночастиц в слое PPX.

Для исследования влияния на РП предварительного разогрева мемристора на него подавались парные импульсы: разогревающий импульс большой длительности t_h и переключающий импульс малой длительности t_s с задержкой между ними длительностью t_d (рис. 2).

Для исключения эффектов 1-го порядка полярности разогревающего и переключающего импульсов были противоположными. Амплитуда переключающего импульса U_s была выбрана недостаточной для переключения мемристора из одного состояния в другое одиночным импульсом.

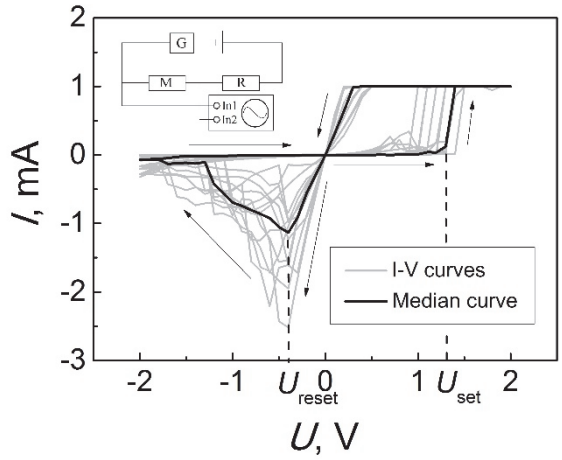

Рис. 1. ВАХ мемристивной структуры Ag/PPX Ag/ITO. На вставке: схема эксперимента для изучения эффектов РП 2-го порядка, где G – генератор, M – мемристор, R – нагрузочное сопротивление, In1 и In2 – входы осциллографа

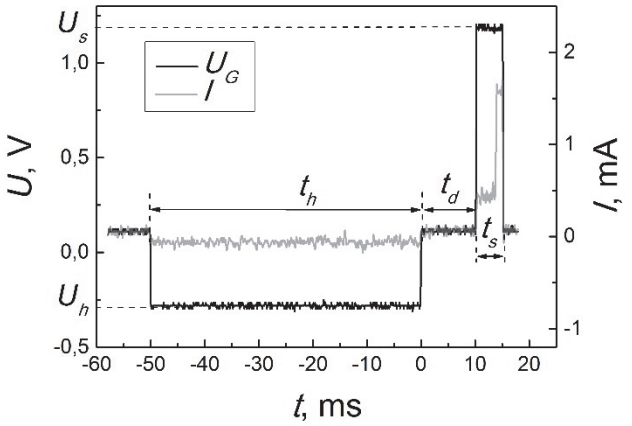

Рис. 2. Пример зависимости напряжения (левая шкала по оси Y) на первом входе осциллографа и силы тока (правая шкала по оси Y) на его втором входе от времени в эксперименте по изучению эффектов РП 2-го порядка. На мемристор последовательно подаются разогревающий импульс длительностью t_h и амплитудой U_h и переключающий импульс длительностью t_s и амплитудой U_s с задержкой между ними длительностью t_d

Эффект РП 2-го порядка был обнаружен как в структуре Cu/PPX/ITO (рис. 3), так и в Ag/PPX-Ag/ITO (аналогичные результаты, здесь не показаны). РП из состояния R_{OFF} в R_{ON} не наблюдается для $t_d \geq 5$ мс (рис. 3*a*), однако, при $t_d \leq 1$ мс положительный импульс напряжения переключает мемристор в низкоомное состояние R_{ON} (рис. 3*b*). Полученные результаты можно объяснить достаточно быстрым спадом локальной температуры T_l после воздействия на мемристор разогревающего импульса: при $t_d \geq 5$ мс температура успевает релаксировать практически к первоначальному значению и второй импульс не переключает мемристор. Однако, при $t_d \leq 1$ мс величина T_l мемристора не успевает измениться, что инициирует образование проводящего мостика после воздействия импульса U_s. Аналогичное поведение можно наблюдать для обратной полярности парных импульсов при РП из состояния R_{ON} в R_{OFF} (рис. 3*c* и 3*d*). Таким образом, можно сделать вывод о существенном влиянии разогрева током (вне зависимости от его полярности) при достаточно малых t_d на РП изучаемых структур.

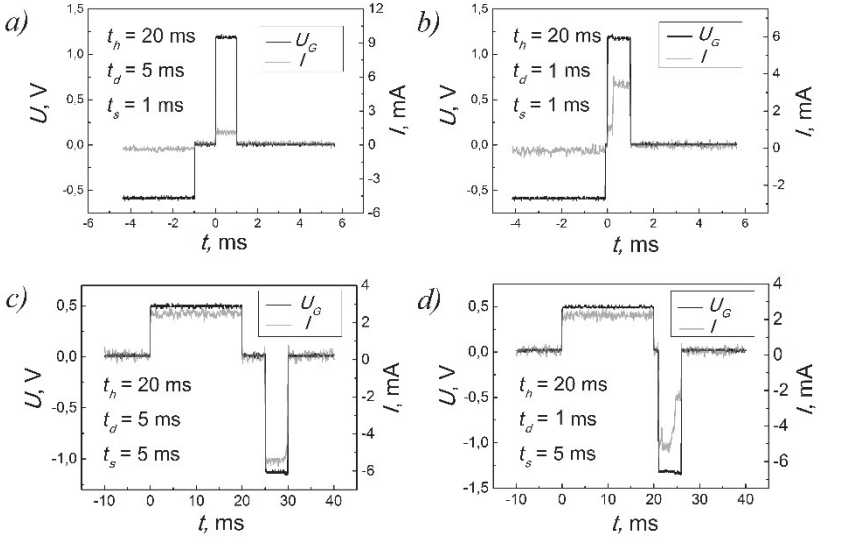

Рис. 3. Зависимость напряжения (левая шкала) и тока (правая шкала) от времени в эксперименте по изучению эффектов РП 2-го порядка для мемристивной структуры Cu/PPX/ITO. *a*, *b* – U_h = -0,6 В, U_s = 1,2 В; *c*, *d* – U_h = 0,5 В, U_s = -1,3 В; остальные используемые параметры импульсов указаны на графиках

Дополнительно для РП из состояния R_{ON} в R_{OFF} исследовалось влияние длительности и амплитуды разогревающего импульса при постоянном t_d = 1 мс (рис. 4). При значении t_h < 20 мс парные импульсы не переключают мемристор в состояние R_{OFF} (рис. 4*a*). Напротив, при длительности разогревающего импульса $t_h \geq 20$ мс переключение мемристора наблюдается (рис. 3*d* и 4*b*). При постоянной t_h = 20 мс, удавалось наблюдать РП при U_h = 0,4–0,6 В (рис. 3*d*), в то время как для меньших и бо́льших амплитуд разогревающего импульса РП не наблюдались (рис. 4*c* и 4*d*). Это может быть связано с тем, что для фиксированной длительности t_h и величине U_h < 0,4 В разогрев мемристивной структуры оказывается недостаточным, а импульс амплитудой U_h > 0,6 В закрепляет мемристор в проводящем состоянии. Таким образом, можно сделать вывод о том, что для исследованных мемристоров существует оптимальная амплитуда и длительность разогревающего импульса для проявления эффектов второго порядка.

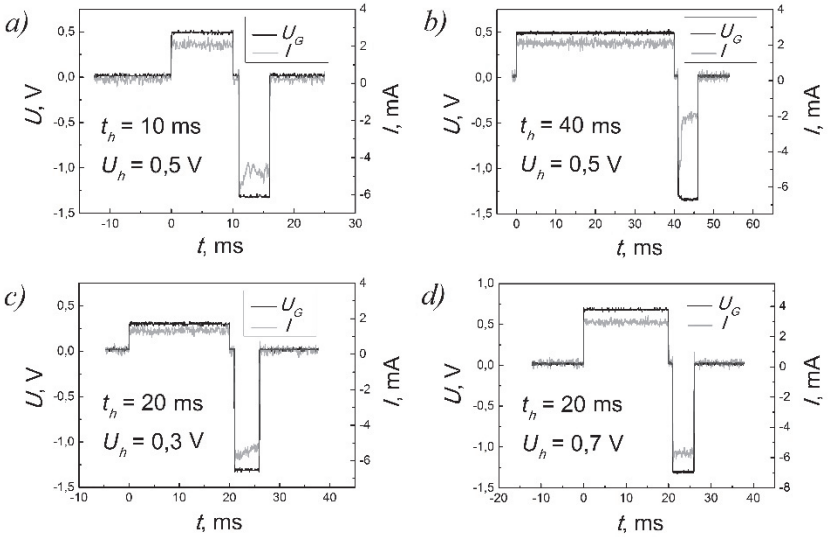

Рис. 4. Зависимость напряжения (левая шкала) и тока (правая шкала) от времени в эксперименте по изучению эффектов РП 2-го порядка для мемристивной структуры Cu/PPX/ITO. Используемые параметры: t_d = 1 мс, t_s = 5 мс, U_s = -1,3 В, остальные параметры импульсов указаны на графиках

Кроме экспериментов с парными импульсами проводился эксперимент по РП структуры Cu/PPX/ITO с помощью пакета переключающих импульсов: после одного длительного разогревающего импульса подавалась последовательность из 10 коротких переключающих импульсов с постоянной задержкой между ними длительностью t_d. Изменение сопротивления в данной последовательности имеет различный характер для различных t_d (рис. 5): для $t_d \geq 1$ мс переключение происходит постепенно, а для $t_d \leq 0{,}5$ мс РП происходит тем резче и быстрее, чем меньше t_d.

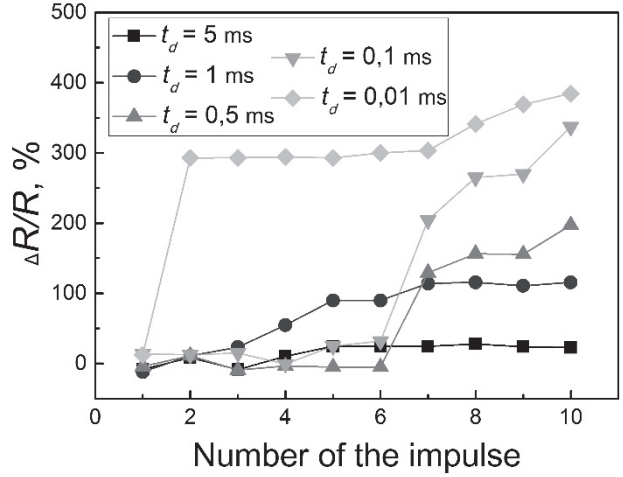

Рис. 5. Зависимость отношения изменения сопротивления к первоначальному сопротивлению от номера переключающего импульса для $t_h = 20$ мс, $t_s = 1$ мс и разных t_d при переключении мемристора Cu/PPX/ITO из состояния R_{ON} в R_{OFF}

Описанное выше влияние импульсов, инициирующих РП мемристора, а также влияние частоты переключающих импульсов на его РП можно объяснить эффектами локального разогрева, обусловливающими экспоненциально сильный рост (по закону Аррениуса) коэффициента диффузии ионов Ag, что ускоряет образование или разрыв проводящего мостика в МДМ структуре.

Заключение

Таким образом, в работе обнаружены проявления эффектов 2-го порядка в РП мемристивных структур Cu/PPX/ITO и Ag/PPX-Ag/ITO при их переключении парными импульсами: воздействие на мемристор разогревающего импульса ускоряло его РП при достаточно малом времени задержки между разогревающим и переключающим импульсами ($\leq$ 1 мс). Обнаружено также, что для мемристоров на основе PPX и PPX-Ag существует оптимальная амплитуда и длительность разогревающего импульса для проявления эффектов 2-го порядка. Аналогичные эффекты наблюдались в эксперименте с пакетом переключающих импульсов. Отметим, что мемристор 2-го порядка является более «биоподобным синапсом» и, следовательно, более предпочтительным при построении НВС, чем мемристор 1-го порядка, поскольку для изменения веса в этом случае важна не только амплитуда, но и частота спайковых импульсов [13].

Список литературы

1. Merrikh-Bayat F., Prezioso M., Chakrabarti B., Nili H., Kataeva I., Strukov D.B. Implementation of multilayer perceptron network with highly uniform passive memristive crossbar circuits // Nature Communications. 2018. Vol. 9. P. 2331.

2. Emelyanov A.V., Nikiruy K.E., Serenko A.V., Sitnikov A.V., Presnyakov M.Y., Rybka R.B., Sboev A.G., Rylkov V. V., Kashkarov P.K., Kovalchuk M.V., Demin V.A. Self-adaptive STDP-based learning of a spiking neuron with nanocomposite memristive weights // Nanotechnology. 2020. Vol. 31. P. 045201.

3. Ielmini D. Resistive switching memories based on metal oxides: Mechanisms, reliability and scaling // Semiconductor Science and Technology. 2016. Vol. 31. P. 063002.

4. Pi S., Li C., Jiang H., Xia W., Xin H., Yang J.J., Xia Q. Memristor crossbar arrays with 6-nm half-pitch and 2-nm critical dimension // Nature Nanotechnology. Springer US, 2019. Vol. 14. P. 35–39.

5. Jiang H., Han L., Lin P., Wang Z., Jang M.H., Wu Q., Barnell M., Yang J.J., Xin H.L., Xia Q. Sub-10 nm Ta Channel Responsible for Superior Performance of a HfO_2 Memristor // Scientific Reports. 2016. Vol. 6. P. 1–8.

6. Strukov D.B., Snider G.S., Stewart D.R., Williams R.S. The missing memristor found // Nature. 2008. Vol. 453. P. 80–83.

7. Герасимова С.А., Михайлов А.Н., Белов А.И., Королев Д.С., Горшков О.Н., Казанцев В.Б. Имитация синаптической связи нейроноподобных генераторов с помощью мемристивного устройства // Журнал Технической Физики. 2017. Т. 87. № 8. С. 1248–1254.

8. Исламов Д.Р., Гриценко В.А., Кручинин В.Н., Иванова Е.В., Заморянская М.В., Лебедев М.С. Эволюция проводимости и катодолюминесценции пленок оксида гафния при изменении концентрации вакансий кислорода // Физика твердого тела. 2018. Т. 60. № 10. С. 2006–2013.

9. Рыльков В.В., Николаев С.Н., Демин В.А., Емельянов А.В., Ситников А.В., Никируй К.Э., Леванов В.А., Пресняков М.Ю., Талденков А.Н., Васильев А.Л., Черноглазов К.Ю., Веденеев А.С., Калинин Ю.Е., Грановский А.Б., Тугушев В.В., Бугаев А.С. Транспортные, магнитные и мемристивные свойства наногранулированного композита $(CoFeB)_x(LiNbO)_{100-x}$ // Журнал экспериментальной и теоретической физики. 2018. Т. 153. № 3. С. 424–441.

10. Lapkin D.A., Emelyanov A.V., Demin V.A., Erokhin V.V., Feigin L.A., Kashkarov P.K., Kovalchuk M.V. Polyaniline-based memristive microdevice with high switching rate and endurance // Applied Physics Letters. 2018. Vol. 112. P. 043302.

11. Van De Burgt Y., Melianas A., Keene S.T., Malliaras G., Salleo A. Organic electronics for neuromorphic computing // Nature Electronics. Springer US, 2018. Vol. 1. No. 7. P. 386–397.

12. Wang W., Wang M., Ambrosi E., Bricalli A., Laudato M., Sun Z., Chen X., Ielmini D. Surface diffusion-limited lifetime of silver and copper nanofilaments in resistive switching devices // Nature Communications. Springer US, 2019. Vol. 10. P. 81.

13. Kim S., Du C., Sheridan P., Ma W., Choi S., Lu W.D. Experimental demonstration of a second-order memristor and its ability to biorealistically implement synaptic plasticity // Nano Letters. 2015. Vol. 15. No. 3. P. 2203–2211.

14. Kim S., Kim H.D., Choi S.J. Compact Two-State-Variable Second-Order Memristor Model // Small. 2016. No. 24. P. 3320–3326.

15. Mikheev V., Chouprik A., Lebedinskii Y., Zarubin S., Matveyev Y., Kondratyuk E., Kozodaev M.G., Markeev A.M., Zenkevich A., Negrov D. Ferroelectric Second-Order Memristor: research-article // ACS Applied Materials and Interfaces. American Chemical Society, 2019. Vol. 11. No. 35. P. 32108–32114.

16. Minnekhanov A.A., Shvetsov B.S., Martyshov M.M., Nikiruy K.E., Kukueva E.V., Presnyakov M.Y., Forsh P.A., Rylkov V.V., Erokhin V.V., Demin V.A., Emelyanov A.V. On the resistive switching mechanism of parylene-based memristive devices // Organic Electronics. Elsevier. 2019. Vol. 74. P. 89–95.

17. Chen Q., Lin M., Wang Z., Zhao X., Cai Y., Liu Q., Fang Y., Yang Y., He M., Huang R. Low Power Parylene-Based Memristors with a Graphene Barrier Layer for Flexible Electronics Applications // Advanced Electronic Materials. 2019. Vol. 5. No. 9. P. 1800852.

18. Мацукатова А.Н., Емельянов А.В., Миннеханов А.А., Сахарутов Д.А., Вдовиченко А.Ю., Камышинский Р.А., Демин В.А., Рыльков В.В., Форш П.А., Чвалун С.Н., Кашкаров П.К. Мемристоры на основе поли-п-ксилилена с внедренными наночастицами серебра // Письма в Журнал Технической Физики. 2020. Т. 46. № 2. С. 25–28.

19. Minnekhanov A.A., Emelyanov A.V., Lapkin D.A., Nikiruy K.E., Shvetsov B.S., Nesmelov A.A., Rylkov V.V., Demin V.A., Erokhin V.V. Parylene Based Memristive Devices with Multilevel Resistive Switching for Neuromorphic Applications // Scientific Reports. 2019. Vol. 9. P. 10800.

20. Швецов Б.С., Емельянов А.В., Миннеханов А.А., Никируй К.Э., Несмелов А.А., Мартышов М.Н., Рыльков В.В., Демин В.А. Синаптическая пластичность мемристивных структур на основе поли-пара-ксилилена // Российские нанотехнологии. 2019. Т. 14. № 1–2. С. 85–91.

V.V. KUZNETSOV, V.A. MOSKALENKO, N.YU. ZOLOTYKH
Institute of Information Technologies, Mathematics and Mechanics
Lobachevsky State University of Nizhni Novgorod
Email: {vladislav.kuznetsov,viktor.moskalenko,nikolai.zolotykh}@itmm.unn.ru

ELECTROCARDIOGRAM GENERATION AND FEATURE EXTRACTION USING A VARIATIONAL AUTOENCODER*

We propose a method for generating an electrocardiogram (ECG) signal for one cardiac cycle using a variational autoencoder. Our goal was to encode the original ECG signal using as few features as possible. Using this method we extracted a vector of new 25 features, which in many cases can be interpreted. The generated ECG has quite natural appearance. The low value of the Maximum Mean Discrepancy metric, 3.83×10^{-3}, indicates good quality of ECG generation too. The extracted new features will help to improve the quality of automatic diagnostics of cardiovascular diseases. Generating new synthetic ECGs will allow us to solve the issue of the lack of labeled ECG for using them in supervised learning.

Keywords: *feature extraction, variational autoencoder, ECG, electrocardiography*.

1. Introduction

All the experience gained by the machine learning community shows that the quality of the decision rule largely depends on what features of samples are used. The better the feature description, the more accurately the problem can be solved. The features are used to require their interpretability, since it means the adequacy of the features to the real-world problem.

The traditional way to build a good feature description was to use an ex- pert knowledge. Specialists in a particular subject area offer various methods for constructing the feature descriptions, which are then tested in solving practical problems. Another approach for constructing a good feature description is automatic feature extraction (also called dimensionality reduction).

* The work is supported by the Ministry of Education and Science of Russian Federation (project 14.Y26.31.0022).

There is a lot of methods for automatic feature extraction, such as principal component analysis, independent component analysis, principal graphs and manifolds, kernel methods, autoencoders, embeddings etc. Among the most powerful and perspective approaches, we mention principal graphs and manifolds [4] and methods used deep learning [2, 11].

Variational autoencoders (VAE) are neural networks which allow you to encode the source information and later on the basis of the encoded information to obtain a specific object, allow to further generate similar objects but from a random set of coded characteristics. Here we examine image one of these meth- ods [7, 10], for the problem of automatic electrocardiogram (ECG) processing.

The electrocardiogram is a record of the electrical activity of the heart, obtained with the help of electrodes located on the human body. Electrocardiography is one of the most important methods in cardiology. Schematic representation of the main part of ECG is shown in Fig. 1. One cardiac cycle (the performance of the heart from the beginning of one heartbeat to the beginning of the next) contains P, T, U waves and QRS complex, consisting of Q, R and S peaks. The size, shape, location of these parts give great diagnostic information about the work of the heart and about the presence/absence of certain diseases.

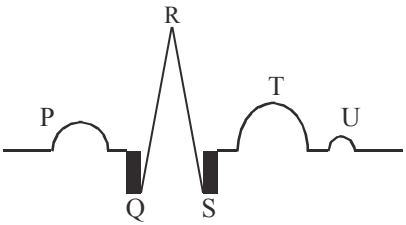

Fig. 1. Schematic representation of main parts of the ECG signal for one cardiac cycle: P, T, U waves and QRS complex, consisting of Q, R and S peaks

Recently, machine learning (especially deep learning) methods have been widely used for automatic ECG analysis. See the recent review [5]. The application tasks include ECG segmentation, disease detection, sleep staging, biometric human identification, denoising, and the others [5]. A variety of classical and new methods are used. Among them there are discriminant analysis, decision trees, support vector machine, fully-connected and convolutional neural networks, recurrent neural networks, generative adversarial networks, autoencoders etc [5, 13].

From our point of view, the most interesting and fruitful directions in applying deep learning methods to ECG analysis are the generation of synthetic ECG

and automatic extraction of new interpretable features. Several works [1, 6, 14] are devoted to the problem of ECG generation. The authors of those papers used different variants of generative adversarial networks (GANs) [3]. The best results concerning the ECG generation were obtained in [6]. The authors report on the Maximum Mean Discrepancy (MMD) metric equals to 1.05×10^{-3}.

Our approach in generating ECG is based on VAE. We propose a neural network architectures for an encoder and a decoder for generating synthetic ECGs and extracting new features. The generated synthetic ECGs look quite natural. MMD equals to 3.83×10^{-3}, which is worse than the value obtained in [6], but we note that the comparison of these two metric values is not absolutely correct, since the values were obtained on different training sets and for solving similar, but different problems.

The main advant age of our work is our proposal of the method for extracting new features. We are planning to encode dat a on the signal with the smallest possible number of features. Our experiments show that these features are quite interpretable. This fact allows us to hope that using these features will help to improve the quality of automatic diagnostics of cardiovascular diseases. Generating new synthetic ECGs will allow us to fix the issue of the lack of labeled ECG f or using them in supervised learning.

2. Algorithm

2.1. Preprocessing

Our original ECG is a 10-second 12-lead signal with a frequency of 500 Hz. Using the segmentation algorithms described in [12], we determine beginnings and endings of all P and T waves and all the picks R. Then, we do the step forward and backward from the R pick at an equal distance. Thus, we obtain the set of cardiac cycles, each of which of vectors length is 400 (800 ms).

2.2. Neural network architecture. Encoder

A variational autoencoder [7, 10] consists of an encoder and a decoder. We prop ose the following architecture for them. The encoder consists of a convolutional and a fully connected blocks. The architecture of the encoder is presented in Fig. 2. The input vector of length 400 is fed to the input of the encoder. The next step is branching into a fully connected and convolutional chains.

The convolutional chain (at the t op of the circuit in Fig. 2) consists of 4 series-connected blocks, each of which consists of a convolution layer , a batch

normalization layer, a ReLU activation function and a MaxPooling layer. In addition, we have another convolution layer. At the output of this block we get 25 neurons.

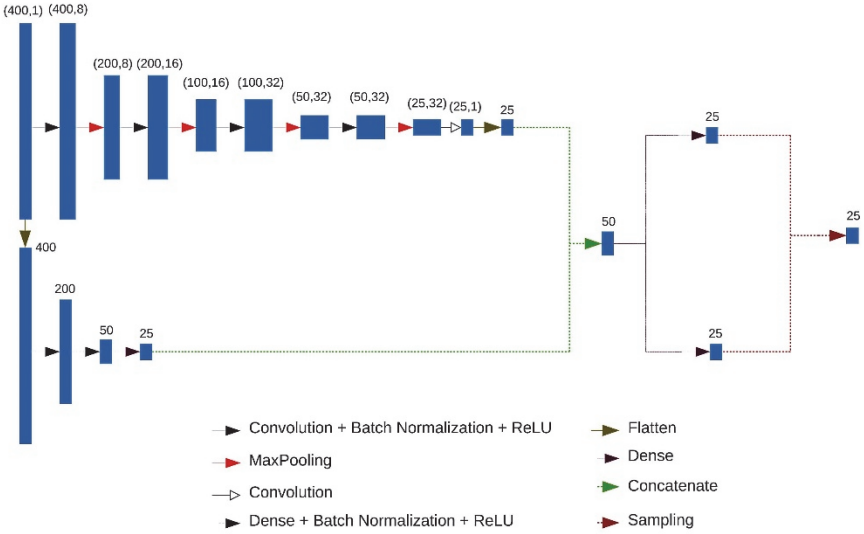

Fig. 2. Encoder architecture

The fully connected chain of the encoder (at the bottom of the circuit in Fig. 2) consist s of 3 fully connected (dense) layers, interconnected by a batch normalization and ReLU activation functions. At the output of the last fully connected layer we have 25 neurons.

The outputs of the convolutional and fully connected chains are concatenated, which gives us a vector of length 50. Using two fully connected layers we get two 25-dimensional vectors which are interpreted as a vector of means and a vector of logarithms of variances for 25 normal distributions (or for one 25-dimensional normal distribution with a diagonal covariance matrix). The output of the encoder is a vector of length 25 in which each component is sampled from those normal distributions with specified means and variance.

We will interprete this 25-dimensional vector as a vector of new features sufficient to describe and restore with small error the one cardiac cycle.

As the loss function, the Kullback–Leibler distance

$$D_{KL}(P \| Q) = \int_X p \log \frac{p}{q} d\mu \qquad (1)$$

is used. Due to this fact those 25 new features are of normal distribution. In (1) μ is any measure on X for which there exists a function absolutely continuous with respect to μ: $p = \frac{dP}{d\mu}$ and $q = \frac{dQ}{d\mu}$, P is the initial distribution, Q is the new distribution we have obtained.

2.3. Neural network architecture. Decoder

The architecture of the decoder is presented in Fig. 3. As an input, the decoder accepts the 25-dimensional vector of features. Then, similarly to the encoder, branching into convolutional and fully connected chains occurs.

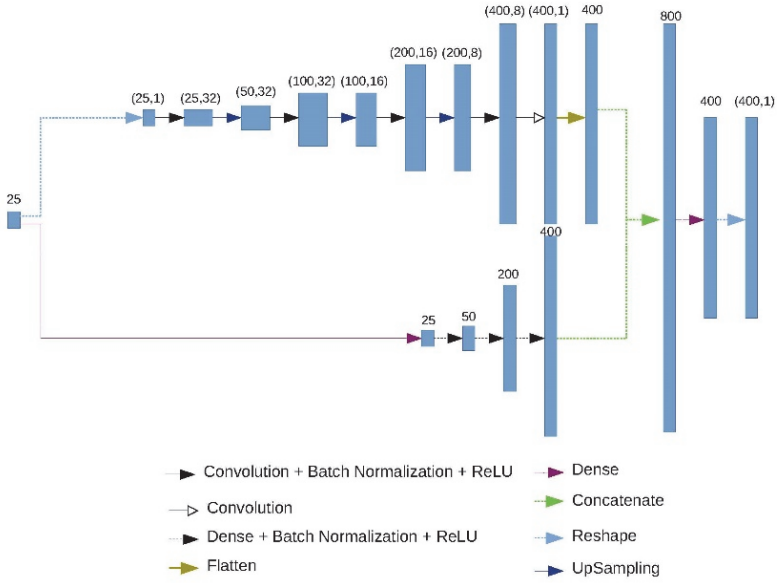

Fig. 3. Decoder architecture

The fully connected chain (at the bottom of the circuit in Fig. 3) con- sists of 4 blocks, each of which contains a fully connected (dense) layer, batch normalization layer and the ReLU activation function.

The convolutional chain (at the top of the circuit in Fig. 3) performs a deconvolution. It consists of 4 blocks which include a convolutional layer, a batch normalization layer, and ReLU activation function, followed by an upsampling layer.

As a result of the convolutional and the fully connected chains, we get 400 neurons from each. Then, we concatenate two results, obtaining 800 neurons. Using a dense layer we get 400 neurons which represent the restored ECG.

As a loss function for the output of the decoder, we use the mean squared error.

3. Experimental results

As a practise test, we use 2033 10-second ECG signals of frequency 500 Hz [8, 9]. We process them according to the principles as described above (see sect. 2.1) and train our network on the obtained 252636 cardiac cycles. Examples of those cardiac cycles are presented in Fig. 4.

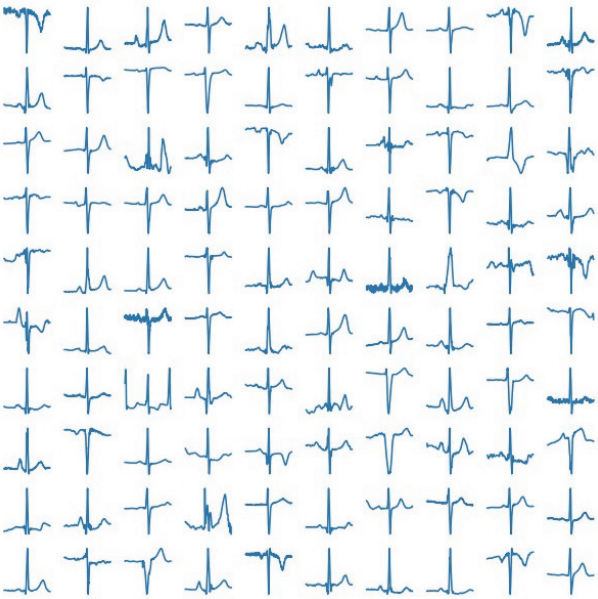

Fig. 4. Examples of cardiac cycles in the training sets

After having trained the network we may test the decoder by supplying random (generated according to the standard normal distribution) numbers to its input. The examples of the produced results are given in Fig. 5. These synthetic generated ECG looks quite natural.

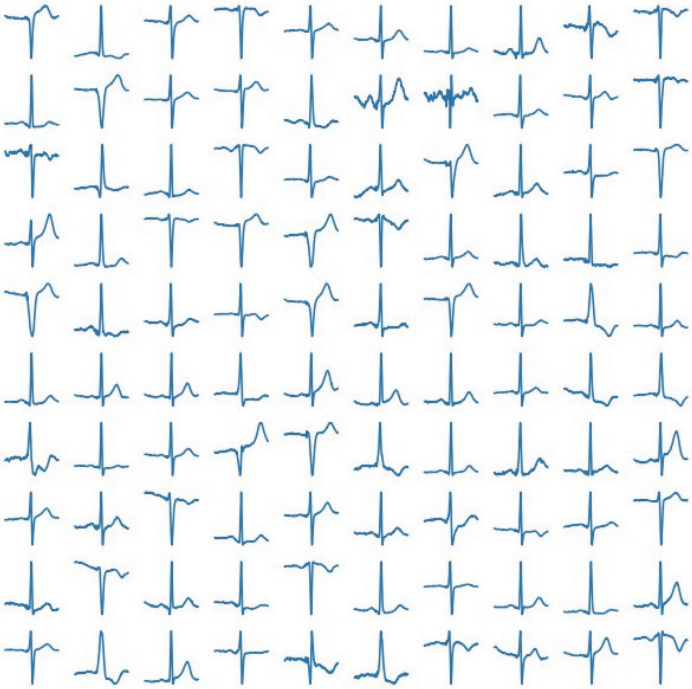

Fig. 5. Examples of generated cardiac cycles.

To evaluate our results we calculated the Maximum Mean Discrepancy (MMD) metric (see [6]) on the set of 3000 generated ECG. The value of MMD is equal to 3.83×10^{-3}. Keep it in mind that the best value of MMD obtained in [6] by GAN is 1.05×10^{-3}. The value obtained by us is slightly less than [6]. However, it shouldn't be argued that this metric is a reference. There are no illustrations [6] confirming the correctness of the result. We note that the comparison of these two metric values is not absolutely correct, since these values were obtained on different training sets and for solving similar, but different problems. Unfortunately, the papers [1, 14] don't contain (applicable to our problem) values of similar metrics.

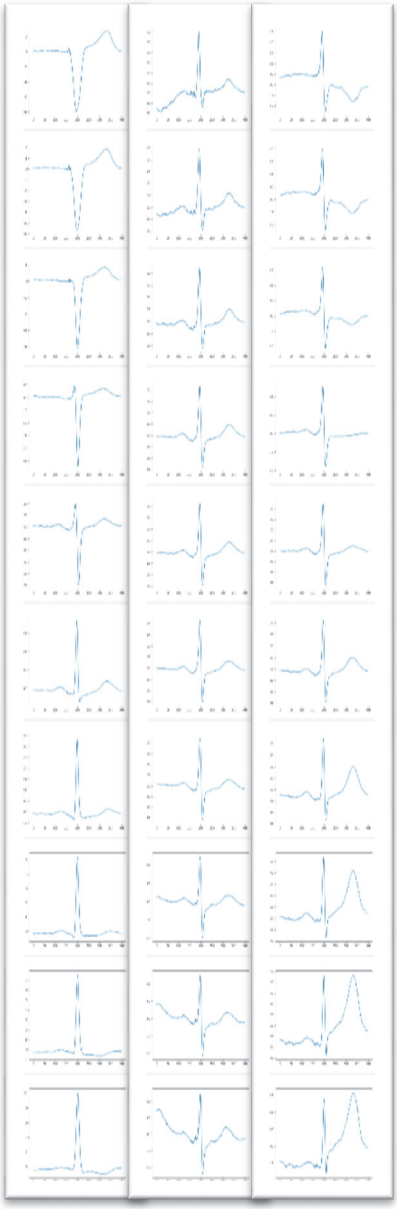

Fig. 6. Examples of ECG generated when a parameter is varying. Each column correspond to the set of fixed 24 features and varying other feature (6, 14 and 24 feature respectively)

Interesting results were obtained when generating ECG with a varying feature. Some generated ECG signals are presented in Fig. 6. 24 features were fixed for each test when the remaining feature was changing. It was possible to find a parameter responsible, for example, for the height of the wave T, the depression of the ST wave, etc. Thus, in some cases, the extracted features may be interpreted, which also confirms the high quality of the constructed feature description.

4. Conclusions and further research

In this paper, we proposed a neural network (variational autoencoder) architecture that is used to generate an ECG corresponding to a single cardiac cycle. Our method generates synthetic ECGs using rather small number (25) of features, with completely natural appearance, which can be used to augment the training sets in supervised learning problems involving ECG. Our method allowed us to extract new features that accurately characterize the ECG. Experiments show that the extracted features are usually amenable to good interpretation.

We plan to use our approach to generate the entire ECG, not just one cardiac cycle. We will also use the extracted features to improve the quality of automatic diagnosis of cardiovascular diseases.

References

1. Golany T., Radinsky K. PGANs: Personalized Generative Adversarial Networks for ECG Synthesis to Improve Patient-Specific Deep ECG Classification. Proceedings of the AAAI Conference on Artificial Intelligence. 2019. 33.

2. Goodfellow I., Bengio Y., Courville A. Deep learning. MIT press, 2016.

3. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative Adversarial Networks. Proceedings of the International Conference on Neural Information Processing Systems (NIPS 2014). 2014. 2672–2680.

4. Gorban A.N., K´egl B., Wunsch D.C., Zinovyev A.Y. (Eds.) Principal manifolds for data visualization and dimension reduction. Springer, Berlin, 2008.

5. S. Hong, Y. Zhou, J. Shang, C. Xiao, J. Sun. Opportunities and Challenges in Deep Learning Methods on Electrocardiogram Data: A Systematic Review. arXiv:2001.01550, 2019.

6. Delaney A.M., Brophy E., Ward T.E. Synthesis of Realistic ECG using Generative Adversarial Networks. arXiv:1909.09150, 2019.

7. C. Doersch. Tutorial on variational autoencoders. arXiv preprint arXiv:1606.05908, 2016.

8. Kalyakulina A.I., Yusipov I.I., Moskalenko V.A., Nikolskiy A.V., Kozlov A.A., Kosonogov K.A., Zolotykh N.Y., Ivanchenko M.V. LU electrocardiography database: a new open-access validation too for delineation algorithms. arXiv:1809.03393, 2018.

9. Kalyakulina A.I., Yusipov I.I., Moskalenko V.A., Nikolskiy A.V., Kozlov A.A., Zolotykh N.Y., Ivanchenko M.V. Finding Morphology Points of Electrocardiographic-Signal Waves Using Wavelet Analysis. Radiophysics and Quantum Electronics. 2019. 61(8–9), 689–703.

10. Kingma D.P., Welling M. Auto-encoding variational Bayes. arXiv preprint arXiv:1312.6114, 2019.

11. LeCun Y., Bengio Y., Hinton G.E. Deep learning. Nature. 2015. 521 (7553), 436–444.

12. Moskalenko V., Zolotykh N., Osipov G. Deep Learning for ECG Segmentation. International Conference on Neuroinformatics, Springer, Cham. 2019. 246–254.

13. Schläpfer J., Wellens H.J. Computer-interpreted electrocardiograms: benefits and limitations. Journal of the American College of Cardiology. 2017. 70 (9), 1183–1192.

14. Zhu F., Ye F., Fu Y., Liu Q., Shen B. Electrocardiogram generation with a bidirectional LSTM-CNN generative adversarial network. Scientific reports. 2019. 9 (1), 1–11.

И.В. ТИХОНОВ, А.А. ЖДАНОВ

Московский физико-технический институт
(национальный исследовательский университет)
tikhonov.iv@phystech.edu, alexander.a.zhdanov@gmail.com

АЛГОРИТМ ДИНАМИЧЕСКОГО СЛЕЖЕНИЯ ЗА ОБЪЕКТАМИ В РЕЖИМЕ РЕАЛЬНОГО ВРЕМЕНИ

Рассматривается задача прогнозирования расположения объекта (координаты ограничивающей рамки) на основе результатов распознавания, полученных на предыдущих шагах и представлений о работе зрительного анализатора человека. Решение предполагает внедрение результатов прогнозирования в архитектуру системы распознавания и интеллектуальное отслеживание траекторий объекта в режиме реального времени. Помимо этого, ставится задача создания словаря сформированных образов на языке признаков.

Ключевые слова: *трекинг, отслеживание объекта, прогнозирование, машинное зрение, нейронные сети.*

Введение

Рассмотрим видеопоток, представленный последовательностью некоторого числа изображений в секунду (измеряется fps – англ. frames per second), с набором интересующих нас объектов. Выбор отслеживаемого объ-

екта реального мира зависит от поставленной задачи. Например, это превышающий скоростной режим автомобиль, уникальный посетитель магазина, заблудившийся в лесу человек или нарушитель охраняемой зоны.

Рассмотрен один из многих примеров применения отслеживания объектов в режиме реального времени (далее будет использоваться термин *трекинг*). Компания [1] локально отслеживает чрезвычайные ситуации в домах пожилых людей, что позволяет существенно снизить стоимость медицинских услуг специалистов по уходу. Трекинг может также быть полезен для оптимизации хранения видеофайлов: платформа видеохостинга YouTube использует [2] отслеживание статического фона для сохранения только движущихся объектов.

Задача трекинга – одна из классических задач компьютерного зрения, это задача классификации объекта (с выводом точности распознавания) и его локализации с помощью ограничивающей рамки (bounding box, далее будет использоваться термин *рамка*). Существует множество исторических подходов к решению: трекинг контуров, определение статического фона, фильтры [3]. Как и во многих технических системах, «классические» алгоритмы сегодня уступили место нейросетевым подходам, ввиду доступности оборудования и разработке эффективных алгоритмов обучения, оптимизированных под доступные вычислительные ресурсы.

Многие технические решения часто получаются из подсказок, которые можно найти в природе. К примеру, устройство сверточных сетей частично напоминает процесс обработки изображения в зрительном тракте человека [4]. В ходе моделирования этапов распознавания зрительного анализатора человека можно наткнуться на много неочевидных, на первый взгляд, проблем: динамическое контрастирование частей изображений, цифровой формат хранения картинки, и прочие. Из-за них придерживаться полностью биоинспирированных подходов в решении задач технического зрения может оказаться не самой лучшей идеей с точки зрения производительности. Однако это не означает, что представления о работе зрительного анализатора, точнее о процессах осмотра объектов человеческим глазом, не могут дать нам полезных подсказок в построении алгоритмов машинного зрения.

Ввиду рассмотренных проблем в качестве системы распознавания в этой работе будут использоваться сверточные сети. Из-за особенностей реализаций архитектур сверточных сетей, сравнительно мало алгоритмических решений, в которых использовались бы результаты распознавания на предыдущих кадрах. К примеру, в алгоритме YOLO [5] между соседними кадрами строится матрица, следящая за распознанными и отслеживаемыми объектами, и оценивающая, насколько распознанная ранее рамка близка

(англ. IoU, Intersection Over Union) к предыдущему кадру и можно ли считать, что ввиду малых изменений положений объекта между кадрами это один и тот же объект. В реальных задачах пропадание объекта из видимости может происходить более чем на несколько кадров ввиду физических помех, канала передачи или неточностей распознающей системы. По этой причине в реализации нашего алгоритма предполагается, что задачу удержания во внимании пропавшего из поля зрения объекта, по аналогии со зрительной системой человека, будет выполнять отдельный, параллельно работающий нейросетевой блок.

В качестве оптимизируемой системы распознавания интерес представляет алгоритм, которому можно было бы «помочь» путем внедрения в него результатов отслеживания траектории объекта в движении. При этом система не должна представлять из себя слишком тяжелую нейросеть, способную распознавать тысячи классов. Предполагается, что блок распознавания заранее переобучается под конкретную практическую задачу распознавания (автомобили, лица, посетители магазина) и такт распознавания представляет из себя сравнительно небольшое число матричных операций. Тем самым, мы можем гарантировать высокий fps в условиях ограниченных вычислительных ресурсов. Под вышеописанные критерии походит алгоритм Faster R-CNN [6], который, помимо прочего, выполняет две важнейшие части любого алгоритма трекинга – поиска объектов с одновременной их классификацией (семейство региональных глубоких сверточных нейронных сетей или Regional Convolutional Neural Networks), что, из-за раздельности выполнения, в более ранних решениях проблемы накладывало ограничения на работу в режиме реального времени.

Обзор существующих методов

Для детальной постановки задачи и описания разработанной модификации алгоритма кратко рассмотрим исходный алгоритм распознавания Faster R-CNN [6].

Модель Faster R-CNN является развитием предыдущей итерации алгоритма Fast R-CNN [7], в которой использовался алгоритм генерации «областей интереса» (или «внимания»), в которых потенциально могут находиться интересующие нас объекты (алгоритм Edge Boxes). На замену ему был предложен алгоритм RPN (Regional Proposal Network). Кратко рассмотрим основные этапы на рис. 1.

На 1-м шаге выполняется формирование карты признаков на основе исходного изображения. Изображение подается на вход сверточной нейронной сети (выбор архитектуры зависит от задачи, к примеру, VGG-16).

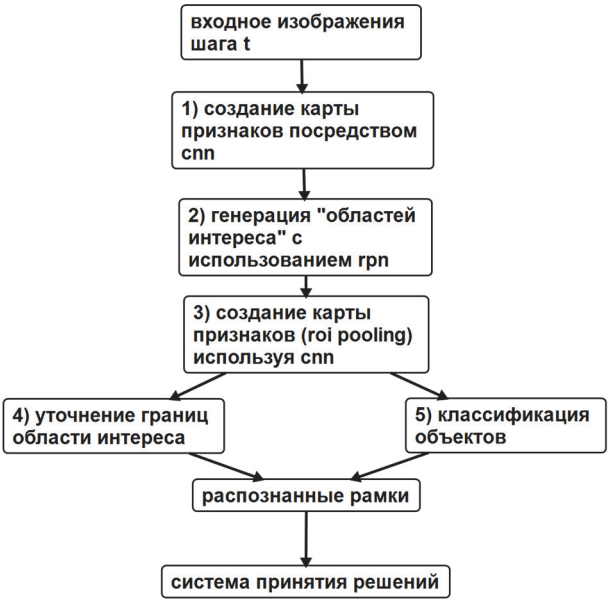

Рис. 1. Алгоритм Faster R-CNN

На 2-м шаге выполняется генерация областей интереса, возможно, содержащих объект. Используя RPN, сформированная карта признаков обрабатывается скользящим окном заданного размера 3x3. Таким образом, генерируется набор из 9 областей интереса, которые имеют один и тот же центр, но с различными пропорциями и масштабами. Для каждой позиции окна извлекается вектор признаков малой размерности и вычисляется значение Intersection over Union (IoU). IoU является оценкой качества классификации, численно равен отношению площади пересечения к площади объединения прямоугольника (или области интереса), полученного в результате детектирования и прямоугольника из разметки. Исходя из полученных значений IoU, выбирается текущая область интереса. В исходной статье рассматривается 2000 областей интереса, однако, в зависимости от решаемой задачи, можно найти баланс между точностью (количеством областей) и быстродействием (fps).

На 3-м шаге выполняется преобразование вектора признаков области интереса из исходного изображения в вектор признаков фиксированной размерности (с помощью слоя RoI pooling).

На 4-м шаге происходит уточнение границ области интереса при помощи регрессионной модели (Bounding Box Regression). Полученные области интереса и полученные вектора признаков подаются на вход двум новым полностью связным слоям. Первый из этих слоев используется для уточнения границ прямоугольника, а второй для классификации объекта, расположенного внутри этого прямоугольника.

На 5-м шаге (выполняемым параллельно с 4-м) выполняется классификация объектов, содержащихся в предполагаемых областях интереса. Используется слой softmax с K+1 выходами (где K+1 – величина, характеризующая число классов объектов, с учетом наличия фона на исходном изображении).

Рассмотрим результаты исходного алгоритма Faster R-CNN (табл. 1). Результаты получены на видеоускорителе Nvidia RTX 2070 в зависимости от выбранного алгоритма и архитектуры выбранной модели CNN (предобученных на наборе данных MS COCO). Полученные результаты соответствуют приведенным в исходной статье ввиду новых версий библиотек, поддержки тензорных ядер и вычислительной мощности ускорителя (Tesla K40 в табл. 5 [6]). Полученная средняя точность (в исходном mAP) модели, основанной на архитектуре VGG, обученной на данных MS COCO составила 74.6 %.

Таблица 1

Результаты распознавания исходной алгоритма Faster R-CNN (300 гипотез)

Модель CNN	Система классификации	Время обработки 1 изображения, мс	FPS
VGG	RPN Shared + Faster R-CNN	103	10
ZF	RPN Shared + Faster R-CNN	33	30

Предлагаемый алгоритм

Существует несколько реализаций алгоритмов трекинга, однако, в большинстве случаев, распознанные объекты могут быть неверно подсчитаны и классифицированы, особенно в ситуациях, когда происходит перекрывание объектов или сбои распознающего алгоритма. Мы будем рассматривать задачу отслеживания с предположением, что объект движется медленно относительно частоты кадров. В современных видеокамерах (30–60 fps) это достаточно распространенная практика. В современных системах видеонаблюдения скорость видеопотока превышает 30 fps при каче-

стве выше HD [8]. Помехи и ошибки записи могут приводить к потере более, чем нескольких кадров, что создает проблемы системам трекинга (сбои в отслеживании). Помимо этого, решается проблема, связанная с точностью прогнозирования дальнейшей траектории движения объектов. Например, движение автомобиля или пешехода обычно достаточно легко аппроксимировать. Распознанный класс и его описание на языке признаков, полученное от CNN, можно легко сравнить (cosine мера) с описаниями полученных ранее объектов. Например, в ситуации, когда отслеживаемый человек пропал из области видимости, алгоритм не будет его распознавать как новый объект. Ниже будет представлен практический пример реализации, в которой новые описания объектов на языке признаков сохраняются для последующего корректного трекинга.

Рис. 2. Интеграция системы прогнозирования с алгоритмом Faster R-CNN

Зрительный анализатор человека прослеживает сцену, фиксируя внимание на каком-нибудь объекте и поддерживает фиксацию на нем путем плавного движения глаз [4]. С учётом нашего представления о работе системы зрения человека, мы предлагаем следующий алгоритм. Сохраним во времени результаты распознавания нескольких предыдущих кадров. Нами были выбраны значения 100, 80, 60, 40, 20, 10 предыдущих кадров. На ос-

нове полученных четверок координат ограничивающих рамок можно реализовать алгоритм множественной регрессии, с чем, при условии плавности движения, хорошо справляются даже полиномиальные множественные регрессии. В нашей реализации мы использовали полносвязную 5-слойную нейросеть. Отметим, что в зависимости от решаемой задачи целесообразно отдельно модифицировать нейросети отдельно для разных видов траектории движения распознаваемых объектов. Тип сверточной сети выбирается в зависимости от конкретизации набора распознаваемых в данной задаче классов. Учитывая эти факторы, можно существенно снизить вычислительную нагрузку и существенно повысить fps, например, учитывать, что распознаются только автомобили или лица. Далее рассмотрим интеграцию такой системы прогнозирования с алгоритмом Faster R-CNN на рис. 2.

На выходе RPN мы, параллельно с основным процессом распознавания, внедряем прогнозируемые нейросетью координаты движущихся объектов. С учётом этого факта сокращается количество выдаваемых RPN прогнозов с 300, рассматриваемых в табл. 1, до 200. Тем самым мы распараллеливаем процесс генерации потенциальных гипотез и снижаем время работы системы, что особенно критично в системах реального времени. Таким образом предлагаемый алгоритм повышает быстродействие и заменяет часть гипотез RPN на более интеллектуальные, полученные в результате отслеживания объекта.

Практические примеры

В ходе постановки эксперимента и сравнения полученных метрик был рассмотрен следующий пример.

Отслеживание статистики количества машин на разных участках дорог, с учётом исторических данных о пробках, может улучшить систему прогнозирования и помочь системам навигации, тем самым разгружая дороги. Аналогичная статистика, с учётом количества устанавливаемых в современных мегаполисах камер [9], позволяет получать более точные данные о загрузках дорог, что потенциально помогло бы в проектировании новых дорожных развязок.

Постановка эксперимента

В ходе реализации эксперимента на языке python был использован фреймворк машинного обучения torch и библиотека для отображения opencv. Для сравнения с приведенными в исходной статье решениями, применялся тот же графический ускоритель и аналогичная, предобученная на

данных MS COCO сверточная нейросеть. Как уже упоминалось ранее, регрессионный блок был заранее обучен на траекториях движения пешеходов, полученных из результатов распознавания исходным алгоритма Faster R-CNN.

В ходе работы программы Faster R-CNN была накоплена обучающая выборка данных по траекториям движения человека, что позволило с большой точностью ($R^2 = 0.91$) прогнозировать координаты следующей ограничивающей рамки (ниже обозначен как *Tracking NN*). Включенное в архитектуру уточнение границ области интереса позволяет компенсировать ошибки прогнозирующего блока.

В качестве примера работы алгоритма рассмотрена проблема перекрытия нескольких кадров в задаче распознавания пешеходов. На рис. 3 можно видеть, что распознанный пешеход (метка 0), в ходе перекрытия другим пешеходом (метка 2), был распознан корректно в процессе дальнейшего трекинга. В подобных случаях распознающий блок сохраняет отслеживаемые объекты в течение 2 секунд. В зависимости от решаемой задачи и динамики движущихся объектов этот параметр можно скорректировать в угоду производительности или точности.

Рис. 3. Система не теряет пешехода при его временном перекрытии другим пешеходом

В ходе запуска сети на новых данных были получены результаты, приведенные в табл. 2. Поскольку распознающий блок был оставлен с исходными параметрами, архитектура VGG показала аналогичную точность. Стоит отметить, что полученная точность и модель выбраны для задачи многоклассовой классификации и может быть существенно улучшена посредством тонкой настройки (англ. fine tuning) под решаемую задачу, существенно повысив fps и точность. Помимо этого, целесообразно провести

эксперименты с более актуальными архитектурами сверточных сетей, к которым можно применить метод дистилляции знаний (knowledge distillation), существенно упрощающий модель с минимальными потерями в точности. Такие способы хорошо зарекомендовали себя во многих областях глубокого обучения. Получаемые метрики сильно зависят от решаемой задачи и требуют существенных вычислительных ресурсов для обучения алгоритма. Исследование предложенных модификаций планируется продолжить в дальнейших работах.

Таблица 2

Сравнение результатов распознавания исходным и предложенным (первые две строки) алгоритмами

Модель CNN	Система классификации	Время обработки 1 изображения, мс	FPS
VGG	**RPN + Tracking NN + Faster R-CNN**	**74**	**13**
ZF	**RPN + Tracking NN + Faster R-CNN**	**26**	**39**
ZF	RPN + Fast R-CNN	33	30
VGG	RPN Shared + Fast R-CNN	103	10
ZF	RPN Shared + Fast R-CNN	33	30

Выводы

Был предложен и реализован алгоритм динамического трекинга объектов Tracking NN. Алгоритм продемонстрировал 30%-й прирост в скорости распознавания, по сравнительно с исходным алгоритмом Faster R-CNN с сохранением точности распознавания. Помимо этого, благодаря предложенному алгоритму и сравнению получаемых описаний на языке признаков, возросла стабильность отслеживания объектов.

Полученные результаты демонстрируют высокие показатели частоты кадров (fps) и возможность гибкой настройки компонентов системы для оптимизации точности или быстродействия. Были рассмотрены возможные варианты улучшения системы за счет модификации компонентов алгоритма.

Список литературы

1. https://cherryhome.ai/ (Дата обращения 26.04.2020.)

2. Leonardo G., Marco B, Lorenzo S, Alberto B. Video Compression for Object Detection Algorithms // ICPR. 2018. P. 3007–3012.

3. Chris Stauffer, W. Eric L. Grimson. Learning Patterns of Activity Using Real-Time Tracking // IEEE 2000. V. 22. P. 747–757.

4. Хьюбел Д. Глаз, мозг, зрение // Мир. 1990. С. 54.
5. Joseph R., Santosh D., Ross G., Ali F. You Only Look Once: Unified, Real-Time Object Detection // Cornell University cs.CV V.5.
6. Shaoqing R., Kaiming H., Ross G., Jian S. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks // Neural Information Processing Systems (NIPS). 2015.
7. Girshick, R. Fast R-CNN // International Conference on Computer Vision (ICC). 2015.
8. https://tass.ru/moskva/6490275?utm_source=yxnews&utm_medium=desktop (Дата обращения 26.04.2020.)

А.Н. ГОРБАНЬ[1,3], С.Б. ПАРИН[1,4], С.А. ПОЛЕВАЯ[1,4], М.А. ФИЛЯЕВ[1,5], Н.П. АШИНА[1,6], И.В. НУЙДЕЛЬ[1,2], О.В. ШЕМАГИНА[1,2], В.Г. ЯХНО[1,2]

[1]Нижегородский национальный государственный университет им. Н.И. Лобачевского
[2]Институт прикладной физики РАН, Нижний Новгород
[3]University of Leicester, Leicester LE1 7RH, UK
[4]Приволжский исследовательский медицинский университет, Нижний Новгород
[5]ООО «Психосоматика 2.0», Нижний Новгород
[6]Пущинский научный центр биологических исследований РАН
ag153@le.ac.uk, parins@mail.ru, s453383@mail.ru, yakhno@appl.sci-nnov.ru

МОДЕЛИРОВАНИЕ ЭТАПОВ ПОВЕДЕНИЯ ЧЕЛОВЕКА ПРИ СТРЕССОВЫХ НАГРУЗКАХ*

Рассмотрена математическая модель, в пределе способная дать полное формализованное описание механизмов запуска стресс-реакции, формирования и развития трех стадий этой реакции и альтернативные варианты выхода из стресса. Для этого в модели использованы знания о «быстрых» и «медленных» стадиях и системе «пробуждающих» параопиоидных пептидов. Обсуждаются варианты сопоставления данных решений модели с известными экспериментальными данными.

Ключевые слова: *моделирование функций биосистем, трехэтапное описание стресса, режимы реагирования, некоторые данные экспериментов.*

* Данная работа выполнена при поддержке Министерства образования и науки РФ, проект №14.Y26.31.0022.

1. Введение

Теория стресса Ганса Селье [1] за 85 лет своего существования претерпела серьезные изменения. Конечно, большинство ее базовых положений сохранили свою актуальность и сегодня. Например, классическая триада Г.Селье (гипертрофия надпочечников, инволюция тимуса и язвообразование в желудочно-кишечном тракте) верифицирована миллионами экспериментальных и клинических наблюдений, что подтверждает первоначальный тезис Г. Селье о безусловной разрушительности стресс-реакции. Несмотря на отдельные попытки пересмотра трехстадийной структуры стресса [2], дальнейшие исследования показали их полную несостоятельность. Как и указывал Г. Селье, стресс развивается через последовательные стадии тревоги, резистентности и истощения.

Однако нельзя не отметить и существенные изменения в структуре теории Г. Селье, связанные с появлением новых методов, подходов и исследовательских парадигм. Центральными из них являются вопросы о конкретизации нейроэндокринных механизмов стресса, сложности системного управления этим процессом и особенностях принципиально антиадаптивных проявлений реакции. Базовые положения теории стресса, постулировавшие решающую роль в его развитии двух стресс-реактивных систем (симпатоадреналовой – САС, гипоталамо-гипофизарно-адреналовой – ГГАС) в последние четыре десятилетия дополнились пониманием ведущей роли третьей системы: эндогенной опиоидной (ЭОС) [3, 4, 5]. Выяснилось, что множественность систем управления функциями организма, характерная для комфортного состояния, при стрессе редуцируется (или регрессирует) до абсолютного доминирования трех стресс-реактивных систем: САС, ГГАС и ЭОС [6, 7]. Наконец, ключевым является вопрос об антиадаптивных свойствах стресса. Формулировка Г. Селье [8]: стресс есть общий адаптационный синдром, - оказала драматическое влияние на все учение о стрессе. Неуместное использование популярного в первой половине XX века термина «адаптация» [9] привело к схоластическим спорам о происхождении неведомой «адаптационной энергии» [10]. Магистральное направление в исследовании стресса было размыто, что привело к дезавуированию основных положений теории и поставило под угрозу само ее существование.

Между тем, еще в ранних работах Г. Селье были представлены убедительные доказательства принципиально антиадаптивных свойств защитной реакции стресса: триада Г. Селье формируется не как приспособление (адаптация) к повреждающему воздействию, а как расплата за возможность противостоять этому повреждению. При стрессе, в противовес адаптации,

сенсорные пороги (особенно, дифференциальные) неуклонно растут [11, 12], потому что нет необходимости тонко отслеживать особенности процессов, для борьбы с которыми уже запущена жестко детерминированная неспецифическая реакция защиты. Наконец, стресс всегда приводит к чрезвычайной стандартизации всех показателей жизнедеятельности: разнообразие адаптивных реакций при стрессе заменяется однотипными унифицированными процессами [6]. По существу, стресс, как и другая неспецифическая защитная реакция – воспаление, обеспечивает спасение целого – всего организма – за счет жертвования частным: клетками, тканями этого организма. Пневмония при COVID-19 – типичный пример такого рода реакций. Как избыточная защита при стрессе приводит к развитию шока, так и избыточная защита при воспалении приводит к фатальному перерождению тканей.

Таким образом, стресс сегодня следует рассматривать как неспецифическую, защитную, стадийную, системную, редуцированную (регрессионную), психофизиологическую реакцию на повреждение или его угрозу [13]. Очевидно, что дальнейшее исследование стресса требует не только экспериментального моделирования и клинических наблюдений, но и формализованного описания механизмов его развития. Нами были ранее предприняты попытки математического моделирования этого процесса. В первом случае [14] модель биологоправдоподобно описывает динамику среднего артериального давления при взаимодействии трех стресс-реактивных систем: САС, ГГАС и ЭОС – при стрессе и шоке. Однако, в ней не учитывались стартовые пороговые условия запуска стресс-реакции, зависимые от генетически детерминированных и приобретенных характеристик субъекта, и механизмы завершение стресса. Другая модель [15] с высокой точностью воспроизводит динамику ритмокардиограммы при остром стрессе и надежно верифицирована в эксперименте. Модель продемонстрировала определенные прогностические возможности. Однако она описывает лишь начальную стадию стресса – стадию тревоги – и учитывает взаимодействие медиаторного («быстрого») компонента ЭОС и активность САС. Используются также элементы описания (учет энерго- обеспеченности организма) из моделей [16, 17]. Особенности архитектуры изучаемых живых распознающих систем взяты с учетом данных из работ [9, 12, 18–21].

2. Основные переменные и модельные балансные уравнения

В данной работе представлен следующий этап разработки математической модели, в пределе способной дать полное формализованное описание механизмов запуска стресс-реакции, формирования и развития трех стадий

этой реакции и альтернативные варианты выхода из стресса. Для этого в модели использованы знания о «быстрых» («легкие» опиоидные пептиды с медиаторными, в основном, свойствами: энкефалины) и «медленных» стадиях («тяжелые» опиоидные пептиды с гормональными, в основном, свойствами: эндорфины и динорфины) [22] и системе «пробуждающих» параопиоидных FaRPs (FMRFamide Related Peptides) пептидов [23]. На стадии тревоги стресса описываются варианты и активной защиты («бей – беги» [9]) при доминировании САС, и пассивно-оборонительной реакции («замирание = freezing» [18] при доминировании ЭОС. В модельном описании предложено использовать две подсистемы. Первая состоит из иерархии основных подсистем, распознающих внутренние и внешние сигналы, которые учитывают в своей работе различные виды эмоциональных состояний организма [9, 12, 18–21], и обеспечивают специфические реакции за время порядка долей секунды – несколько секунд. Вторая подсистема реализует неспецифические реакции в ответ на полученный $S_{a_i}(t)$ – вектор сигналов запуска от первой подсистемы.

В модельной подсистеме, описывающей неспецифические реакции интегральной системы, использованы следующие переменные.

Таким образом, любой информационный сигнал (внешний или внутренний) вызывает либо специфическую реакцию (при адекватном осознанно – бессознательном распознавании), либо запускается неспецифический процесс, связанный с поиском новых алгоритмов для выхода из ситуаций, в которых ранее освоенные алгоритмы дают сбои. Известно, что опытные люди при необходимом объеме знаний и «энергообеспечения» могут обучаться в любых трудных ситуациях, не впадая в стресс. А когда знаний или «энергообеспечения» не хватает, то поиск выхода запускается через стадии стресса.

Балансные уравнения для переменных (компонент), обеспечивающих неспецифические реакции записываются в виде:

$$\frac{dK_i}{dt} = -\frac{K_i}{\tau_{2i}} + \frac{1}{\tau_{1i}} \cdot F_i\left[-T_{0i} + \sum_{j=1}^{8} \sigma_{ij} K_j + S_{a_i}(t) \right], \text{ где } i = 1, 2, 4, 5, 6, 8, \quad (1)$$

K_i – переменные, введенные в табл. 1,

τ_{1i} – характерное время активации *i*-й переменной;

τ_{2i} – характерное время утилизации *i*-й переменной;

T_{0i} – порог срабатывания активационной нелинейной функции для *i*-й переменной;

σ_{ij} – коэффициент влияния *j*-й переменной на *i*-ю переменную;

$S_{a_i}(t)$ – сигнал активации на *i*-ю переменную со стороны распознающей системы, обнаружившей сбой в работе своих алгоритмов.

Таблица 1

ФАЗА ТРЕВОГИ (характерное время секунды – десятки секунд)	**Переменная 1 – $К_1$: САС** – симпатоадреналовая система, активирует систему. **Переменная 2 – $К_2$: ЭОС** – эндогенная опиоидная система («легкие» энкефалины, быстрая компонента), вызывает расслабление системы. **Переменная 3 – $К_3$: E(t)** – эффективное энергетическое обеспечение (быстрые траты - восстановление используемых ресурсов, по-видимому, с ограниченным объемом запасов)
ФАЗА РЕЗИСТЕНТНОСТИ (характерное время десятки минут – часы)	**Переменная 4 – $К_4$: ГГАС –** гипоталамо-гипофизарно-адреналовая система, способствует запоминанию найденных решений (действий). **Переменная 5 – $К_5$: Окситоцин,** способствует стиранию (забыванию) найденных решений (выполненных действий). **Переменные 3 и 7 – $К_3$: E(t) и $К_7$: E(t)**
ФАЗА ИСТОЩЕНИЯ (характерное время часы – сутки)	**Переменная 6 – $К_6$: ЭОС** – эндогенная опиоидная («тяжёлые» эндорфины и динорфины) система (медленная компонента), вызывает расслабление системы и повышение порогов срабатывания сенсорных систем, а также запуск механизмов восстановления используемых ресурсов. **Переменная 7 – $К_7$: E(t)** – дополнительные энергетические источники (со сниженной эффективностью, значительными, но менее доступными запасами), обеспечивают необходимые траты энергии и механизм медленного восстановления используемых ресурсов). **Переменная 8 – $К_8$:** Пробуждающие пептиды (FMRFamide-Related-Peptides = FaRPs) [23], направленные, по-видимому, на управление порогами **ЭОС** – эндогенной опиоидной («тяжёлые» эндорфины и динорфины) системы (**$К_6$**)

Изменения переменных K_3 и K_7 определяются уравнениями:

$$\frac{dK_i}{dt} = -\frac{K_i}{\tau_{3ii}} - K_i \cdot \sum_{j=1, i\neq j}^{8} \frac{K_j}{\tau_{3ij}} + \frac{1}{\tau_{1i}} \cdot F_i\left[-T_{0i} + \sum_{j=1}^{8} \sigma_{ij} K_j + S_{a_i}(t)\right], \quad i = 3,7, \quad (2)$$

а τ_{3ij} – характерное время потребления *j*-й компонентой той энергии, которая берется от *i*-го энергоисточника. Все остальные параметры такие же, как в уравнениях (1).

Нелинейные функции активации задаются в кусочно-линейном виде

$$F_i[\ ] \Rightarrow \begin{cases} 0 & \alpha_i[\ ] < -0.5 \\ 0.5 + \alpha_i[\ ], & \text{если} \quad -0.5 \le \alpha_i[\ ] \le 0.5 \\ 1 & \alpha_i[\ ] > 0.5 \end{cases} \tag{3}$$

$\alpha_i = \alpha_i(K_3, K_7)$ – наклоны среднего участка нелинейной функции, зависящие от уровней энергообеспечения (K_3 и K_7).

Для качественного анализа временных изменений переменных, происходящих в единой системе, можно использовать результаты отдельных (независимых) рассмотрений их поведения на выделенных этапах – стадиях: ФАЗА ТРЕВОГИ; ФАЗА РЕЗИСТЕНТНОСТИ; ФАЗА ИСТОЩЕНИЯ. Дело в том, что масштабы как времен роста, так и уменьшения рассматриваемых компонент на этих выделенных этапах – стадиях демонстрируют существенные различия. В дальнейшем единое решение составляется из фрагментов решений на выделенных этапах.

3. Классификация получаемых решений

Рассмотрим основные элементы решений, полученных с помощью качественного анализа уравнений (1)–(3).

1. В случаях, когда распознающая система адекватно обеспечивает запоминание, анализ, принятие решений и обучение при работе с любыми видами как ожидаемых, так и неожиданных информационных сигналов (специфические реакции), запуск неспецифических реакций отсутствует. При этом переменные, обеспечивающие неспецифические реакции, изменяются в диапазоне ниже пороговых значений.

2. Первый этап стресса, **ФАЗА ТРЕВОГИ**, (характерное время секунды – десятки секунд).

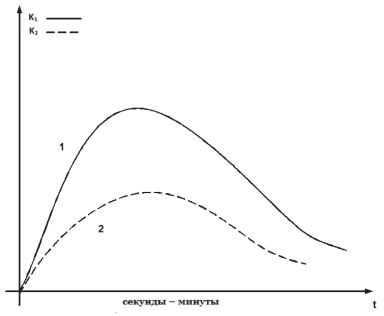

2.1. Активация при условии $\mathbf{K_1(t) > K_2(t)}$:

Рис. 1. Активация, поиск выхода на основании генетически заданных («инстинктивных») программ («бей – беги» по У.Кеннону [9 – W.Cannon, 1915]), переход ко 2-му этапу

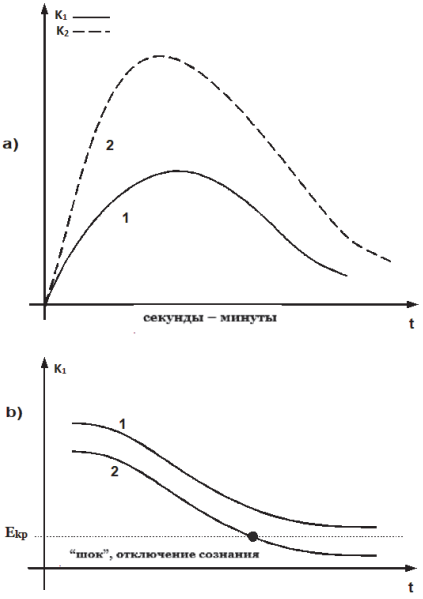

2.2. Замирание при условии $\mathbf{K_1(t) < K_2(t)}$:

Рис. 2. Замирание («фризинг» по Т. Инои [18 – T.Inoue, 1996]), отказ от поиска в выборе новых решений, вариант «депрессии», переход ко 2-му этапу стресса (зависимость 1 на рис. 2, *б*).

Если $\mathbf{K_3 = E(t)}$ становится $< \mathbf{K_{кр.} = E_{кр}}$, то организм переходит в более тяжелое патологическое состояние («шок», потеря сознания – зависимость 2 на рис. 2, *б*)

3. Второй этап стресса, **ФАЗА РЕЗИСТЕНТНОСТИ**, (характерное время десятки минут – часы).

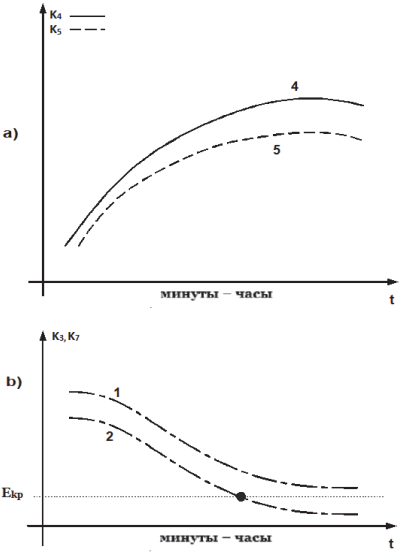

3.1. Активация **ГГАС** и **Окситоцина** при условии **$К_4(t) > К_5(t)$:**

Рис. 3. Действие **ГГАС** превалирует над действием **Окситоцина** (рис. 3, *а*), то происходит запоминание найденных решений (действий), переход к 3-му этапу (зависимость 1 на рис. 3, *б*)

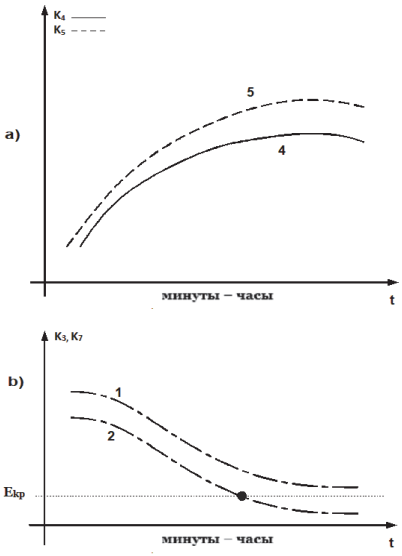

3.2. Активация **ГГАС** и **Окситоцина** при условии **$К_4(t) < К_5(t)$:**

Рис. 4. Если действие **Окситоцина** превалирует над действием **ГГАС,** то происходит стирание (забывание) найденных решений (выполненных действий), переход к 3-му этапу (зависимость 1 на рис. 4, *б*).

3.3. При снижении уровня доступных энергоресурсов (**$К_3 = E(t)$** становится меньше **$К_{кр} = E_{кр}$**) происходит переход организма в более тяжелое патологическое состояние («шок», потеря сознания – зависимость 2 на рис. 4, *б*)

4. Третий этап стресса, **ФАЗА ИСТОЩЕНИЯ**, (характерное время часы – сутки).

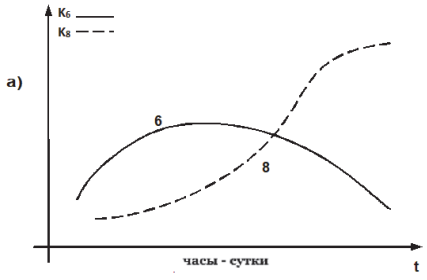

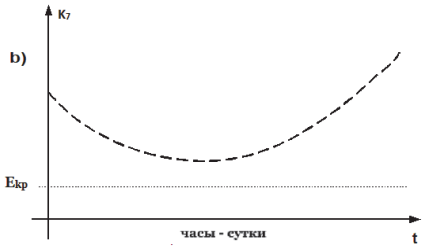

4.1. Взаимодействие компонент при условии $\mathbf{К_8(t) > К_6(t)}$ и $\mathbf{К_7(t) = E(t)}$ всегда больше $\mathbf{К_{кр.} = E_{кр}}$ – критической величины энергообеспечения организма. Таким образом, реализуется этап «отдыха и восстановления» системы.

Рис. 5. Если действие «Пробуждающих пептидов» (FaRPs) превалирует над действием медленной компоненты **ЭОС** (рис. 5, *а*), то происходит восстановление (рост) уровня доступных организму энергоресурсов (рис. 5, *б*) и выход переменных, отвечающих за неспецифические реакции, в начальный диапазон «нормы» (ниже пороговых значений)

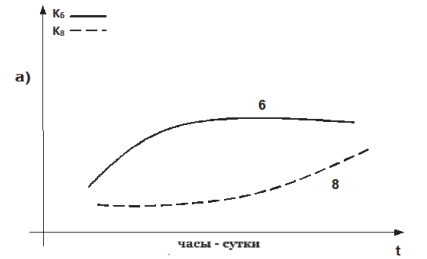

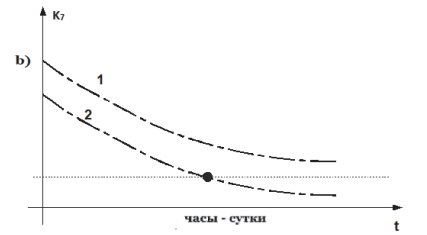

4.2. Взаимодействие компонент при условии $\mathbf{К_8(t) < К_6(t)}$:

Рис. 6. а) Взаимодействие компонент $\mathbf{К_8(t)}$ и $\mathbf{К_6(t)}$ при замедленном процессе восстановления уровня доступных организму энергоресурсов (зависимость 1 на рис. 6, *б*).

4.3. При этом повышается риск перехода в более тяжелое патологическое состояние. Если переменная $\mathbf{К_3 = E(t)}$ становится меньше значения $\mathbf{К_{кр.} = E_{кр.}}$ (зависимость 2 на рис. 6, *б*), то система переходит в состояние «шока» и потери сознания

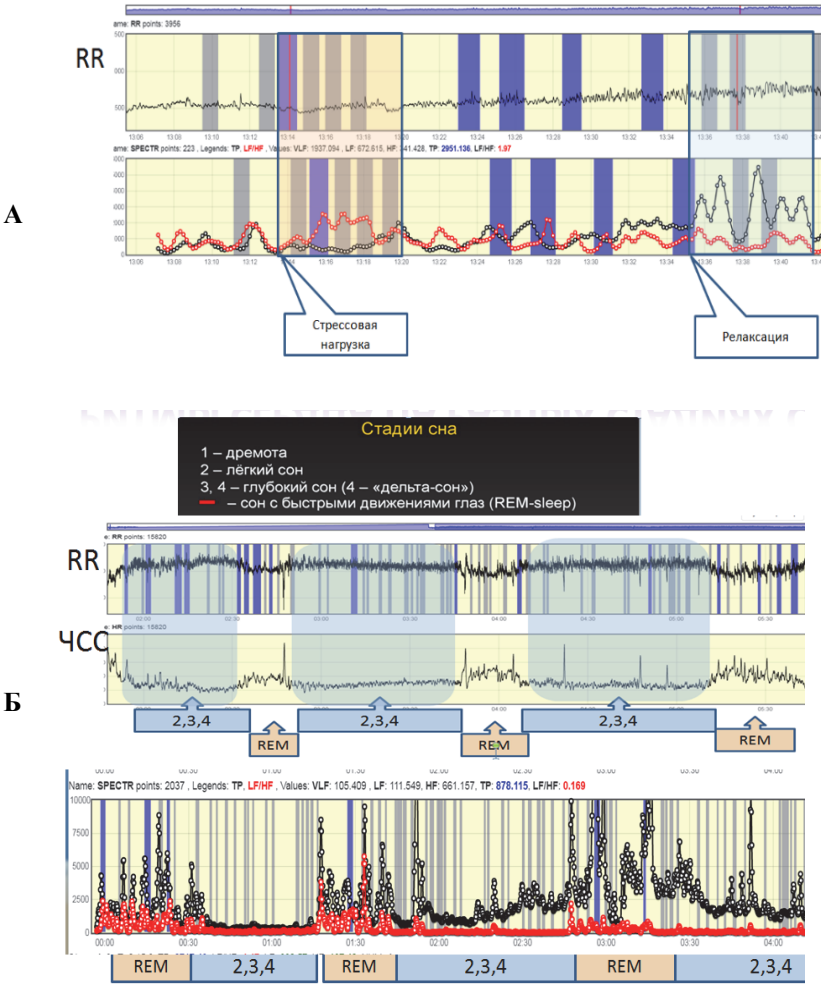

Рис. 7. Примеры нативных ритмокардиограмм (RR), динамики частоты сердечных сокращений (ЧСС) и результатов их автоматической on-line обработки при различных функциональных состояниях: А – во время сеанса психотерапии; Б – во время сна. Красные линии – ИВБ (индекс вегетативного баланса = соотношение активности симпатической (HF) и парасимпатической (LF) систем, черные линии – общая мощность спектра вариабельности ритма сердца (TP); синие вертикальные полосы – автоматически зафиксированные стресс-эпизоды

4. Сравнение с экспериментальными данными и выводы

Для верификации решений модели предполагается в первую очередь использовать результаты технологии событийно-связанной телеметрии ритма сердца (ССТ РС) [24], позволяющей с высокой достоверностью регистрировать динамику различных функциональных состояний в условиях естественной деятельности (рис. 7). Технология основана на автоматической регистрации и обработке вариабельности ритма кардиосигнала и основана на методе кардиоритмографии [25].

Проведенная модификация модели позволила построить описание, соответствующее более объемному материалу экспериментальных данных. Полученное разнообразие режимов демонстрирует возможность дальнейшего уточнения модельного языка описания, а также выявления спорных мест выбранного подхода. Удалось формализовать описание ряда процессов, ранее вызывавших неоднозначное толкование. Несомненно, следует продолжать проверку данного подхода.

Список литературы

1. Selye, H. A Syndrome Produced by Diverse Nocuous Agents. Nature. 1936, 138: 32.

2. Гаркави Л.Х., Квакина Е.Б., Уколова М.А. Адаптационные реакции и резистентность организма. Ростов: Изд-во Рост. ун-та, 1977. 120 с.

3. Bodnar R.J., Kelly D.D., Brutus M., Glusman M. Stress-induced analgesia: Neural and hormonal determinants. Neuroscience & Biobehavioral Reviews. 1980, 4(1): 87–100.

4. Голанов Е.В., Фуфачева А.А., Черкович Г.М., Парин С.Б. Влияние лигандов опиатных рецепторов на эмоциогенные реакции сердечно-сосудистой системы у низших приматов. Бюллетень экспериментальной биологии и медицины. 1987, 103(4): 424–427.

5. Onaka T., Yagi K. Differential effects of naloxone on neuroendocrine responses to fear-related emotional stress. Experimental Brain Research, 1990, 81(1):53–58.

6. Парин С.Б. Люди и животные в экстремальных ситуациях: нейрохимические механизмы, эволюционный аспект. Вестник Новосибирского государственного университета. 2008, 2(2): 118–135.

7. Александров Ю.И., Сварник О.Е., Знаменская И.И., Колбенева М.Г., Арутюнова К.Р., Крылов А.К., Булава А.И. Регрессия как этап развития. М.: Когито-Центр, 2017. 191 с.

8. Selye H. Experimental evidence supporting the conception of «adaptation energy», Am. J. Physiol. 1938, 123: 758–765.

9. Cannon W. B. Bodily changes in pain, hunger, fear and rage: An account of recent researches into the function of emotional excitement. New York, NY: D. Appleton & Company; 1915. 326 p.

10. Goldstone B. The general practitioner and the general adaptation syndrome, S. Afr. Med. J. 1952, 26(5): 88–92, 106–109.

11. Полевая С.А., Ковальчук А.В., Парин С.Б., Яхно В.Г. Роль параметров внутреннего состояния физиологической системы в осознании сенсорных сигналов. Научная сессия НИЯУ МИФИ-2010. Материалы избранных научных трудов по теме: «Актуальные вопросы нейробиологии, нейроинформатики и когнитивных исследований». М.: НИЯУ МИФИ, 2010: 58–68.

12. Яхно В.Г., Полевая С.А., Парин С.Б. Базовая архитектура системы, описывающей нейробиологические механизмы осознания сенсорных сигналов. Когнитивные исследования: Сборник научных трудов: Вып. 4 / Под ред. Ю.И. Александрова, В.Д. Соловьева. М.: Изд-во «Институт психологии РАН», 2010: 273–301.

13. Parin S.B., Bakhchina A.V., Polevaia S.A. A neurochemical framework of the theory of stress. International Journal of Psychophysiology. 2014, 94(2): 230.

14. Парин С.Б., Яхно В.Г., Цверов А.В., Полевая С.А. Психофизиологические и нейрохимические механизмы стресса и шока: эксперимент и модель. Вестник Нижегородского университета им. Н.И. Лобачевского. 2007, 4: 190–196.

15. Parin S., Polevaia S., Gromov K., Polevaia A., Kovalchuk A. Short-term variability of R-R intervals during acute stress in healthy adults: neuromorphic model, experiment data, monitoring of daily life activity. International Journal of Psychophysiology. 2016, 108: 88.

16. A.N. Gorban, T.A. Tyukina, E.V. Smirnova, L.I. Pokidysheva Evolution of adaptation mechanisms: Adaptation energy, stress, and oscillating death, Journal of Theoretical Biology, 405 (2016), 127–139.

17. A.N. Gorban, L.I. Pokidysheva,·E,V. Smirnova, T.A. Tyukina. Law of the Minimum Paradoxes, Bull Math Biol 73(9) (2011), 2013-2044; Online first 19.11.2010.

18. Inoue T, Tsuchiya K, Koyama T. Effects of typical and atypical antipsychotic drugs on freezing behavior induced by conditioned fear. Pharmacology Biochemistry and Behavior. 1996, 55(2): 195–201.

19. Гроф С. Путешествие в поисках себя: Измерение сознания. Новые перспективы в психотерапии и исследовании внутреннего мира. / С.Гроф; Пер. с англ. Н.И. Папуш и М.П. Папуша под ред. А. Киселева. М.: ООО «Издательство АСТ» и др., 2004. 346 с.

20. Гроф С. Величайшее путешествие: Сознание и тайна смерти: пер. с англ. / С. Гроф. М.: ООО «Издательство АСТ», 2007. 475 с.

21. Яхно В.Г., Макаренко Н.Г. Поможет ли нам создание «Цифрового двойника человека» лучше понимать друг друга? // в кн. Подходы к моделированию мышления, гл. 6. С. 169–202 / Под ред. В.Г. Редько. М.: ЛЕНАНД. 2014. 392 с. (Синергетика от прошлого к будущему. № 70, Науки об искусственном. № 13).

22. Akil H., Darragh F.M., Devine P., Watson S.J. Molecular and Neuroanatomical Properties of the Endogenous Opioid System: Implications for Treatment of Opiate Addiction. Seminars in Neuroscience. 1997, 9(3–4): 70–83.

23. Тиняков Р.Л., Парин С.Б., Беспалова Ж.Д., Крушинская Я.В., Соколова Н.А. FMRFa и FMRFамид-подобные пептиды (FaRPs) в патогенезе шока. Успехи физиологических наук. 1998, 29(3): 56–65.

24. Polevaya S.A., Eremin E.V., Bulanov N.A., Bakhchina A.V., Kovalchuk A.V., Parin S.B. Event-related telemetry of heart rhythm for personalized remote monitoring of cognitive functions and stress under conditions of everyday activity. Sovremennye tehnologii v medicine. 2019, 11(1): P.109–115.

25. Парин В.В., Баевский Р.М. Введение в медицинскую кибернетику. М.: Медицина, 1966. 220 с.

О.В. МАСЛЕННИКОВ, В.И. НЕКОРКИН
Институт прикладной физики РАН, Нижний Новгород
olmaov@ipfran.ru, vnekorkin@ipfran.ru

ДИНАМИКА РЕКУРРЕНТНЫХ СЕТЕЙ ЧАСТОТНЫХ НЕЙРОНОВ ПРИ КОНТРОЛИРУЕМОМ ОБУЧЕНИИ ГЕНЕРАЦИИ ПЕРЕКЛЮЧАТЕЛЬНЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ

Анализируются объекты фазового пространства, возникающие при обучении рекуррентных сетей частотных нейронов генерировать многомерные последовательности заданной конфигурации. Рассматривается три типа задач: во-первых, автономная генерация сложных последовательностей выходными нейронами, активируемыми рекуррентной сетью. Во-вторых, активация выходных нейронов входными импульсами. В-третьих, задача переключения между различными последовательностями активаций посредством входных импульсов.

Ключевые слова: *рекуррентная нейронная сеть, обучение с учителем, резервуарные вычисления, переключательная активность.*

Введение

Искусственные нейронные сети являются предметом исследования двух крупных научных направлений [1]. Во-первых, в области математической нейронауки разрабатываются модели крупномасштабных популяций нейронов, на основе которых изучаются динамические механизмы коллективного поведения биологических сетей-прототипов и функционирования различных отделов нервной системы живых организмов [2–4]. Во-вторых, в области машинного обучения разрабатываются новые алгоритмы обучения искусственных нейронных сетей для построения всё более сложных интеллектуальных систем, решающих прикладные задачи распознавания,

классификации, прогнозирования [5–6]. На стыке этих направлений развивается концепция резервуарных вычислений, высокий интерес к которой наблюдается в настоящее время [7]. Суть её состоит в том, что модификация весовых коэффициентов происходит только между сетью-резервуаром и слоем выходных нейронов, тогда как внутрирезервуарные и входные веса остаются неизменными.

В данной работе рассматривается система резервуарных вычислений, включающая слои входных и выходных элементов и резервуар, динамика элементов которого описывает частоту спайковой активности нейронов. Изучена динамика сети-резервуара, контролируемо обучаемого выполнять три различных задачи генерации переключательных последовательностей [1]. В первой задаче целевые сигналы состоят из последовательно активирующихся выходных нейронов, и система способна автономно генерировать такие паттерны. Во второй задаче сеть-резервуар получает короткие входные импульсы и обучается отвечать активацией соответствующих выходных нейронов. В третьей задаче резервуар получает короткие импульсы с входных нейронов и обучается возбуждать различные последовательности в слое выходных нейронов в ответ на определенные стимулы.

Нейронная сеть: динамика, структура, обучение

Рассмотрим систему резервуарных вычислений, центральный компонент которой — резервуар, представляющий собой сеть случайно и редко связанных между собой частотных нейронов [8]. Принципиальная схема рассматриваемой системы представлена на рис. 1.

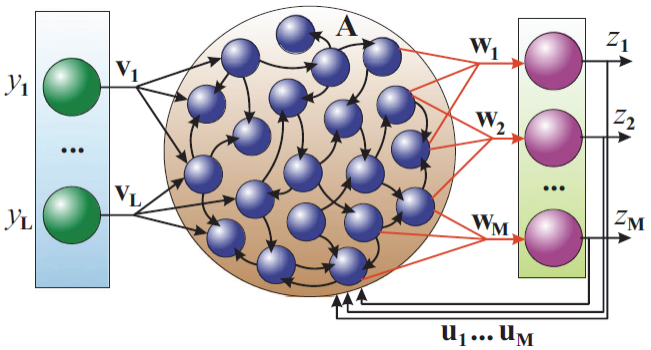

Рис. 1. Анализируемая система резервуарных вычислений.

Узлы этой сети получают короткие импульсы от элементов входного слоя, и в свою очередь, влияют на активность элементов выходного слоя. Автономная динамика сети-резервуара описывается следующим уравнением в векторной форме:

$$\tau \dot{X} = -X + AR \ , \qquad (1)$$

где τ – константа времени, вектор $X = (x_i)$ описывает активность нейронов $i = 1,\ldots,N$ в резервуаре, вектор $R = (r_i)$ описывает средние частоты спайков, определяемые как $r_i = \tanh x_i$. Эти частотные нейроны рекуррентно связаны друг с другом в резервуаре в соответствии с матрицей смежности A , элементы которой берутся из гауссова распределения с нулевым средним и стандартным отклонением $g(pN)^{-1/2}$, где p – доля ненулевых элементов, а g – глобальная сила связи.

Воздействие стимулов $Y = (y_j)$ с входных нейронов, где $j = 1,\ldots,L$, на рекуррентную сеть определяется матрицей V размером $N \times L$, столбцы которой — это векторы V_j . Каждый нейрон входного слоя j посылает в рекуррентную сеть свою активность, умноженную на определенный входной вектор $V_j = (v_{ij})$, где $i = 1,\ldots,N$.

Выходной слой состоит из M выходных нейронов, динамика которых $z_k(t) = W_k R(t)$ полностью определяется активностью резервуара и выходными весами. Каждый выходной нейрон k $(k = 1,\ldots,M)$ получает на вход произведение активности резервуара и определенного выходного вектора $W_k = (w_{ik})$, который изменяется в процессе обучения $(i = 1,\ldots,N)$. Выходные сигналы могут быть записаны в векторной форме:

$$Z = W^T R \ , \qquad (2)$$

где вектор-столбец $Z = (z_k)$ состоит из скалярных сигналов z_k , матрица W размером $N \times M$ состоит из вектор-столбцов W_k ; W^T – транспонированная матрица W .

Выходные нейроны имеют обратные связи с резервуаром, веса которых обозначаются векторами-столбцами U_k . Полная информация об обратной связи содержится в матрице U размером $N \times M$, состоящей из векторов-

столбцов U_k $(k=1,\ldots,M)$. Элементы векторов V_j и U_k взяты из независимых случайных равномерных распределений между -1 и 1 и остаются неизменными.

Таким образом, динамика нейронов резервуара с учетом входных нейронов и обратной связи с выходных нейронов описывается следующим образом:

$$\tau \dot{X} = -X + AR + UZ + VY = -X + (A + UW^T)R + VY = -X + QR + VY, \quad (3)$$

где матрица $Q = A + UW^T$ определяет эффективную топологию с учетом внутрирезервуарных и обратных связей.

Элементы матрицы W модифицируются в процессе обучения согласно алгоритму контролируемого уменьшения ошибки первого порядка. В процессе контролируемого обучения в моменты времени t, $t+\delta t$, $t+2\delta t$ и т. д. вычисляются следующие величины:

вектор ошибки $E(t) = Z(t) - F(t) = W^T(t)R(t) - F(t)$,

матрица P – текущая оценка обратной матрицы корреляции частот нейронов в сети:

$$P(t) = P(t-\delta t) - \frac{P(t-\delta t)R(t)R^T(t)P(t-\delta t)}{1 + R^T(t)P(t-\delta t)R(t)}, \quad (4)$$

матрица выходных весов обновляется по следующему правилу:

$$W(t) = W(t-\delta t) - P(t)R(t)E^T(t). \quad (5)$$

Матрица P инициализируется как $P(0) = I/\alpha$, где I – единичная матрица, константа α – скорость обучения. Временные интервалы δt взяты равными 2 мс.

Вначале элементы выходной матрицы W равны нулю, и после каждого интервала δt изменяются согласно описанному выше правилу адаптации. Постепенно значения W_k приближаются к некоторым стационарным состояниям. После чего процедура обучения прекращается и мы имеем многомерную динамическую систему сложной сети с фиксированными весами.

В зависимости от цели обучения, система либо автономно генерирует некоторую целевую функцию, либо откликается на внешние стимулы определенными выходными сигналами. Центральная структура сети – резервуар, определяемая матрицей A, после обучения остается такой же, как и до обучения. Автономная динамика сети в отсутствие входных и обратных связей является хаотической, поскольку глобальная сила связи превышает порог $g = 1.5 > 1$. Модифицированные в процессе обучения векторы W_k,

умноженные на векторы обратной связи U_k , задают низкоранговое возмущение в топологию связей резервуара, и соответствующая сетевая активность существенно изменяется. Такое структурное возмущение приводит к глобальной трансформации фазового пространства сети-резервуара. В данной работе было проанализировано, какого рода динамика возникает на индивидуальном уровне нейронов в резервуаре и в пространстве трех первых главных компонент, лежащая в основе выхода системы в случае успешного обучения.

Автономная генерация сложных последовательностей

Рассмотрим автономный случай, в котором система контролируемо обучается генерировать заданный паттерн последовательной активации нейронов выходного слоя. В дальнейшем описании рассматриваются целевые функции, в которых выходные нейроны обучаются генерировать последовательные импульсы в определенном порядке. Выбрана специальная форма целевых функций, однако представленные результаты качественно не меняются при выборе другого типа целевой функции. Конкретно, целевые функции взяты в виде комбинаций положительных полупериодов синусоиды с единичной амплитудой и частотой 2 Гц, которые активируются друг за другом M выходными нейронами. Система обучается генерировать последовательность из D таких полупериодов-активаций. Процедура обучения, как правило, длится в течение десяти повторов целевого паттерна. В это время выходные веса векторов W_i $(i = 1,\ldots,M)$ модифицируются, как это описано выше, и достигают некоторых стационарных значений. Проведен анализ того, какого рода динамические объекты в фазовом пространстве резервуара возникают в случае успешного обучения. Перед обучением резервуар находится в хаотическом режиме, когда все нейроны демонстрируют нерегулярную динамику. После обучения эффективная топология связей изменяется и появляется регулярное решение, соответствующее выходному паттерну. Наш анализ показал, что в N -мерном фазовом пространстве возникает замкнутая устойчивая кривая – предельный цикл. Структура предельного цикла отражает особенности выходного паттерна. Активация определенных выходных нейронов ассоциирована с посещением траекторией определенных областей фазового пространства, т.е. во время активации какого-либо выходного нейрона фазовая траектория, спроецированная в пространство первых трех главных компонент, двигается в соответствующей этому нейрону области. После многократного

предъявления системе целевой последовательности конфигурация предельного цикла настраивается таким образом, чтобы в слое выходных нейронов активность ближе соответствовала целевому паттерну. Устойчивость наблюдаемой траектории подтверждается вычислением ляпуновских показателей. Мы отслеживали эволюцию N -мерной траектории сети-резервуара наряду с четырьмя малыми ортогональными возмущениями, как это производится согласно алгоритму Бенеттина, и получали оценку первых четырех показателей Ляпунова. Анализ показал, что старший показатель Ляпунова равен нулю, а остальные отрицательны, что свидетельствует о том, что наблюдаемый предельный цикл устойчив.

Важные выводы о роли динамики резервуара в обучении получены в результате исследования того, какая доля нейронов в обученном резервуаре достаточна для воспроизводства целевого поведения. Результат обучения можно оценивать вычисляя нормированную среднеквадратичную ошибку, усредненную по всем выходам $k=1,\ldots,M$:

$$E = \frac{1}{M} \frac{\sum_{k=1}^{M} \left\langle \left(z_k(t) - f_k(t) \right)^2 \right\rangle}{\left\langle f_k(t)^2 \right\rangle}, \qquad (6)$$

где $\langle \ldots \rangle$ обозначают усреднение по времени, $f_k(t)$ – целевой сигнал. Мы удаляли долю h_0 выходных связей w_{ki} в векторе W_k начиная с наименьших значений и затем вычисляли логарифм нормированной среднеквадратичной ошибки E . Проводя эту процедуру для всех выходов $k=1,\ldots,M$ и усредняя по ним ошибку, мы получили возрастающую функцию величины h_0 , однако выходные сигналы остаются близкими к целевым даже при больших долях удаленных связей.

Стимул-индуцированная генерация последовательностей

Рассмотрим более сложную задачу, когда система получает входные стимулы y_j $(j=1,\ldots,L)$ в форме коротких прямоугольных импульсов, поступающих в резервуар через векторы V_j $(j=1,\ldots,L)$. Импульсы имеют единичную амплитуду и длительность 50 мс. Вначале исследовалась задача, когда сеть-резервуар обучается производить дискриминацию, т. е. получая импульс с j-го входного нейрона, сеть должна своей активностью возбудить отклик длительностью 250 мс только в j-м выходном нейроне.

Во время фазы обучения входные импульсы появляются в случайном порядке и целевая функция настраивается соответствующим образом.

После предъявления сети около ста входных импульсов в случайном порядке и модификации выходных весов согласно описанному правилу обучения, резервуар способен корректно откликаться на входящие стимулы. Успешное обучение приводит к перестройке геометрии фазового пространства таким образом, что области, посещаемые траекторией после прихода стимулов с определенных входных нейронов, четко разделены в фазовом пространстве. Однако здесь фундаментальное различие со случаем автономной генерации целевого паттерна. В последнем случае появляется устойчивый предельный цикл, который притягивает траектории, стартующие из начальных точек достаточно большого бассейна притяжения. Здесь же, хотя наблюдаются хорошо предсказуемые отклики, система фактически остается хаотической как и до обучения. Если входные нейроны прекращают посылать импульсы, поведение резервуара становится нерегулярным, и старший ляпуновский показатель больше нуля, что является индикатором хаоса в системе. Таким образом, внешние периодические короткие стимулы приводят к регуляризации хаотической динамики.

Также анализировалось, какая доля нейронов в обученном резервуаре, главным образом, отвечает за воспроизведение целевой функции. Удаление порядка 30 % выходных связей слабо сказывается на качестве обучения. Более того, исследование показало, что хотя с ростом h_0 ошибка увеличивается, переключательная активация выходных нейронов может достаточно хорошо наблюдается даже при удалении 80 % слабейших выходных связей.

Изучено влияние динамики резервуара на выходную активность. Мы интересовались, имеются ли нейроны в резервуаре, наиболее ответственные за активацию определенных выходных нейронов. В нормальной ситуации каждый входной импульс $y_j(t)$ воздействует на динамику сети-резервуара через вектор V_j, который остается неизменным как в процессе обучения, так и после него. Данная схема была изменена, и те же самые входные импульсы прикладывались только к ограниченному числу нейронов резервуара, после чего изучалась выходная активность. Выбирались нейроны $i=1,\ldots,n<N$ с наибольшими нормами весов w_{ki} для некоторого выхода k и стимулировались тем же прямоугольным импульсом, воздействующим через входной вектор, который содержит только значения 1 и -1 в зависимости от того, положительный или отрицательный вес w_{ki} они имеют. Установлено, что при стимуляции лишь 5 % нейронов резервуара

описанным образом выходные нейроны генерируют отклики, близкие к целевым. Таким образом, в процессе обучения возникают особые центральные группы, состоящие из относительно небольшого числа нейронов, соответствующие каждому выходному нейрону. Стимуляция нейронов только в этих группах приводит к селективному отклику соответствующего выходного нейрона.

Также рассматривался резервуар, который контролируемо обучался возбуждать различные переключательные последовательности в слое выходных нейронов в зависимости от того, какой входной нейрон посылает импульс. Во время фазы обучения сеть-резервуар получает входы $y_j(t)$ $(j = 1,\ldots,L)$ с входных нейронов в форме прямоугольных импульсов единичной амплитуды и длительностью 50 мс. Каждому стимулу соответствует определенный целевой паттерн в виде D последовательных активаций M выходных нейронов. Показано, что после стимулирования сети входными стимулами в случайном порядке достаточное количество раз и модифицирования выходных весов согласно описанному выше правилу обучения резервуар способен возбуждать различные выходные последовательности в зависимости от входных импульсов. Заметим, что стимуляция определенного входного нейрона приводит к генерации одной и той же последовательности, в то время как импульсы с различных входных нейронов запускают генерацию различных паттернов в выходном слое.

Когда входные нейроны прекращают посылать стимулы, динамика резервуара переключается к некоторому периодическому режиму, который не совпадает ни с одним из целевых паттернов. В N -мерном фазовом пространстве это соответствует устойчивому предельному циклу. Траектории, соответствующие целевым паттернам, в некоторых сегментах двигаются в малой окрестности предельного цикла, тогда как в других областях пространства отходят от него достаточно далеко. Таким образом, эти решения возникают только после ритмической стимуляции, поэтому роль внешних стимулов состоит в том, чтобы сместить траекторию с устойчивого предельного цикла в метастабильные области, образованные в процессе обучения. После прохождения метастабильной области траектория возвращается в окрестность устойчивого предельного цикла, откуда она может быть выведена внешним импульсом в ту же самую или другую метастабильную область.

Выводы

Изучена динамика рекуррентной сети частотных нейронов, контролируемо обучаемой выполнять три различных задачи генерации последовательностей активации. В первой задаче целевые сигналы состоят из последовательно активирующихся выходных нейронов, и система способна автономно генерировать такие паттерны. Показано, что динамическим образом многомерной активности, поддерживающей успешное обучение, является устойчивый предельный цикл. Во второй задаче сеть-резервуар получает короткие входные импульсы и обучается отвечать активацией соответствующих выходных нейронов. Установлено, что несмотря на предсказуемость и регулярность выходов, в отсутствие коротких внешних импульсов сетевая динамика является хаотической. Таким образом, роль периодических стимулов состоит в регуляризации хаоса в активности системы. В третьей задаче резервуар получает короткие импульсы с входных нейронов и обучается возбуждать различные последовательности в слое выходных нейронов в ответ на определенные стимулы. В автономном случае сеть генерирует некоторую переключательную активность, которая не совпадает ни с одним из целевых паттернов, однако под воздействием коротких импульсов выходные нейроны демонстрируют определенные переключательные последовательности, совпадающие с целевыми.

Работа выполнена при поддержке РНФ (проект № 19-72-00112).

Список литературы

1. Maslennikov O.V., Nekorkin V.I. Stimulus-induced sequential activity in supervisely trained recurrent networks of firing-rate neurons // Nonlinear Dynamics. 2020. T. 101. C. 1093–1103.

2. Marblestone A.H., Wayne G., Kording K.P. Toward an integration of deep learning and neuroscience // Frontiers in computational neuroscience. 2016. T. 10. C. 94.

3. Barak O. Recurrent neural networks as versatile tools of neuroscience research // Current opinion in neurobiology. 2017. T. 46. C. 1–6.

4. Buonomano D.V., Maass W. State-dependent computations: spatiotemporal processing in cortical networks //Nature Reviews Neuroscience. 2009. T. 10. №. 2. C. 113–125.

5. Graves A., Mohamed A., Hinton G. Speech recognition with deep recurrent neural networks // 2013 IEEE international conference on acoustics, speech and signal processing. IEEE, 2013. C. 6645–6649.

6. Venugopalan S. et al. Translating videos to natural language using deep recurrent neural networks // arXiv preprint arXiv:1412.4729. 2014.

7. Lukoševičius M., Jaeger H. Reservoir computing approaches to recurrent neural network training // Computer Science Review. 2009. T. 3. №. 3. C. 127–149.

8. Sussillo D., Abbott L.F. Generating coherent patterns of activity from chaotic neural networks // Neuron. 2009. V. 63. No. 4. P. 544.

Н.В. ЛАВРОВ, В.В. ЛАВРОВ
Санкт-Петербургский государственный педиатрический медицинский университет
vasilylavrov@yandex.ru

КЛАССИФИКАЦИЯ МЕЖНЕЙРОННЫХ СВЯЗЕЙ ВНУТРИ НЕЙРОННЫХ СЕТЕЙ

Рассматривается структурно-функциональная организация каналов межнейронной коммуникации в свете морфологических и нейрофизиологических сведений относительно неспецифических образований мозга, контролирующих и консолидирующих работу мозга. Обращается внимание на типологию межнейронных связей внутри нейронных сетей. Гетерогенность нейронных модулей, в которых находятся представители центрального регуляторного аппарата, объясняет системную консолидацию корковых и подкорковых отделов мозга.

Ключевые слова: *гетерогенный нейронный модуль, межнейронная коммуникация, целесообразное управление, кодирование сигнала, контекстное поле.*

Введение

Попытка найти нейросетевое подобие мозга и аппаратов, воспроизводящих отдельные функции интеллекта, сталкивается с непреодолимым препятствием при сопоставлении конструктивных особенностей компьютерных комплексов и мозговых образований. В том и другом случае вместо равномерного сетевого распределения структурных элементов прослеживаются модульные образования. В первом случае конструктивно обособляются блоки программного и аппаратного обеспечения функций. Конструкции обозначаются разнообразными терминами. Рассмотрение этих терминов в связи с особенностями конструкции аппаратных комплексов составляет предмет специальных объемных исследований. В случае мозга проблема функциональной единицы выглядит гораздо сложнее, поскольку речь идет не только о морфологических особенностях нейронных скоплений и их связей, а о системной вовлеченности в цельную мозговую деятельность. Анализ организации нервных клеток не может не учитывать того факта, что они постоянно находятся под контролем в рамках «большой» системы с иерархией подсистем и существованием центрального меха-

низма управления. В настоящее время снизился интерес к дискуссии относительно организации нейронной функциональной единицы вследствие продвижения нейросетевой парадигмы, которая предусматривает существование сети однородных элементов с циркуляцией запущенных импульсов по сетевым связям.

Данная работа посвящена рассмотрению двух обстоятельств. Во-первых, обращается внимание на особенности системного объединения комплексов нейронов в целесообразную деятельность. Во-вторых, предпринимаются усилия объяснить принципы межнейронной коммуникации в условиях разнообразия способов передачи и кодирования сигнала.

На раннем этапе изучения коммуникации нервных клеток проблема передачи информации ограничивалась выяснением особенностей импульсации нейронов в зависимости от параметров предъявленных стимулов. В дальнейшем проблема усложнилась в связи с исследованием закономерностей вовлечения нейронов в выполнение поведенческих актов. Усложнение усугубилось пониманием тройственного характера передаваемой информации, имеющей вид команды на выполнение стандартных действий, регулятора состояния или сигнала, мобилизующего на принятие самостоятельного решения [1]. Обращение к нейронаукам, остающимся на механистичной теоретической платформе, не проясняет проблему. В частности, нейробиология, направляя усилия на изучение функциональных отношений мозговых структур, фактически игнорирует вопросы, обусловленные дискретностью информации и системным управлением информационными процессами в мозге. Она концентрирует внимание на структурах, активируемых при выполнении функции, исходя из предположения, что эти структуры ответственны за функцию, не учитывая, что в реальности *мозг действует как единое целое, а каждая его структура вовлечена в выполнение всех поведенческих актов*. Зачастую концентрация внимания на роли той или иной структуры затрудняет изучение цельности системной коммуникации. Например, после обнаружения нейронов, активируемых при конструктивном диалоге и проявлениях эмпатии, было высказано предположение о существовании «зеркальных нейронов», обеспечивающих взаимопонимание при общении [2]. Такое предположение, предусматривающее наличие промежуточного «зеркального» элемента, опосредующего получение информации, по сути, создает побочное направление исследований.

Понимание организации межнейронной коммуникации зависит от выяснения принципов восприятия сигнальной значимости информации с учетом следующих обстоятельств: во-первых, изменения состояния органоидов и мембраны нервных клеток под воздействием получаемого и посыла-

емого сигнала, во-вторых, многообразия частотно-временных характеристик импульсных потоков и, в-третьих, пространственно-временных отношений нейронов в рамках модулей и макроструктур. Здесь было бы уместно рассмотреть возникшие в связи с достижениями криптографии предположения по поводу возможных типов импульсного кодирования сигналов, однако это невозможно сделать из-за ограниченных размеров статьи. Авторов предположений объединило одно – они концентрировали внимание на стандартных ситуациях и не предусматривали изменения кодирования при возникновении новых не прогнозируемых ситуаций. При рассмотрении коммуникативной системы авторы, чаще всего, ограничиваются оценкой надежности каналов связи и поиском стандартных способов сигнального (знакового, символьного и т.д.) кодирования в рамках предполагаемых множественных «языков мозга» [3]. При этом вне поля зрения остается соответствие контекстов взаимодействующих нейронов. В отсутствие такого соответствия, даже при полной надежности канала связи, в контекстном поле существует барьер, который препятствует правильному восприятию полученных информационных посылок. Проблема преодоления контекстного барьера и включения коммуникации нейронов является одной из основополагающих в изучении мозга. Говоря о «временной связи» И.П. Павлов [4] имел в виду «проторение» нервного канала и возникновение контакта между нейронами. В настоящее время, когда известно, что в мозге имеется избыточность контактов, его идея может быть интерпретирована как «проторение» согласованности между источником и приемником импульсных посылок. Вполне вероятно, что П.К. Анохин [5], разрабатывая теорию функциональных систем и обращая внимание на системоорганизующую консолидирующую роль мотивации на достижение полезного результата, также имел в виду соответствие контекстов нейронов и формирование коммуникативной системы, без которой невозможно согласованное взаимодействие при выполнении поведенческих актов.

Постановка задач

Начальный этап работы определялся рассмотрением мнения о существовании в мозге универсальных способов кодирования специфической информации посредством частотно-временных параметров импульсных потоков. Обратились к электрофизиологическим данным, сопоставляя нейронную активность и макропотенциалы мозга, природа которых известна. Имелись в виду сверхмедленные волны биопотенциалов (СМВ), обусловленные функциональным состоянием мозга. Формулируя задачу исследования, руковод-

ствовались следующим рассуждением. Если характер импульсации нейронов до, после и во время обучения будет стабильно оставаться в зависимости от СМВ и зависимость в ходе обучения принципиально не изменится, то будет логично полагать, что импульсные потоки отражают *неспецифические* процессы. Поэтому мнение об исключительности импульсного кодирования *специфической* информации нуждается в пересмотре. Возникает вопрос, как объяснить передачу специфической информации, если будет установлено, что частотно-временные параметры импульсных потоков, прежде всего, обусловлены регуляторными неспецифическими процессами. Второй этап работы – формулирование гипотезы о том, что межнейронное «взаимопонимание» обеспечивается соответствием контекстов. Гипотеза является альтернативой мнению о существовании универсальных «языков» [3], обеспечивающих межнейронный обмен информации. Согласно гипотезе, выделение специфической информации из поступающих импульсных потоков обеспечивается селекцией на основе матриц, задаваемых обучением. Такие матрицы, по сути, представляют собой контекст [6], при сопоставлении с которым выявляется специфический сигнал.

Первая **задача** данной работы состояла в оценке мнения о существовании специфических форм импульсного кодирования информации. Эта задача решалась при исследовании соотношения параметров мультиклеточной импульсации (МКИ) кортикальных нейронов и СМВ в процессе обучения животных дифференцированию положительного светового сигнала от отрицательных. Вторая **задача** заключалась в формулировании гипотезы, объясняющей принципы коммуникации нейронов в отсутствие специфических форм кодирования информации.

Экспериментальные предпосылки решения задач

При решении первой задачи использовали результаты ранее проведенных наблюдений [7, 8] до введения ограничений на исследования с использованием домашних животных. Эксперименты проведены на 28 животных (кошки, самцы весом 3,5–4,0 кг), находящихся в экранированной звукоизолированной камере в состоянии бодрствования в условиях свободного поведения. Провели 900 исследований МКИ 120 пунктов сенсомоторной коры больших полушарий до, во время и после обучения дифференцировать отрицательные световые сигналы от положительного, подкрепляемого пищей. Подачу раздражения производили засветкой матового диска, угловые размеры которого относительно глаз животного составляли 120 градусов. Положительный световой сигнал 30 лк длительностью 3 с подкреп-

лялся кусочком мяса (вес порядка 3 г). Животное обучалось самостоятельно открывать крышку и доставать мясо из кормушки. Положительный сигнал в случайном порядке сочетался с грубым дифференцировочным 250 лк и средне дифференцировочным 120 лк. Регистрация МКИ, ЭЭГ и СМВ производилась одновременно. При этом следили за поведением и контролировали функциональное состояние, отмечая ритмику сердечных сокращений и дыхания. *Принципиальная особенность* экспериментов состояла в контроле фонового состояния, предшествовавшего предъявлению сигналов. В качестве контроля служила ЭЭГ в передней сигмовидной извилине левого полушария. Все стимулы испытывались в условиях фона покоя, когда в ЭЭГ доминировали медленные альфа- и тета-ритмы (частота менее 12 Гц). Соблюдение такого условия обеспечивало сравнимость реакций на сигналы. В качестве СМВ отмечали колебания биопотенциалов с периодом от 2 до 12 с. Используемые методы дискриминации МКИ позволяли выделять 3 популяции нейронов (отношение амплитуд 1:2:4), находящихся под одним электродом. Если уровень шума (менее 5 мкВ) взять за 100 %, то для первой популяции уровень амплитуды импульсов равнялся 200–250 %, для второй 250–400 % и для третий от 400 до 800 %. Сравнивая активность 3 групп между собой, а также выясняя уровень зависимости каждой группы от активационных влияний и сверхмедленных потенциалов, можно было сделать заключение о принципах организации нейрональной активности при разном функциональном состоянии мозга и на разных этапах поведенческих актов. Интервал между началом опытов и операцией, в ходе которой вживляли электроды в мозг, составлял не менее двух недель, чтобы исключить влияние наркоза. СМВ и результаты компьютеризированной обработки МКИ сопоставлялись при одновременной регистрации с помощью 13-канального энцефалографа. Проверку достоверности различия результатов наблюдений производили по критерию Стьюдента (уровень значимости 0,05). Определяя достоверность события, использовали критерий знаков.

Проведенные эксперименты показали, что включение световых сигналов вызывало изменение фоновых колебаний частоты МКИ при одновременной активации мозга, отражавшейся в ЭЭГ преобладанием быстрой бета-ритмики. Для выявления особенностей ответных реакций сравнили параметры МКИ, отводимой от трех групп нейронов, расположенных под одним электродом. Выраженность реакций оценивали, сопоставляя характер волнообразных колебаний частоты МКИ, отмеченной в фоне и после стимула. Производили сравнительный анализ амплитуды и периода колебаний. Выраженность ответных изменений амплитуды волнообразных колебаний частоты МКИ, отводимой от группы нейронов с наименьшей величиной импульсов,

не была равна реакциям нейронов, которые относились к другим группам с большей величиной импульсов и, по всей видимости, более приближенных к электроду. При этом характер реакций (активация или торможение), а также длительность колебаний были одинаковыми у всех трех групп. Во всех случаях световой сигнал вызывал увеличение периода первого колебания частоты МКИ на 2-4 с. Возвращение длительности последующих колебаний к уровню фона было неровным – например, третье колебание, хотя и было меньше первого, но могло превосходить второе.

Перед началом обучения тестировали световые стимулы без подкрепления. Световые стимулы (30, 120 и 250 лк) отличались по физической интенсивности, и выраженность изменения длительности первого колебания, по сравнению с фоновыми, находилась в прямой зависимости от физической интенсивности. После завершения обучения зависимость проявилась по-иному. Выраженность изменений длительности была наибольшей при действии положительного сигнала (хотя его физическая интенсивность была самой слабой), меньше при среднем дифференцировочном и еще меньше при грубом. Таким образом, после обучения выраженность зависела от биологической значимости сигналов, что соответствовало ранее установленной закономерной зависимости активации мозга [9].

В 60 % случаев включение светового сигнала до, в ходе обучения и после его завершения вызывало увеличение амплитуды колебания частоты МКИ в 2-5 раз по отношению к фону. В 30 % случаев амплитуда колебания частоты МКИ возрастала менее, чем в 2 раза или оставалась на неизменном уровне. В 10 % наблюдений действие сигнала подавляло частоту МКИ, и ответная реакция выражалась в снижении амплитуды первого колебания частоты МКИ, после чего происходило постепенное восстановление фоновых параметров колебаний в течение 20–30 с.

При регистрации СМВ отметили, что световые стимулы вызывали значительное увеличение амплитуды и периода первого колебания потенциала в 60 % наблюдений, в 30 % случаев увеличение было слабым, а в 10 % – амплитуда снижалась. Последующие колебания СМВ постепенно в течение 20–30 с восстанавливались до исходного уровня. До обучения выраженность ответных изменений СМВ зависела от физической интенсивности стимулов, а после – от биологической значимости.

Сопоставление колебательных процессов СМВ и МКИ показало, что они коррелируют по времени. В случае, если ответная реакция МКИ характеризовалась повышением частоты импульсации, выраженность амплитуды колебаний частоты МКИ также соответствовала амплитуде вызванных изменений СМВ.

Таким образом, в результате проведенных экспериментов было показано, что импульсные потоки, распространяемые между нейронами, находятся в соответствии с СМВ, обусловленными неспецифическими регуляторными процессами [10, 11]. До обучения и обретения стимулами сигнальной значимости частотно-временные параметры нейрональной импульсации отражают физическую интенсивность, а после – сигнальную (биологическую) значимость. В процессе обучения после начального генерализованного восприятия сигналов происходит их дифференциация, о чем свидетельствует зависимость выраженности нейрональных реакций от биологической значимости.

Принципиальный момент проведенных наблюдений – отмечено, что частотно-временные характеристики нейронной импульсации вместе с выраженностью ЭЭГ реакций, а также СМВ приобретали новую зависимость, но их параметры оставались в рамках тех значений, которые существовали до обучения. Еще раз подчеркивается, что характер нейронной импульсации постоянно определялся неспецифическими образованиями мозга. Нейроны, находящиеся в общем функциональном поле под одним электродом, не отличались по характеру реагирования. Полученные данные, продемонстрировавшие однородность и цикличность импульсных потоков, противоречат мнению о жестко установленных формах кодирования сигнала, поэтому гипотеза о кодирования специфической информации посредством импульсных паттернов требует пересмотра.

Предлагается альтернативное объяснение принципов передачи специфической информации. Главное внимание обращается на коммуникативную систему, которая складывается при соответствии контекстов источника и приемника. Под термином «контекст» понимается совокупность обстоятельств, определяющих восприятие целостной информационной посылки и ее фрагментов [6]. Контекст отдельного нейрона имеет вид матрицы, определяющей восприятие поступающих импульсных потоков и ответную реакцию. Соответствие контекстов и возникновение контекстного поля можно трактовать как возникновение коммуникативной системы с использованием разных способов передачи сигнала. Ниже в табл. 1 приводится перечень возможных способов кодирования информации при коммуникации нейронов.

Таблица 1

Способы межнейронной передачи информации

Носитель информации	***Возможные способы кодирования***
Частотно-временные параметры импульсации	Амплитуда и длительность колебания частоты импульсного потока
	Включение и выключение импульсации
	Частота и количество импульсов в «пачке»
	Комплекс «пачек» в сигнальной посылке
Химизм синаптической передачи	Специфичность медиатора и количество медиатора
	Сочетание биологически активных веществ в комплексе с медиатором
Пространственное положение синапса на теле и отростках нейрона	Дендритное расположение синапса
	Расположение на аксоне
	Локализация на соме нейрона
Прямое электрическое воздействие	Параметры электрического импульса
Химизм внешней нейронной среды	Биологически активные вещества в межклеточном пространстве
Пространственно-временные особенности импульсных потоков	Сочетание во времени импульсных потоков, поступающих по входным каналам
Контекстное поле коммуникативной системы	Информация считывается с матрицы, активированной комплексом полученных импульсов

По всей видимости, при коммуникации в той или иной мере степени могут применяться все способы, и задача исследования заключается в выяснении их сочетания при изменении ситуации. Гипотеза о существовании контекстного поля и мнестических матрицах, определяющих целостное восприятие информационной посылки, складывающейся из множества фрагментов, расширяет перспективу понимания принципов восприятия информации и принятия решений. Можно объяснить, каким образом нейрону, обладающему ограниченным функциональным ресурсом, удается справиться с задачей интеграции множества воздействий – нейрон использует матрицы для выделения информации. Матрицы формируются в памяти в процессе обучения под управлением регуляторного аппарата мозга. При этом специфические и неспецифические элементы составляют целостную информационную посылку не только при коммуникации нейронов. Попытка разделять эти элементы [12] с предположением о существовании

двух коммуникативных систем (специфической/лингвистической и неспецифической/экспрессивной) препятствует пониманию целостности информации в диалоге.

Представление о контекстном поле создает предпосылку для ответа на вопрос, который интересует исследователей [13–15], пытающихся выяснить принципы межнейронной коммуникации. Имеется в виду вопрос о том, каким образом одновременное сочетание стимулов поступивших по множеству каналов образует целостный интегративный сигнал. Мало вероятно, что нейрон способен одновременно вести отдельное считывание информации, содержащейся в импульсных потоках, поступающих по каждому каналу, а затем интегрировать результаты. Вероятнее всего [13], нейрон использует шаблоны/матрицы, которые заготовлены в процессе формирования коммуникативной системы, выделяя командные посылки, регуляторные и те, которые формулируют задачу для принятия решения.

Гипотеза о контекстном поле коммуникативной системы концентрирует внимание на принципиальной особенности любого эффективного диалога. Имеется в виду соответствие контекстов источника и приемника информации. Соответствие посылаемого сигнала тому, который воспринимается нейроном при получении, равно как и взаимопонимание сторон в процессе переговоров, достигается благодаря тому, что стороны находятся в общем контекстном поле. Гипотеза позволяет по-новому подойти к решению задачи по созданию устройства, имитирующего мозговую деятельность с учетом множественности каналов коммуникации и соответствия контекстов\матриц взаимодействующих элементов.

Заключение

Изучение характера импульсных потоков, распространяющихся между нейронами во время обучения, ведет к пониманию принципов формирования и восприятия информационных посылок в нервной сети. Проведенное исследование показало соответствие СМВ и частотно-временных параметров МКИ нейронов, находящихся в кортикальных модулях. Имеется в виду, что до начала обучения, при его проведении и после завершения колебания частоты МКИ соответствовали СМВ. Выраженность колебаний зависела от физической интенсивности стимулов до обучения и обретала зависимость от биологической значимости сигналов после обучения. Поскольку СМВ обусловлены регуляторными процессами, сделан вывод, что частотные, пространственные и временные параметры импульсных потоков отражают неспецифические регуляторные влияния. Ответ на вопрос о

принципах передачи сочетанной специфической и неспецифической информации по общему каналу приходится искать вне упрощенной схемы кодирования/декодирования. Предлагается гипотеза о том, что обмен информацией в нервной сети обеспечивается коммуникативной системой, создаваемой благодаря соответствию контекстов источника и приемника сигналов – то есть, при возникновении контекстного поля. Гипотеза объясняет сочетание специфической и неспецифической информации в импульсных посылках, которые формируются и воспринимаются в соответствии с сигнальными матрицами, хранящимися в памяти нейрона.

Список литературы

1. Лавров В.В., Рудинский А.В. Стратегии управления обработкой фрагментированной сенсорной информации // Нейроинформатика-2014. Ч. 2. М.: МИФИ. 2014. С. 214–225.

2. Rizzolatti G., Craighero L. The Mirror-neuron system // Annual Rev. Neurosci. 2004. V. 27. P. 169–192.

3. Прибрам К. Языки мозга. М.: Прогресс. 1975. 464 с.

4. Павлов И.П. Двадцатилетний опыт объективного изучения высшей нервной деятельности (поведения) животных. М.-Л.: АН СССР. 1949. Т.3. 605 с.

5. Анохин П.К. Очерки по физиологии функциональных систем. М.: Медицина, 1985. 444 с.

6. Торсуева И.Г. Контекст // Лингвистический энциклопедический словарь. М.: СЭ. 1990. С. 238–239.

7. Лавров В.В. Динамика сверхмедленных колебаний мультинейронной активности и биоэлектрических потенциалов мозга кошки при неподкрепляемом световом раздражении // Физиол.журн.СССР. 1989. Т.75. N 7. С. 890–897.

8. Лавров В.В. Мозг и психика. СПб: РГПУ. 1996. 156 с.

9. Кратин Ю.Г., Зубкова Н.А., Лавров В.В., Сотниченко Т.С., Федорова К.П. Зрительные пути и система активации мозга. Л.: Наука. 1982. 156 с.

10. Хомская Е.Д. Мозг и активация. М.: МГУ. 1972. 382 с.

11. Аладжалова Н.А. Психофизиологические аспекты сверхмедленной ритмической активности головного мозга. М.: Наука. 1979. 240 с.

12. Miyagawa Sh., Ojima Sh., Berwick R.C., Okanoya K. // Frontiers in Psychology. 2014. http://journal.frontiersin.org/Journal/10.3389/fpsyg.2014.00564/full

13. Wolpert D.H. Stacked generalization // Neural Networks. 1992. V. 5. P. 241–259.

14. Николлс Дж.Г., Мартин А.Р., Валлас Б.Дж., Фукс П.А. От нейрона к мозгу. М.: Едиториал УРСС. 2003. 672 с.

15. Лавров В.В. Интерфейс мозга и психики. Saarbrücken: OSM. 2017. 171 с.

А.Ю. ДОРОГОВ
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ»
vaksa2006@yandex.ru

САМОПОДОБНЫЕ СТРУКТУРЫ МНОГОСЛОЙНЫХ НЕЙРОННЫХ СЕТЕЙ

Рассматривается класс многослойных модульных нейронных сетей обладающих самоподобной структурой. В работе вводится понятие морфогенеза и регулярности сети. Определены условия морфогенеза многослойной сети, доказана теорема о морфологии слабосвязанной многослойной сети и получены инварианты системных графов регулярных самоподобных сетей. Предложено правило построения графа самоподобных многослойных сетей. Отмечено, что самоподобные сети описывают структуру алгоритмов быстрого преобразования Фурье.

Ключевые слова: *нейронная сеть, модульность, неокортекс, самоподобие, морфогенез, самоподобный граф.*

1. Модульность биологических нейронных сетей

Известно, что биологический нейрон не функционирует, изолировано, а образует различной величины и численности нейронные ансамбли, нейронные модули или нервные центры. Впервые принцип модульной организации нейронных сетей был описан Р. Лорентье де Но [1]. Еще в 1933 г. выполняя патоморфологические исследования строения человеческого мозга, учёный установил, что нейроны коры головного мозга объединяются в вертикальные столбики клеток (колонки), представляющие собой функциональные единицы, связанные общностью рецепторного поля.

Прямые физиологические результаты, подтверждающие модульное строение корковых структур мозга были получены В. Маунткаслом в 1957–59 гг. [2]. Исследования новой коры (неокортекса) у млекопитающих проведенные Дж. Эдельманом и В. Маунткаслом [3] показали, что кора обладает высокой степенью однородности в структурном строении. Неокортекс присутствует только у млекопитающих, причём стремительное увеличение коры головного мозга у человека произошло всего лишь пару миллионов лет тому назад. Любые значительные эволюционные изменения, происходящие в короткий промежуток времени, обеспечиваются заимствованием существующих структур.

У человека новая кора насчитывает шесть горизонтальных слоёв нейронов, отличающихся по типу и характеру связей. Число нейронов в колонке постоянно и составляет около 110 для приматов [4]. Колонка связана 10-30 связями с другими участками коры. Колонки группируются в более сложные образования – макроколонки, сохраняют определённый топологический порядок и образуют строго-связанные распределённые системы. Новая кора человека содержит около 600000 макроколонок.

«По убеждению многих нейробиологов в конце концов, будет доказано, что уникальные свойства каждого человека - способность чувствовать, думать, обучаться и помнить, заключены в строго организованных сетях синаптических взаимосвязей между нейронами человеческого мозга» [5].

2. Самоподобие и морфогенез

По определению, компактное топологическое пространство X самоподобно, если существует конечное множество S, индексирующее набор несюръективных отображений $\{f_s\}_{s\in S}$ для которых

$$X = \bigcup_{s\in S} f_s(X).$$

Пример. Компактом X является отрезок единичной длины. Позиция точки на отрезке определяется числом из интервала $[0,1)$. В десятичной системе число выражается в позиционной форме $z = 0.z_{-1}z_{-2}\cdots z_{-n}\ldots$ в общем случае с бесконечном числом разрядов, где $z_i = 0,1,2,\cdots,9$. Ограничим в позиционном представлении число разрядов значением n, и будем считать, что число $0.z_{-1}z_{-2}\cdots z_{-n}$ соответствует отрезку длиной 10^{-n}, а значение числа указывает позицию отрезка на интервале $[0,1)$. В частности, для $n=1$ число $0.z_{-1}$ будет соответствовать отрезку длиной 0.1, а значение разряда z_{-1} указывает его позицию на X. Введём для этого уровня множество функций $f_{z_{-1}}(X)$ отображающие компакт X на отрезок длиной 0.1 в позиции $z = 0.z_{-1}$, очевидно, что

$$X = \bigcup_{z_{-1}} f_{z_{-1}}(X).$$

В этом примере символ объединения можно заменить прямой суммой, поскольку при разбиении отрезки не пересекаются. Таким образом, можно записать:

$$X = \bigoplus_{z_{-1}} f_{z_{-1}}(X).$$

Процесс можно итеративно продолжить, выбирая в качестве компактов, уже отрезки построенного разбиения. Тогда для уровня n получим:

$$X = \bigoplus_{z_{-1}} \bigoplus_{z_{-2}} \cdots \bigoplus_{z_{-n}} f_{\langle z_{-1} z_{-2} \cdots z_{-n} \rangle}(X).$$

В данном выражении кортеж $\langle z_{-1} z_{-2} \ldots z_{-n} \rangle$ определяет многомерный индекс множества несюръективных отображений разбивающих компакт X на части. Для позиционной системы счисления соответствие значения числа и его позиционного представления $z \leftrightarrow \langle z_{-1} z_{-2} \ldots z_{-n} \rangle$ является взаимно-однозначными.

Рассмотренное выше классическое понятие самоподобия ориентировано на обслуживание математических моделей фракталов, и не вполне подходит для представления самоподобных объектов не фрактальной природы, поэтому существует необходимость введения обобщающего определения, включающее в себя фрактал как частный случай. Если обратится к биологии, то подходящим понятием может служить морфогенез живых систем. Под морфогенезом в биологии понимается процесс возникновения новых структур и изменения их формы в ходе индивидуального развития организмов, что является неотъемлемым свойством самоорганизующихся систем, обладающих свойством целостности.

В прикладных областях биологии используется более узкое определение: морфоге́нез это возникновение и направленное развитие популяции таксономической группы организмов. Где такси́н (τάξις от греческого «порядок, устройство, организация») – страта в иерархической классификации, состоящая из дискретных упорядоченных объектов, объединяемых на основании общих свойств и признаков.

Не ставя перед собой задачи построение строгой математической модели морфогенеза, введём рабочее определение достаточное для задач морфологического синтеза самоподобных сетей.

Определение 1. Будем говорить, что на популяции индексированных объектов $X = \{A_z\}$ определён *морфогенез*, если для каждого объекта популяции найдётся точное отображение «родитель-потомок» однозначно индексирующее дочерние объекты.

Например, пусть $X = X_0 = \bigoplus_{z_0} A_{z_0}$ – начальная индексированная популяция, тогда направленное развитие популяции по поколениям определяется последовательностью индексируемых популяций вида:

$$X_0 = \bigoplus_{z_0} A_{z_0}, \quad X_1 = \bigoplus_{z_1} \bigoplus_{z_0} A_{\langle z_1 z_0 \rangle}, \cdots, X_{n-1} = \bigoplus_{z_{n-1}} \cdots \bigoplus_{z_1} \bigoplus_{z_0} A_{\langle z_{n-1} \ldots z_1 z_0 \rangle}, \cdots$$

Если X – это компактное топологическое пространство заданное отрезком единичной длины и объектами популяцией является части отрезка, то все поколения объектов популяции совпадают с этим пространством, так что

$$X = X_0 = X_1 = \cdots = X_{n-1} = \cdots$$

и если ещё потребовать конечности выбора правил индексации объектов популяции, то понятие морфогенеза трансформируется к определению самоподобия на компакте. Заметим, теперь, что если ограничится только условием конечности выбора правил индексации, то это приводит к самоподобным растущим популяциям не связанным с фракталами. Если снять условие конечности выбора правил индексации, то процесс роста популяции вследствие морфогенеза в общем случае не будет самоподобным.

При неопределённости числа поколений затруднительно ответить на вопрос о конечности выбора правил индексации и самоподобия. В этом случае необходимо вводить дополнительные ограничения, выделяющие самоподобный процесс, например если для всех поколений морфогенеза, отображения «родитель-потомок» совпадают, то очевидно морфогенез тривиально самоподобен. Однако класс популяций тривиального самоподобного морфогенеза достаточно узкий, и для практических целей целесообразно его несколько расширить.

Определение 2. Морфогенез назовём *регулярным*, если отображение «родитель-потомок» в каждом поколении совпадает для всех объектов и однозначно определяется номером поколения.

Очевидно, что тривиальный самоподобный морфогенез является частным случаем регулярного, когда отображения «родитель-потомок» для всех поколений совпадают. Дальнейшее изложение будет в основном связано с регулярным морфогенезом. Прослеживается явная автомодельность в описании регулярного и тривиального самоподобного морфогенеза, поэтому и для регулярного морфогенеза мы будем использовать термин самоподобный, делая необходимые пояснения в тех случаях, когда требуется выделить отличия.

3. Морфогенез многослойной сети

Пусть многослойный сетевой граф Γ имеет n слоёв. Обозначим через $\left\{A_i^m\right\}$ – множество вершин в слое m, где $m = 0,1,\cdots,n-1$. Множество вершин входного (нулевого) слоя назовём *афферентом* сети и обозначим $Aff\left(\Gamma\right)$, а множество вершин конечного слоя назовём *эфферентом* сети и

обозначим $Eff(\Gamma)$. Пусть A_i^m некоторая вершина сети в слое m. Назовём афферентом вершины (далее обозначается $Aff(A_i^m)$) подмножество вершин афферента сети, связанного дугами с вершиной A_i^m, таким образом $Aff(A_i^m) \subset Aff(\Gamma)$. Аналогично введём понятия эфферента вершины $Eff(A_i^m)$ как подмножество вершин эфферента сети, связанного дугами с вершиной A_i^m, таким образом $Eff(A_i^m) \subset Eff(\Gamma)$. Афференты и эфференты вершины будем также называть её *терминальными проекциями*.

Обозначим через $\Gamma^{-1}(A_i^m)$ рецепторную окрестность вершины A_i^m, а через $\Gamma(A_i^m)$ её аксоновую окрестность. Правило построения графа зададим следующими выражениями:

$$\begin{aligned} Aff(A_i^m) &= \bigoplus_{A_k^{m-1} \in \Gamma^{-1}(A_i^m)} Aff(A_k^{m-1}), \\ Eff(A_i^m) &= \bigoplus_{A_k^{m+1} \in \Gamma(A_i^m)} Eff(A_k^{m+1}). \end{aligned} \qquad (1)$$

Символ прямой суммы подчёркивает, что для любой вершины сети терминальные проекции вершин её окрестности не пересекаются. Эти выражения задают морфогенез и называются условиями слабой связанности сети [6]. В данном случае объектами популяции являются проекции вершин слоёв на терминальные множества. Фактически оба выражения двойственны друг другу, и если выполняется одно из них, то обязательно будет выполнено и другое. Докажем это утверждение.

Теорема 1. О двойственности

Доказательство. Пусть для всех вершин сети выполнено первое условие из (1), но не выполнено второе, тогда существует, по крайней мере пара вершин C_1, C_2, принадлежащих аксоновой окрестности вершины B, таких, что $\mathrm{Efr}(C_1) \cap \mathrm{Efr}(C_2) \neq \varnothing$. Но это означает, что в некотором слое M, находящемся между вершиной B и эфферентным слоем, существует вершина M', которая связана дугами с вершинами C_1, C_2 (рис. 1). Пусть N_1, N_2 – вершины рецепторной окрестности для M', тогда очевидно, что $\mathrm{Afr}(N_1) \cap \mathrm{Afr}(N_2) \neq \varnothing$. Это противоречит принятому предположению о выполнении первого условия из (1), что и доказывает двойственность условий. ■

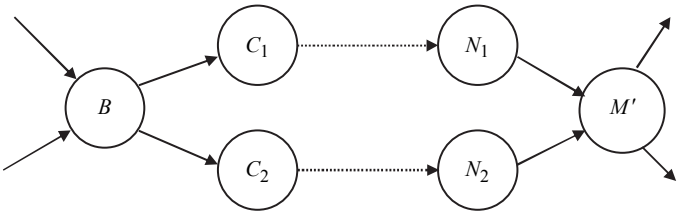

Рис. 1. Параллельные пути в модульной сети

Следующая теорема является обоснованием использования термина «слабосвязанная сеть» [7].

Теорема 2. В слабосвязанных сетях отсутствуют параллельные пути

Доказательство. Предположим противное. Пусть 2 параллельных пути сходятся в вершине B, проходя через её окрестные вершины A_1 и A_2. По условию параллельности пути имеют точку пересечения в некоторой вершине A', предшествующей вершинам A_1 и A_2. Следовательно, афференты вершин A_1 и A_2 пересекаются так, что $\mathrm{Afr}\left(A_1\right) \cap \mathrm{Afr}\left(A_2\right) = \mathrm{Afr}\left(A'\right)$, но это противоречит условию слабой связанности. Поскольку утверждение справедливо для любой вершины, включая терминальные, то отсюда следует невозможность параллельных путей для всей сети. ■

Для многослойных слабосвязанных сетей число слоёв зависит от числа вершин в терминальных слоях. Поясним характер этой зависимости на примере регулярных сетей. Будем полагать, что сеть состоит из одной компоненты. Отношение проекции вершин слоя на терминальное афферентное поле сети, разбивает множество вершин этого слоя на классы. Классу принадлежат вершины слоя, имеющие общее афферентное множество, назовём эти классы афферентными доменами и обозначим $Dom_p\left(A^m_{z^m}\right) = X^m_{i^m}$, здесь $A^m_{z^m}$ – один из представителей домена, i^m – порядковый номер домена в слое m. Вершины афферентного домена имеют проекцию на входной слой сети. Для обозначения проекции доменов слоя на афферент сети будем использовать левую стрелку над символом афферентного домена:

$$\vec{X}^m_{i^m} \subset Aff\left(\Gamma\right).$$

Итерационный процесс от слоя $n-1$ к слою 0 порождаемый условиями морфогенеза (1) последовательно разбивает проекции доменов каждого слоя m на более мелкие части, индексируя разбиение в слое разрядным числом i_m. Сеть будет регулярна, если число порождаемых частей зависит

только от номера слоя. Для последнего слоя однокомпонентной сети существует всего один афферентный домен, поэтому $\tilde{X}^{n-1} = Aff\left(\Gamma\right)$. Объединение проекций афферентных доменов каждого слоя всегда образует афферент сети, таким образом, имеем:

$$Aff\left(\Gamma\right) = \tilde{X}^{n-1} = \bigoplus_{i_{n-1}} \tilde{X}^{n-2}_{i_{n-1}} = \bigoplus_{i_{n-1}} \bigoplus_{i_{n-2}} \tilde{X}^{n-3}_{\langle i_{n-1} i_{n-2}\rangle} = \cdots = \bigoplus_{i_{n-1}} \bigoplus_{i_{n-2}} \cdots \bigoplus_{i_2} \bigoplus_{i_1} \tilde{X}^{0}_{\langle i_{n-1} i_{n-2} \ldots i_1\rangle},$$

где правило перехода $i^{n-k} = \left\langle i_{n-1} i_{n-2} \ldots i_{n-k+1} \right\rangle$ от поразрядной формы к числу устанавливает взаимно-однозначное соответствие порядкового номера домена кортежу индексов. В нулевом слое домены и их афферентные проекции совпадают, и каждый домен состоит только из одной вершины:

$$Dom_p\left(A^0_{i^0}\right) = \tilde{X}^0_{\langle i_{n-1} i_{n-2} \ldots i_1\rangle} = A^0_{i^0}.$$

Номер вершины нулевого слоя определяется кортежем $i^0 = \left\langle i_{n-1} i_{n-2} \ldots i_1 \right\rangle$. Предположим, что для всех m, индекс i_m, принимает только два значения, тогда терминальный афферентный слой должен иметь $N = 2^{n-1}$ вершин.

Аналогично. Отношение проекции вершин слоя m на терминальное эфферентное поле сети, разбивает множество вершин этого слоя на классы – эфферентные домены которые обозначим $Dom_g\left(A^m_{z^m}\right) = Y^m_{j^m}$, где j^m – порядковый номер эфферентного домена в слое m. Проекцию эфферентного домена на выходной слой обозначим $\vec{Y}^m_{j^m} \subset Eff\left(\Gamma\right)$ с правой стрелкой над символом домена. Для нулевого слоя существует всего один домен $\vec{Y}^0 = Eff\left(\Gamma\right)$. Итерационный процесс по m от нулевого слоя к слою $n-1$ обусловленный выражением (1), последовательно разбивает проекции доменов каждого слоя на более мелкие части индексируя разбиение в слое разрядным числом j_m. Объединение проекций доменов каждого слоя всегда образует эфферент сети, таким образом, имеем:

$$Eff\left(\Gamma\right) = \vec{Y}^0 = \bigoplus_{j_0} \vec{Y}^1_{j_0} = \bigoplus_{j_0} \bigoplus_{j_1} \vec{Y}^2_{\langle j_0 j_1\rangle} = \cdots = \bigoplus_{j_0} \bigoplus_{j_1} \cdots \bigoplus_{j_{n-1}} \bigoplus_{j_{n-2}} \vec{Y}^{n-1}_{\langle j_0 j_1 \ldots j_{n-1} j_{n-2}\rangle}$$

В конечном слое эфферентные домены и их проекции совпадают, и каждый домен состоит только из одной вершины:

$$Dom_g\left(A^{n-1}_{j^{n-1}}\right) = \vec{Y}^{n-1}_{\langle j_0 j_1 \ldots j_{n-1} j_{n-2}\rangle} = A^{n-1}_{j^{n-1}}.$$

Номер вершины определяется кортежем $j^{n-1} = \left\langle j_0 j_1 \ldots j_{n-1} \right\rangle$. Процедура разбиения обеспечивает взаимно-однозначное соответствие номера эффе-

рентного домена кортежу индексов $j^m = \langle j_0 j_1 \dots j_{m-1} \rangle$ в каждом слое. Итерационный процесс по m в прямом и обратном направлении, связан с последовательной индексацией доменов в каждом слое ниже приведены символические формулы индексации афферентных и эфферентных доменов для четырёхслойной сети:

$$X^0 \langle i_1 i_2 i_3 \rangle \leftarrow X^1 \langle i_2 i_3 \rangle \leftarrow X^2 \langle i_3 \rangle \leftarrow X^3,$$
$$Y^0 \rightarrow Y^1 \langle j_0 \rangle \rightarrow Y^2 \langle j_0 j_1 \rangle \rightarrow Y^3 \langle j_0 j_1 j_2 \rangle.$$

Теорема 3. О морфологии слабосвязанной сети. В каждом слое слабосвязанной сети с одной компонентой связанности афферентные и эфферентные домены попарно пересекаются во всех возможных сочетаниях точно по одной вершине. Т.е. для каждой парной комбинации афферентного и эфферентного доменов существует единственная вершина $A^m_{z^m}$, такая что

$$Dom_p\left(A^m_{z^m}\right) \bigcap Dom_g\left(A^m_{z^m}\right) = A^m_{z^m}.$$

Доказательство. Нужно доказать, что во все парные сочетания разнотипных доменов имеют не пустое пересечение и что эти пересечения состоят только из одной вершины слоя.

Докажем первое. Предположим, что в слое m существует пара разнотипных доменов, которые не пересекаются по вершинам слоя. В этом случае вершины афферентного домена не связаны с частью вершин эфферента сети и поэтому в сети выделяется две правых юбки вершин не связанных между собой во всех последующих слоях. С другой стороны вершины эфферентного домена не связаны с частью вершин афферента сети и в сети выделяются две левых юбки не связанных между собой в предшествующих слоях. Поскольку домены не пресекаются, то в этом случае в сети существует две не связанные между собой компоненты, что противоречит условию теоремы об однокомпонентности сети.

Докажем второе. Предположим, что домены пересекаются по двум вершинам A^m_1 и A^m_2. Тогда эта пара вершин имеет общую афферентную окрестность. Таким образом, в слое $m-1$ существует, по крайней мере, одна вершина A^{m-1}_k, связанная с вершинами A^m_1 и A^m_2, и её эфферент по условию морфогенеза (1) должен быть равен прямой сумме эфферентов вершин её аксоновой окрестности. В эту прямую сумму входят и вершины A^m_1 и A^m_2, но поскольку по предположению они принадлежат одному эфферентному домену слоя, то для них выполняется $Eff\left(A^m_1\right) \cap Eff\left(A^m_2\right) \neq \varnothing$ (рис. 2). Таким образом, мы пришли к нарушению условия морфогенеза (1)

по эфферентам вершин. Аналогично это положение доказывается с использованием эфферентной окрестности пары вершин A_1^m и A_2^m. ■

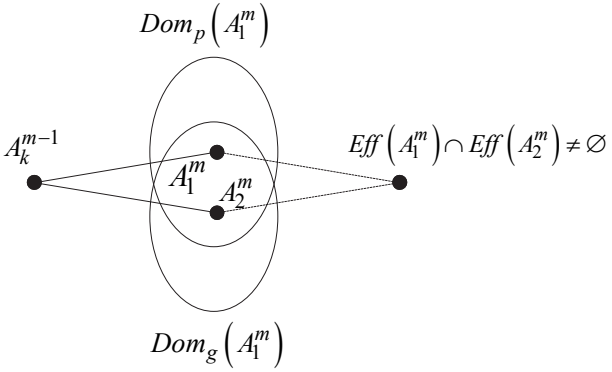

Рис. 2. Теорема о морфологии слабосвязанной сети

Из этой теоремы следует, что для самоподобной сети существует взаимно-однозначное соответствие между номером вершины в пределах слоя и индексами пары пересекающихся разнотипных доменов. Соответствие может быть задано кортежем:

$$z^m = \left\langle j_0 j_1 \cdots j_{m-1} i_{m+1} i_{m+2} \cdots i_{n-1} \right\rangle .$$

В этом кортеже допустима любая перестановка индексов.

4. Граф самоподобной сети

Из выражения (2), для слоя $m-1$ получим:

$$z^{m-1} = \left\langle j_0 j_1 \cdots j_{m-2} i_m i_{m+1} \cdots i_{n-1} \right\rangle . \qquad (2)$$

Вершины смежных слоёв m и $m-1$ связаны дугой, если их афференты пересекаются. Афферент вершины z^{m-1} определяется разрядными числами кортежа $\left\langle i_m i_{m+1} \cdots i_{n-1} \right\rangle$, а вершины z^m разрядными числами кортежа $\left\langle i_{m+1} i_{m+2} \cdots i_{n-1} \right\rangle$, пересечение афферентов возможно только в том случае, когда одноименные разряды в приведённых кортежах будут совпадать. Такой же вывод можно сделать, используя условия пресечения эфферентов смежных слоев m и $m+1$: вершины будут связаны дугой, если в кортежах

$\langle j_0 j_1 \cdots j_{m-1} \rangle$ и $\langle j_0 j_1 \cdots j_{m-1} j_m \rangle$ одноименные разряды будут совпадать. Полученные правила позволяют достаточно просто выполнить построение графического образа самоподобной модульной сети. На рис. 3 показан пример построения четырехслойной самоподобной сети для варианта, когда для всех m индексы принимают значения $i_m = \{0,1\}$ и $j_m = \{0,1\}$.

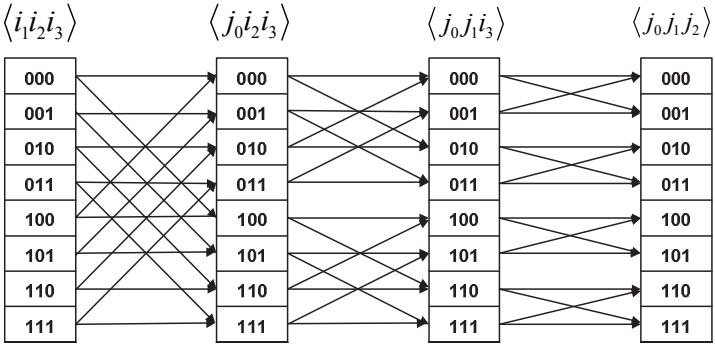

Рис. 3. Четырехслойная самоподобная модульная сеть

Построенная модель полностью описывается лингвистическим предложением:

$$\left[\langle i_1 i_2 i_3 \rangle \langle j_0 i_2 i_3 \rangle \langle j_0 j_1 i_3 \rangle \langle j_0 j_1 j_2 \rangle\right].$$

Здесь каждое слово предложения представляет кортеж z^m номера вершины сети. В словах предложения допустима любая перестановка индексов.

Заключение

В работе показано, что математическая модель самоподобия может быть распространена на многослойные сети. При этом доказано, что структура самодобной сети может быть выражена аналитически и описана лингвистической моделью. В работах автора [7, 8] представлены алгоритмы настройки слабосвязанных сетей для реализации быстрых спектральных преобразований. Самоподобие и регулярность слабосвязанных сетей обеспечивают уникальную возможность аналитического представления топологии реализующей сети, что позволяет разработать алгоритмы обучения нейронных сетей, абсолютно-сходящиеся за конечное число шагов. Кроме

того, существует вариант аналитического расширения топологии самоподобной сети который приводит к архитектурам глубоких нейронных сетей, сохраняющих быструю абсолютную сходимость алгоритмов обучения [9].

Список литературы

1. Lorente de No R. Studies on structure of the cerebral cortex // J.Psychol. Neurol. 1933. V. 45. P. 381–392.

2. Mauntcastle V.B. Powell T.P. Central nervous mechanisms subserving position sense and kinesthesis // Bull. John Hopkins Hosp. 1959. V. 105. P. 173–182.

3. Маункасл В. Организующий принцип функции мозга – элементарный модуль и распределенная система // Дж. Эдельман, В. Маункасл. Разумный мозг: Кортикальная организация и селекция групп в теории высших функций головного мозга / Пер. с англ. Н.Ю. Алексеенко; под ред. Е.К. Соколова. М.: Мир, 1981. 133 с.

4. Rockel A.J., Hiorns R.W., Powell T.P. Numbers of neurons through fall depth of neocortex // Proc. Anat. Soc. Cr. Br. Iro. 1974. 118, 371.

5. Кэндел Э. Малые системы нейронов. / В кн. Мозг. Д. Хьюбел, Ч. Стивенс и др. М.: Мир, 1984. 280 с.

6. Дорогов А.Ю. Быстрые нейронные сети: Проектирование, настройка, приложения. // Лекции по нейроинформатике Ч. 1. В тр. школы-семинара «Современные проблемы нейроинформатики», науч.-техн. конф. «Нейроинформатика-2004». 28–30 января 2004 г. Москва. М.: МИФИ, 2004. С. 69–135.

7. Дорогов А.Ю. Быстрые нейронные сети: Проектирование, настройка, приложения. // Лекции по нейроинформатике Ч. 1. В тр. школы-семинара «Современные проблемы нейроинформатики», науч.-техн. конф. «Нейроинформатика-2004». 28–30 января 2004 г. Москва. М.: МИФИ, 2004. С. 69–135.

8. Дорогов А.Ю. Теория и проектирование быстрых перестраиваемых преобразований и слабосвязанных нейронных сетей. СПб.: Политехника, 2014. 328 с.

9. Дорогов А.Ю. Быстрые нейронные сети глубокого обучения. Сборник докладов III Международной научной конференции по проблемам управления в технических системах (CTS'2019), Санкт-Петербург. 30 октября – 1 ноября 2019 г. СПб.: СПбГЭТУ «ЛЭТИ», 2019. С. 275–280.

Секция 4

Нейросетевые системы обработки данных, распознавания образов и управления

R. SHIRIYAZDANOV[1], N. RUDNEV[2], K. USTYUZHANIN[2]
[1]Gaschemengineering LCC, Ufa
[2]Ufa State Petroleum Technological University
Mikrukov.aa@rea.ru

APPLICATION OF NEURAL NETWORK ALGORITHMS IN MODELLING AND OPTIMIZATION OF CHEMICAL PROCESSES

Several of the presented works performed by the authors have shown effectiveness of application of neural networks in modelling of the chemical and technological processes. Economic effect of using machine learning model as a part of control system is an ability to create predictive control circuits and manage plant's operation plan. A need to obtain more data for models also pushes large industrial enterprises to accumulate information about their activities and treats it as a valuable resource while simultaneously increasing their experience in use.

A process of creating a machine learning model without having vast amounts of data is possibly by using transitive learning is laid into foundation of a novel information system for process control.

Keywords: *neural network, chemical technology, rectification, catalytic process, machine learning, transitive learning.*

1. Addressing problem of data shortage

1.1. Introduction

At present, automated analyzers for determining the main quality indicators of oil and petroleum products have already been developed and are being implemented in the practice of factory laboratories, which also include various algorithmic procedures [1–5]. An idea of using artificial intelligence in the control circuits gives an opportunity to improve quality of the product by introducing quality-based control. This task contains two major problems:

Little laboratory/historic data about flow composition and its properties:

Complexity of relations between physical properties and chemical compound properties that result in inability of draw a definite line between «good» performance and «bad» performance of the plant.

Researchers offer various options for reducing the number of laboratory analyses by predicting with high accuracy the missing features of products and evaluating the optimal parameters of the chemical process.

Shortage of historic data, however, prevents from using machine learning to predict relative quality with confidence: sometimes, there is much more types of analyses than there are data entries. In that case, there also occurs a need of using meta-parameters, for example, generated through PCA or Korhonen maps.

1.2. Simulation modelling as a source of data for machine learning

In the practice of optimizing refining and petrochemical processes, simulation models of chemical processes are often used, created in the calculation and modeling programs such as: Aspen Plus, Hysys, Unisim Design, WinSim, PRO II, ChemCAD, and others. The physical and chemical models obtained in this way are often called digital doubles [7].

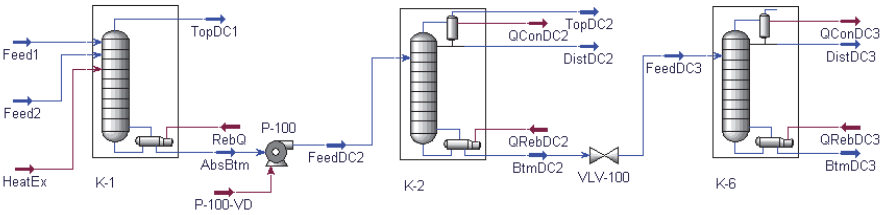

Fig. 1. Schematic of the gas fractionation unit simulation model in Unisim Design

Base simulation model could be created in Honeywell's Unisim Design system. An example of such model is a gas fractionation unit (HFC) and (see Fig. 1).

The initial data for creating the model were the HFC process regulations and documentation. In the Unisim Design environment, various unit states were modeled to ensure the representativity of training dataset. When modeling we were interested in such features of the column operation:

Flow of crude oil and product flows

Temperature of crude oil and of the product flows

Column overhead and bottom temperatures

Pressure of crude oil and product flows

Column overhead and bottom pressures
The composition of the crude oil stream
Products composition

This model could be used to obtain process and quality data of the unit operation to pretrain the neural network model. Assuming such model could function at least equally to the Unisim simulation we could later obtain more relevant data during process monitoring. Risk of the pretrained model deviation from the simulation is hereby equal to risk of the simulation to deviate from the real process. If the structure of the neural network is not prone to underfitting and the data that could be obtained from the simulation is unlimited, then it is logical to conclude that model can be used as a substitute of such simulation.

1.3. Quality evaluation

Second part of the data shortage problem is evaluating quality of the product flow, for example of such features as: crude oil temperature, overhead pressure, bottom pressure, upper refluxing flow, central refluxing flow, steam heating flow, reboiler heating flow, distillate heat branching, kerosene heat branching, diesel heat branching, heat takeoff, overhead heat takeoff, e.t.c. In most cases, such analyses could be obtained once in a shift which makes data gathering a lengthy procedure. Moreover, resulting quality could not be simplified to a scalar value which makes it hard to evaluate current technological regime as successful or faulty. Instead, we propose to use a meta-value that encapsulates different flow properties into a single scalar.

One way is to use Kohonen maps [7] for rapid assessment of the state of the oil rectification process at the atmospheric vacuum tube and crude-oil distillation unit (CDU) for purpose of giving the plant operators an ability to develop optimization strategies and predict possible outcomes of their decisions. The resulting separation is used as a template for defining different regimes of the unit as a neighborhood of similar physical states will show similar performance.

After obtaining a dataset of following features let's analyze the contribution and influence of each of them on the value of the quality of products.

The important features are (choice): the quality of distillate, the quality of diesel and kerosene. One can also add the quality of the remainder, but here one need to specify that almost impossible to get all the products at once in the best quality – that's why we choose the target products – one can also select consumption as a main feature.

Here, the output features are the quality of distillate, kerosene and diesel fuel. The features depend on each other, so they may not be included as a feature in the training example.

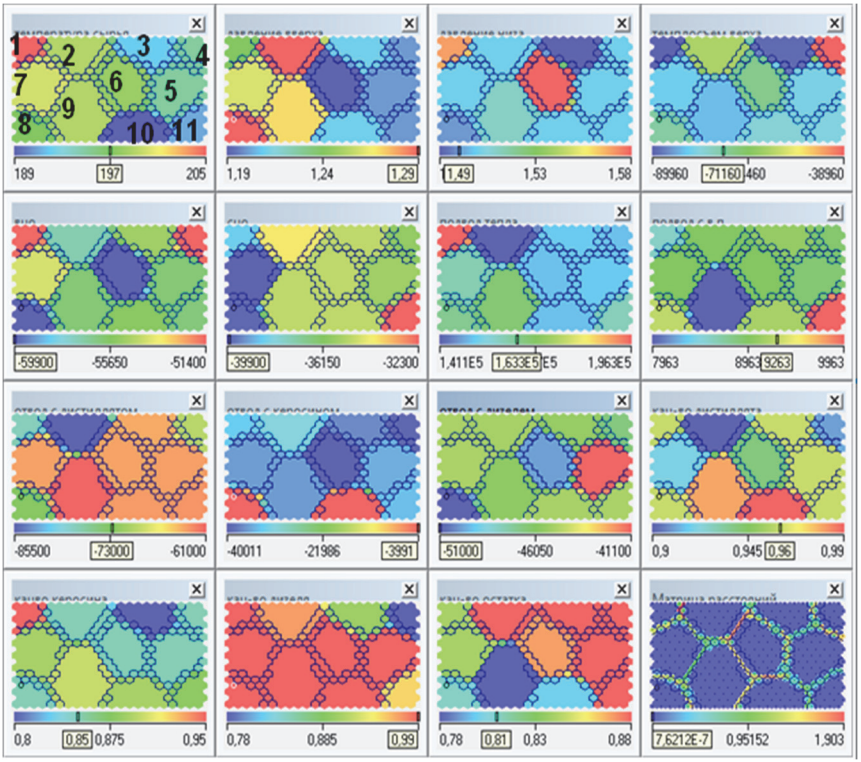

Fig. 2. Kohonen maps depicting clustering of quality of the DCU products

A set of significant clusters was obtained (see Fig. 2):

very good quality distillate (gasoline)

good quality diesel fuel

kerosene quality is good enough (in this case, we are focusing on excellent quality commercial products-diesel fuel and gasoline).

In all the analyses above, we searched for areas with signs (required: good quality distillate and diesel fuel; preferably: good quality of kerosene and residue). Clusters under numbers 7, 6 and 5 are marked as zones of medium quality; clusters with numbers 8 to 11 provide insignificant quality and marked as zones of poor quality.

This clustering will be use as target data for neural network predictor.

2. Neural network architecture evaluation and optimization

The neural network was created in the MathWorks Matlab R2013b system. We chose the network architecture for forward propagation of the signal and reverse propagation of the error. We formed the network using the fitnet function. The network consists of three layers. The number of neurons in the input layer is 32, the number of neurons in the hidden layer is 10, and the number of output neurons is 27.

The sigmoid logistic and linear functions for the hidden and output layers, respectively, were selected as neuronal activation functions. The number of neurons in the input layer was chosen because the training data is a vector with 32 elements. These elements represent the corresponding feature of the unit (temperature, pressure, etc.). The number of hidden layer neurons equal to ten is optimal for this network, since it provides the least error.

Several neural networks were created with different numbers of N neurons in the hidden layer. With a smaller number of neurons, the network is not able to reproduce the process; with a larger number of neurons, the phenomenon of overfitting appears.

After determining the number of network layers and the number of neurons in each of them, one need to assign values of weights and offsets that minimize the decision error.

The Levenberg-Marquardt algorithm with Bayes regularization (trainbr function) was chosen as the training algorithm. The group training method was chosen when a static model was being created. To create a dynamic model, one should use a sequential learning method. We obtained data for network training and testing from the Unisim Design environment using the OLE real-time connection.

3. System architecture

The neural network model obtained in this way is used as a part of the Information System (IS), which will allow creating control, diagnostics and decision support systems based on it (issuing recommendations to operators) for various technological installations. The flowchart is shown on Fig. 3.

Simulations and neural network models of two other processes were constructed in the same way: primary oil distillation columns and primary oil treatment plants. Such design allows online retraining of the model in the process control environment.

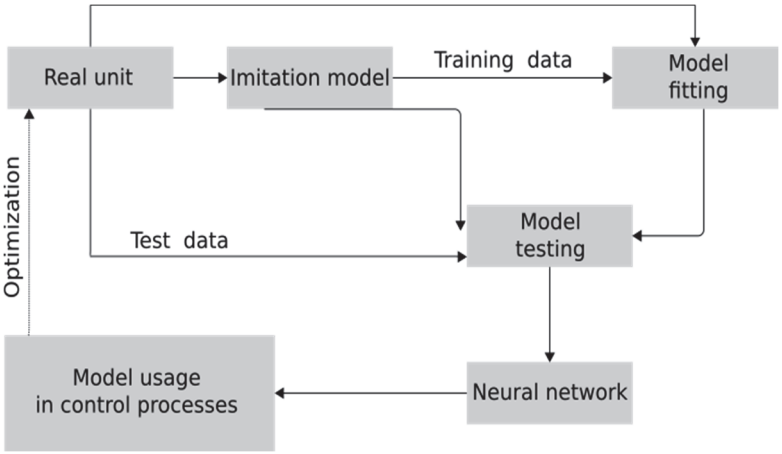

Fig. 3. Information System (IS) flowchart

Transitivity of learning will be achieved by using real process data in fitting of an imitation model (Unisim Simulation) that will be used as a «sandbox» for process optimization procedures and control strategy evaluation.

The most difficult problems for modeling in petrochemistry and oil refining are the problems of constructing an adequate mathematical model of heterogeneous-catalytic processes. Quite often, the first stage of such work is to build a digital double of such a process using a neural network algorithm, and then use such a double when searching for an optimal solution. To automate the construction of neural network models, a tool was developed that allows creating virtual quality analyzers based on experimental or industrial data. It was used to create three neural network models with The LSTM architecture: oxidative and thermal dehydrogenation of ethane, Hydrotreating of diesel fuel [6], and alkylation of isobutane with olefins on zeolite-containing catalysts.

4. Results

In this paper, several models based on neural networks were described.

A neural network model of a chemical process performs calculations orders of magnitude faster than a model built for example in the UniSim Design environment. Also, the advantages of neural network modeling can be attributed to the simplicity of model development in comparison with the physical and chemical model of a heterogeneous-catalytic process in the presence of data from a

real object. In the future, the model can be implemented in the working environment of the enterprise or the modeling program UniSim Design as an extension.

The neural network models obtained in this way can be used as part of information systems that will allow creating control, diagnostics, and decision support systems (issuing recommendations to operators) for various technological installations.

References

1. Stratiev D.S, Shishkova I.K, Nikolaychuk E., Sharafutdinov I.M., Vely A., Mitkova M., Yordanov D., Rudnev N. (2016) Relationship of the aromatic structural types in vacuum gas oil to empirical correlations based on bulk properties. Petroleum Science and Technology 34:860–865 . https://doi.org/10.1080/10916466.2016.1170845

2. Bahtadze N.N. (2004) Virtual'nye analizatory (identifikacionnyj podhod). Avtomatika i telemehanika 3–24 [in Russian].

3. Verevkin A.P., Denisov S.V., Murtazin T.M., Ustjuzhanin K.J. (2019) Podgotovka dannyh dlja postroenija vir-tual'nyh analizatorov v zadachah usovershenstvovannogo upravlenija. Avtomati-zacija v promyshlennosti [In Russian].

4. Tugashova L.G. (2013) Virtual'nye analizatory pokazatelej kachestva processa rektifikacii. Jelektrotehnicheskie i informacionnye kompleksy i sistemy 9: [in Russian]

5. Digo G.B., Digo N.B., Mozharovskij I.S., Torgashov A.J. (2011) Issledovanie meto-dov identifikacii modelej virtual'nyh analizatorov pokazatelej kachestva rektifikacionnoj kolonny. Modelirovanie sistem 30 [in Russian].

6. Teljashev e.G., Shirijazdanov R.R., Rudnev N.A., Ustjuzhanin K.J., Harickij D.K. (2019) Cifrovoj dvojnik Modelirovanie processa gidrooblagorazhivanija neftjanyh frakcij s primeneniem metodov mashinnogo obuchenija. Delovoj Zhurnal Neftegaz.ru 60–65 [in Russian]

7. Kohonen T. (2001) Self-Organizing Maps, 3rd ed. Springer-Verlag, Berlin Heidelberg.

8. Dan Foresee F., Hagan M.T. (1997) Gauss-Newton approximation to Bayesian learning. In: Proceedings of International Conference on Neural Networks (ICNN'97). IEEE, Houston, TX, USA, pp 1930–1935

9. MacKay DJC (1992) Bayesian Interpolation. Neural Computation 4:415–447. https://doi.org/10.1162/neco.1992.4.3.415

А.А. МИКРЮКОВ, М.Е. МАЗУРОВ
Институт цифровой экономики и информационных технологий РЭУ им. Г.В. Плеханова, Москва
Mikrukov.aa@rea.ru

КОГНИТИВНАЯ МОДЕЛЬ СЦЕНАРНОГО ПРОГНОЗИРОВАНИЯ ОСНОВНЫХ ВЕКТОРОВ ИНТЕРНАЦИОНАЛИЗАЦИИ ДЕЯТЕЛЬНОСТИ УНИВЕРСИТЕТА*

Целью работы является обоснование и прогнозирование мероприятий для обеспечения приращений значений целевых показателей (индикаторов) деятельности университета в международном институциональном рейтинге *QS* до величин, требуемых для вхождения университета в ТОП-500 вузов в 2025 г. Полученный в результате моделирования сценарий планирования мероприятий позволил обосновать величину необходимых приращений значений выявленных латентных факторов, влияющих на целевые показатели и обеспечивающих гарантированное достижение требуемого значения главного показателя (функционала).

Ключевые слова: *когнитивная модель, сценарное прогнозирование, целевые показатели, институциональный рейтинг.*

Введение

Актуальность решаемой задачи обусловлена необходимостью разработки научно-обоснованных предложений по достижению требуемых значений целевых показателей деятельности университета к 2025г. путем расчета необходимых приращений латентных факторов (частных показателей) с учетом их корреляционных взаимосвязей с целевыми показателями. В свою очередь главный показатель, называемый функционалом F (он же – рейтинг университета R), рассчитывается как сумма произведений значений целевых показателей на их весовые коэффициенты [1].

Проведенный анализ поставленной задачи показал, что она относится к классу слабоструктурированных задач, которая решается в условиях ограниченного количества исходных данных и ряда неопределенностей.

* Работа выполнена при финансовой поддержке РФФИ (проекты №№ 18-07-00918А, 19-07-01137, 20-07-00926А).

Для решения поставленной задачи используется методология когнитивного моделирования, предназначенная для анализа и принятия решений в плохо определенных ситуациях и, в частности, метод сценарного прогнозирования (планирования) на основе когнитивных карт (карт познания), который позволяет выбрать наиболее предпочтительную альтернативу [2].

Сценарное прогнозирование показателей деятельности университета на основе когнитивной модели

В контексте рассматриваемой задачи под сценарием понимается динамическая последовательность возможных событий изменения значений факторов – причин и факторов – следствий, влияющих на целевые показатели [3]. Причинно-следственные связи между этими событиями и точками принятии решений способны изменить их ход и траекторию движения во времени всей рассматриваемой системы показателей, а, значит, выбрать наиболее предпочтительный вариант траектории.

Для решения поставленной задачи предложен подход к сценарному прогнозированию на основе когнитивной карты, который включает следующие этапы [4]:

- генерирование сценариев и оценка рисков;
- корректировка сценариев через дискретные интервалы времени (в нашем случае, ежегодно) с учетом достигнутых значений места в рейтинге QS функционала и индикаторов.

На первом этапе исследования проведена идентификация и интерпретация скрытых (латентных факторов), влияющих на целевые показатели, и оценка их значимости с использованием методов факторного анализа [5–8].

На следующем этапе разработана когнитивная модель, на основе которой решена задача сценарного прогнозирования показателей деятельности университета. Разработка когнитивной модели основана на построении когнитивной карты в виде знакового ориентированного графа [9, 10].

С учетом полученных на основе факторного анализа в работе [8] значений корреляционных зависимостей между функционалом и целевыми показателями, а также экспертными оценками взаимовлияния латентных факторов и их влияния на целевые показатели построена когнитивная модель (карта), отражающая взаимосвязи латентных факторов, целевых показателей и функционала (рис. 1).

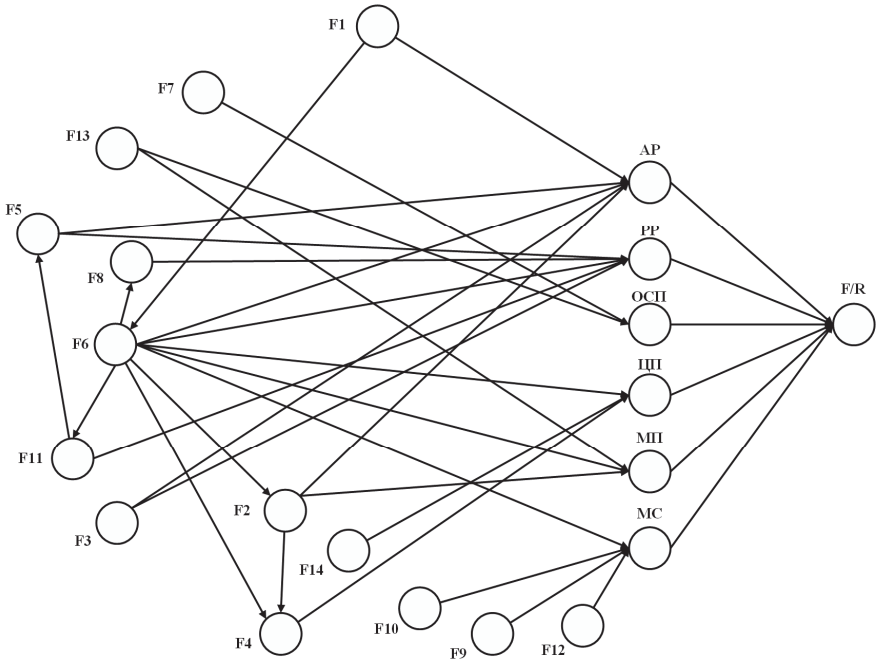

Рис.1. Когнитивная модель взаимосвязи латентных факторов, целевых показателей и функционала:

F – функционал; *R* – рейтинг университета; целевые показатели: *AP* – академическая репутация; *PP* – репутация у работодателя; *ОСП* – отношение числа студентов к числу преподавателей; *ЦП* – показатель цитируемости преподавателей; *МП* – число международных преподавателей; *МС* – число международных студентов; латентные факторы: F_1 – «Научные школы и диссертационные советы»; F_2 – «Совместные научные проекты»; F_3 – «Наличие базовых кафедр»; F_4 – «Число публикаций в БД Scopus»; F_5 – «Востребованные направления подготовки»; F_6 – «Уровень квалификации научно-педагогических работников (НПР)»; F_7 – «Число НПР»; F_8 – «Уровень компетенций студентов»; F_9 – «НПР с языковой подготовкой»; F_{10} – «Места в общежитии»; F_{11} – «Востребованность выпускников у работодателей»; F_{12} – «Площади для образовательной деятельности»; F_{13} – «Уровень оплаты НПР»; F_{14} – «Стимулирующие факторы»

В общем случае формализация задачи на основе когнитивной карты заключается в следующем. Модель ситуации задается четверкой $\langle F, X, X(0),$

$W\rangle$, где F – множество признаков (характеристик) ситуации, X – множество состояний, $X(0) = (x_{11}^0, x_{12}^0, ..., x_{nm}^0)$ – начальное состояние, W – матрица смежности функционального орграфа, отражающая взаимосвязи между вершинами n, m когнитивной карты, $X^G = (x_{11}^g, x_{12}^g, ..., x_{nm}^g)$ – желаемое состояние [8–10].

Необходимо найти целевой вектор приращений $G = (p_{1j}, p_{2j}, ..., p_{nm})$, где $p_{11} = x_{11}^g - x_{11}^0$, $p_{12} = x_{12}^g - x_{12}^0$ и т. д. Целевой вектор приращений G показывает, в каком направлении и насколько нужно изменить значения признаков в начальном состоянии $X(0)$, чтобы перейти в целевое состояние X^G.

Обозначим латентные факторы, влияющие на целевые показатели (рис. 1), факторами-причинами, целевые показатели – факторами-следствиями, а функционал – целевым фактором. Сила взаимовлияния факторов-причин и сила влияния факторов-причин на факторы-следствия определены на основе метода экспертного оценивания (метода парных сравнений Саати) [12].

Сценарный анализ поведения системы проведен на ее когнитивной модели путем импульсного моделирования. Формула импульсного процесса имеет вид [13, 14]:

$$x_i(n+1) = x_i(n) + \sum_{j=1}^{k-1} f_{ij} P_j(n) + Q_i(n), \quad (1)$$

где $x_i(n)$ – величина импульса в i -й вершине когнитивной модели в предыдущий момент (такт моделирования) n, $x_i(n+1)$ – в интересующий момент $(n+1)$; f_{ij} – коэффициент преобразования импульса; $P_j(n)$ – значение импульса в вершинах, смежных с i-й вершиной; $Q_i(n)$ – вектор возмущений и управляющих воздействий, вносимых в i-ю вершину в момент n.

Набор реализаций импульсных процессов представляет собой «сценарий развития» и указывает на возможные тенденции развития ситуаций. Ситуация в импульсном моделировании определяется набором всех возмущений и управляющих значений Q и значений импульсов X в каждом такте моделирования.

На временной оси приращение значений факторов в дискретные моменты времени можно представить в виде линейной зависимости [14]:

$$x_i(t+1) = x_i(t) + \sum_{j \in I_i} a_{ij} \left(x_j(t) - x_j(t-1) \right), i = 1, \dots, N, \quad (2)$$

при известных начальных значениях факторов $(x(0))_{i \in N}$ и их начальных приращениях $(x_i(0) - x_i(-1))_{i \in N}$.

Здесь $x_i(t+1)$ и $x_i(t)$ — значения i-го фактора соответственно в моменты времени $t+1$ и t; $x_j(t) - x_j(t-1) = \Delta x_j(t)$ – приращение фактора x_j в момент

времени t; a_{ij} – вес влияния фактора x_i на фактор x_j; I_i – количество факторов, непосредственно влияющих на фактор x_i; N — количество факторов (вершин графа).

Если ввести импульсы («скорости») $p_j(t) = \Delta x_j(t)$, то динамика системы может быть представлена следующим уравнением:

$$p_i(t+1) = x_i(t) + \sum_{j \epsilon I_i} a_{ij}\, p_j(t) + p_j^0(t), \qquad (3)$$

где $p_j^0(t)$ – внешний импульс, вносимый в вершину i в момент t.

Обозначим через u_i внешний вход в вершину i, в этом случае получим

$$p_i{}^0(t+1) = u_i(t+1) - u(t). \qquad (4)$$

Пусть $x_i(t) = 0$, $t < 0$, $i = 1, ..., N$, а внешние импульсы подаются, начиная с $t = 0$. Тогда в соответствии с (3) и (4) получим

$$x_i(t+1) = \sum_{i,j} a_{ij}\, x_j(t) + u_j^0(t), i = 1, \ldots, N \qquad (5)$$

или в матричной форме

$$x(t+1) = (I + A)\, x(t) + Bu(t), \qquad (6)$$

где $A = ||a_{ij}||$ – матрица смежности размера $N \times N$ графа когнитивной карты, I – единичная матрица $N \times N$; $u = (u_1, ..., u_M)^T$ – вектор внешних управляющих воздействий; B – (0,1) – матрица размера $N \times M$, ненулевые элементы которой указывают точки приложения управлений.

Таким образом, после описания взаимосвязей между факторами с помощью уравнений, задания весов их взаимовлияний на основе экспертных оценок и значений начальных приращений факторов, можно анализировать динамику изменения факторов и развития системы показателей в целом [15–18].

Для того чтобы сформировать возможные стратегии развития системы, необходимо в первую очередь прогнозировать ее саморазвитие, т. е. изучить динамику изменения значений базовых ориентиров при отсутствии внешних управляющих воздействий. В результате такого прогноза получаем вектор значений факторов $x = (x_1, x_2, ..., x_N)$ в момент времени t. Динамика свободного движения состояния $x(t)$ описывается уравнением

$$x(t) = (I_N + A + A^2 + \ldots + A^t)\, x(0). \qquad (7)$$

Искомая совокупность управляющих воздействий определяется путем решения обратной задачи управления. В этом случае каждое управляющее воздействие $g(t)$ выбирается в виде «мгновенного» импульса величины $g(0)$, подаваемого в момент $t = 0$. Тогда динамика системы может быть описана уравнением [19, 20]:

$$x(t) = (I_N + A + A^2 + ... + A^t)\, x(0) + (I_N + A + A^k + ... + A^{i-1})\, Bg(0). \qquad (8)$$

Задача управления считается решенной, если в условиях заданных ограничений найден вектор управляющих воздействий $g^*(0)$, соответствующий альтернативному варианту (сценарию прогнозирования) приращения значений функционала и индикаторов до целевых значений за счет импульсных воздействий (приращений значений факторов), обеспечивающий гарантированное достижение поставленной цели с минимальным весом.

В этом случае значения целевых координат в установившемся состоянии модели совпадают с заданными целевыми значениями (координатами вектора g^*), что можно представить с учетом равенства (8) выражением:

$$g_{\text{уст}} = Cx_{\text{уст}} = CQx(0) + CQBg(0) = g^*, \quad (9)$$

где элементы матрицы C указывают, какие из факторов модели являются целевыми; $x_{уст}$ – установившееся состояние модели; g^* – заданный вектор цели.

Значения исходных данных, не имеющих количественный характер (Уровень квалификации НПР, Уровень компетенций студентов, Уровень квалификации НПР и др.) определены экспертным путем.

Последовательно задаваемые «слабые» приращения значений перечисленных выше факторов на уровне 10 %, позволили оценить чувствительность целевого показателя к управляющим воздействиям по данным направлениям регулирования, на основе чего была выбрана наиболее предпочтительная альтернатива сценарного прогнозирования.

Предварительные значения интенсивности взаимовлияния между измеримыми факторами когнитивной модели были установлены на основе корреляционного и факторного анализа [8]. Попарные корреляции между латентными факторами, установлены экспертным путем. Далее коэффициенты были уточнены сообразно логике перехода системы из одного стационарного состояния в другое в результате внешних импульсных воздействий.

С целью проверки адекватности когнитивной модели она была протестирована на ретроспективном периоде 2014–2019 гг. на основе имеющихся статистических данных по измеримым факторам модели. Общая корректность модели подтвердилась близостью рассчитанных на модели темпов прироста факторов к действительным темпам прироста.

Интерпретация результатов численного эксперимента на основе модели сценарного прогнозирования

Требуемые интенсивности воздействия на управляющие факторы в процентном отношении при заданном приращении целевого фактора вычислены в ходе сценарного моделирования. С учетом реально достижимых

значений латентных факторов на интервале 2019–2020 гг. выбран сценарий их приращения, представленный на рис. 2.

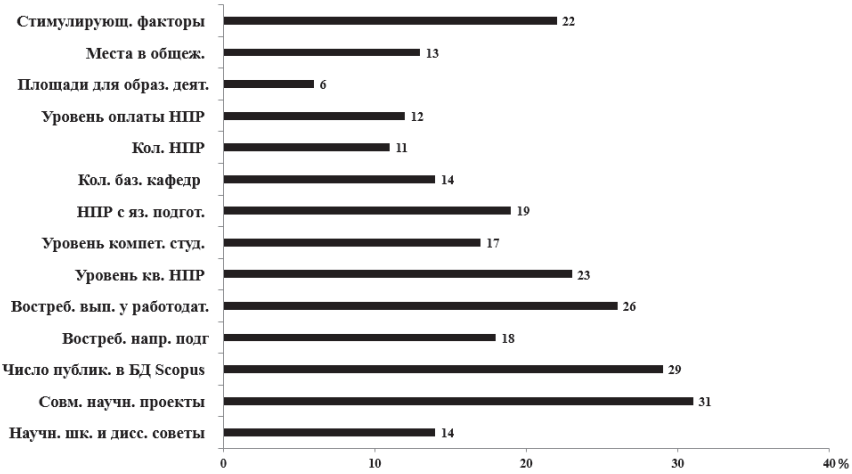

Рис. 2. Расчетные значения интенсивностей управляющих воздействий на латентные факторы в виде приращений в %

Наибольшая интенсивность воздействия потребуется для следующих латентных факторов: Совместные научные проекты, Число публикаций в БД Scopus, Востребованность выпускников у работодателей, а наименьшая – для латентных факторов: Количество НПР и Площади для образовательной деятельности.

Результаты расчета прогнозных значений показателей роста целевых показателей и функционала в 2020 г. представлены на рис. 3. Полученные результаты показали степень приращения в процентах каждого из целевых показателей с учетом выполненных воздействий на латентные факторы. Прирост значений целевых показателей должен привести к увеличению значения функционала на 12 %, т.е. достижению его планового значения.

В результате выполненных расчетов можно сделать следующие выводы:

Для гарантированного достижения значения функционала F = 26,89 к 2025 г., соответствующего 435 (451) месту в рейтинге *QS* необходимо ступенчатое (с интервалом в один год) наращивание значений целевых пока-

зателей с учетом влияющих на них латентных факторов. Величина очередного импульсного воздействия определяется с учетом текущих значений латентных факторов и целевых показателей.

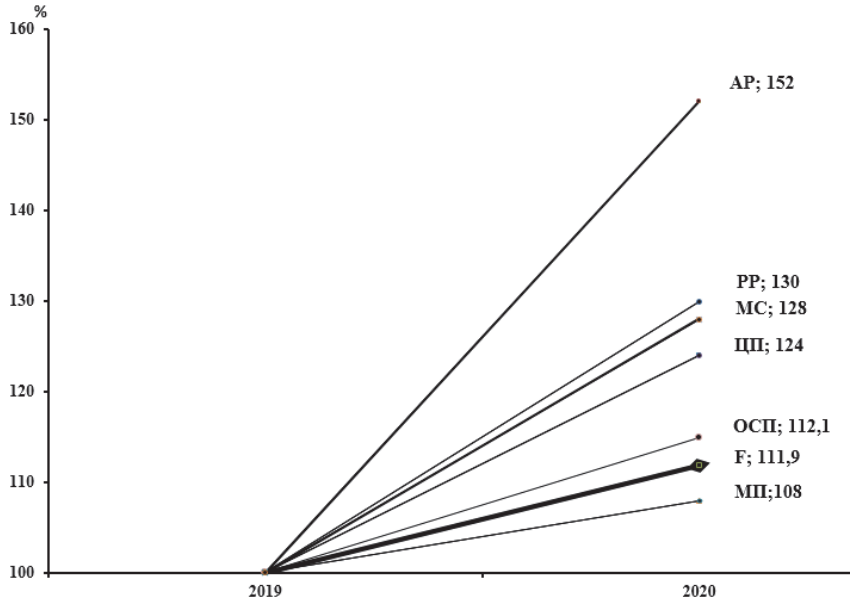

Рис. 3. Прогнозные показатели роста целевых показателей и функционала в 2020 г. по сравнению с 2019 г. (2019 г. – 100 %)

Заключение

Для достижения поставленной цели исследования обосновано применение методов решения слабо структурированных задач на основе разработки модели сценарного прогнозирования (планирования) с использованием когнитивных карт, которая позволила выбрать наиболее предпочтительную альтернативу. Предложенный подход позволяет в условиях заданных ограничений найти наиболее приемлемый сценарий планирования приращения значений функционала и целевых показателей до требуемых значений за счет импульсных воздействий на латентные факторы, обеспечивающих гарантированное достижение поставленной цели.

В ходе исследования решены следующие задачи: разработана когнитивная модель сценарного прогнозирования мероприятий по достижению требуемых значений целевых показателей деятельности университета в международном институциональном рейтинге QS, на основе разработанной модели проведен расчет наиболее предпочтительного варианта набора требуемых интенсивностей воздействия на управляющие переменные при заданном приращении значения целевого фактора.

Полученные результаты позволили сформировать сценарный план необходимого ступенчатого наращивания значений целевых показателей с учетом влияющих на них латентных факторов в интервале 2020–2025 гг.

Список литературы

1. Информационно-аналитическая система QS – analytics [Электронный ресурс]. Режим доступа: https://analytics.qs.com/#/signing (дата обращения 14. 11.2019).

2. Горелова Г.В., Захарова Е.Н, Родченко С.А. Исследование слабоструктурированных проблем социально-экономических систем: когнитивный подход. Ростов н/Д: Изд-во РГУ, 2006. 332 с.

3. Авдеева З. К., Коврига С. В., Макаренко Д. И., Максимов В. И., Когнитивный подход в управлении // Пробл. управл. Вып. 3. 2007. С. 2–8.

4. Болотова Л.С. Системы искусственного интеллекта: модели и технологии, основанные на знаниях: учебник / ФГБОУ РГУИТП; ФГАУ ГНИИ ИТТ «Информатика». М.: Финансы и статистика, 2012. 664 с.

5. Горидько Н.П. Современный экономический рост: теория и регрессионный анализ: Монография / Н.П. Горидько, Р.М. Нижегородцев. М.: Инфра-М, 2017. 444 с.

6. Дрейпер Н. Прикладной регрессионный анализ / Н. Дрейпер. М.: Вильямс И.Д., 2019. 912 с.

7. Соколов Г.А. Введение в регрессионный анализ и планирование регрессионных экспериментов в экономике: Учебное пособие / Г.А. Соколов, Р.В. Сагиотов. М.: Инфра-М, 2016. 352 с.

8. Микрюков А.А., Гаспариан М.С., Карпов Д. С. Разработка предложений по продвижению университета в международном институциональном рейтинге QS на основе методов статистического анализа. Статистика и Экономика. 2020;17(1):35–43.

9. Трахтенгерц Э.А. Компьютерная поддержка формирования целей и стратегий. М.: СИНТЕГ, 2005. 224 с.

10. Корноушенко Е.К., Максимов В.И. Управление ситуацией с использованием структурных свойств когнитивной карты // Тр. ИПУ РАН. Т. XI. 2000. С. 85–90.

11. Кузнецов О.П. Интеллектуализация поддержки управляющих решений и создание интеллектуальных систем // Пробл. управл. № 3.1. 2009. С. 64–72.

12. Саати Т. Принятие решений. Метод анализа иерархий: пер. с англ. М.: Радио и связь, 1993. 320 с.

13. Кульба В.В. Сценарный анализ динамики поведения социально-экономических систем / В.В. Кульба, Д.А. Кононов, С.С. Ковалеский и др. М.: ИПУ РАН, 2002. 122 с.

14. Максимов В.И. Структурно-целевой анализ развития социально-экономических ситуаций // Проблемы управления. 2005. № 3. С. 30–38.

15. Горелова Г.В., Мельник Э.В., Коровин Я.С. Когнитивный анализ, синтез, прогнозирование развития больших систем в интеллектуальных РИУС «Искусственный интеллект» 3’2010. С. 61–72.

16. Робертс Ф.С. Дискретные математические модели с приложениями к социальным, биологическим и экологическим задачам / Ф.С. Робертс. М.: Наука, 1986. 234 с.

17. Кульба В.В. Методы формирования сценариев развития социально-экономических систем / В.В. Кульба, Д.А. Кононов, С.А. Косяченко, А.Н. Шубин. М.: СИНТЕГ, 2004. 296 с.

18. Simon H. The Structure of Ill-structured Problems // Artificial Intelligence. 1973. Vol. 4. P. 181–202.

19. Когнитивный анализ и управление развитием ситуаций: материалы 1-й международной конференции. М.: ИПУ, 2001. 196 с.

20. Huff A. S. Mapping strategic thought. Chichester: Wiley,1990. P. 11–49.

M. PILGUN[1], A.A. KHARLAMOV[2]

[1]Institute of Linguistics, RAS, Moscow,

[2]Institute of Higher Nervous Activity and Neurophysiology, RAS, Moscow

mpilgun@iling-ran.ru

PREDICTIVE ANALYTICS OF DIGITAL CONFLICTS: A NEURAL NETWORK APPROACH

The paper presents the results of an analysis of the residents’ reaction to the implementation of road construction projects based on digital content to prevent urban conflicts. The material for the study was the data of social media on the construction of road transport facilities in Moscow, namely the imple-mentation of transport interchange hub projects. The study used the transdisciplinary approach. The study made it possible to identify conflictogenic digital zones and main causes of conflicts, to determine the level of social stress, to predict the growth directions of identified conflicts and to develop recommendations to neutralize the situation.

Keywords: *predictive analytics, social media, neural network technologies, perception, conflict.*

1. Introduction

Predictive analytics is becoming increasingly popular in various fields. It focuses on solve business problems, in various aspects of organizations to solve issue or improve their results [1]. Great opportunities for the development of predictive analytics are provided by Big Data and Data Mining [2; 3]. The theory, experimental modeling, system development, and validation of predictive health analytics actively develop integrating modern computational methods, advanced data science techniques, innovative biomedical applications, and impactful health analytics [4].

Social media has significantly expanded the empirical base of modern research, made it possible to conduct real-time analytics on large data sets. In particular, scientists have developed a broad range of cutting-edge computational methods applied to research in conflict dynamics, a variety of computational approaches from text mining and machine learning to agent-based modeling and social network analysis [5].

The purpose of this study is to analyze the reaction of residents to the implementation of road construction projects to prevent urban conflicts based on digital content.

1.1. Data

The material for the study was the data of social networks, microblogs, blogs, instant messengers, videos, forums and reviews dedicated to the construction of road transport facilities in Moscow (Michurinsky, Khovrino, Varshavskaya transport and interchange hubs). Date of collection: 1.08.19 00:00–30.09.19 23:59 (see Table 1).

Table 1

Quantitative parameters of the data set

HUB	Michurinsky ave.	Khovrino	Varshavskaya
Content volume	696 952	8 541 705	431 484
Messages	486	2 198	328
Active actors	404	159	118
Loyalty	0,4	1,1	41,0
Involvement	7 256	1 595	788
Audience	1 142 404	1 485 643	1 827 865

1.2. Method

The study used the transdisciplinary approach. To interpret the content, neural network text analysis, content analysis and sentiment analysis were used.

The topic structure of the database and the semantic network were identified and analyzed; an associative (content-addressable) search was performed, and the social stress index was calculated.

The degree of aggression was determined on the analysis of lexical marks of aggression determined expertly. The set l_i of lexical marks that make up the lexical mask $L = \{l_i\}, i = 1..I$ [6] was automatically ranked within the analyzed corpus of texts by determining their semantic weight r_i in this corpus [6]. Summing up the ranks of lexical marks weighted by the degree of their significance w_i in this subject domain assigned by an expert, makes it possible to calculate the integral degree of aggression present in the corpus texts: $W = \sum r_i w_i$.

1.3. Tools

Brand Analytics social media monitoring and analysis system was used as a tool for data collection; TextAnalyst technology was used for neural network text analysis; and the AutoMap service was used for content analysis.

2. Results and discussion

Sentiment analysis of the consolidated database showed that the content characterizing neutral and positive clusters included mostly official messages, which were of no interest for users. Negative connotation and aggression characterize the content generated by the actors. The main topics and concepts of the negative cluster are: the danger of industrial and environmental disasters, the danger of ecological disasters, the problem of spoil disposals, the increase in radiation background, the growth of cancerous diseases, hazards of the lives of citizens, the threat of the destruction of parks and squares, the threat of the destruction of architectural monuments, the growth of social tension, the danger of social upheaval, lowering the standard of living for local residents, the deterioration of transport communication quality within an area, noise from vehicles, pollution of the grounds, high-rise buildings (“human ant-hills”), deceiving the population under the guise of the hub construction, the construction of skyscrapers under the guise of building the hubs, fraud with the land of the natural complex, the illegal sale of Moscow land by the mayor, the need to change urban planning policies, the construction of hubs as an attempt to avoid solving the priority problems of

citizens , delayed construction, problems with the Lyubertsy sewage collector, construction of a Transport Logistic Center (TLC).

2.1. Michurinsky avenue hub

The key topics of the content characterizing the construction of the Michurinsky ave. hub are related to the hostile attitude of local residents to the construction, who believe that under the guise of building a hub, the Moscow authorities gave permission to a Chinese campaign to build skyscrapers:

«Mother of God, drive away Sobyanin!"

Such an appeal was written on the fence of the Chinese construction company CRCC by residents of Ramenki in protest against the construction of skyscrapers under the guise of the Michurinsky avenue hub.

The high level of the residents' aggression and their negative attitude is directed at the mayor of Moscow and the city's authorities, which are recognized as the main source of problems for citizens (Fig. 1).

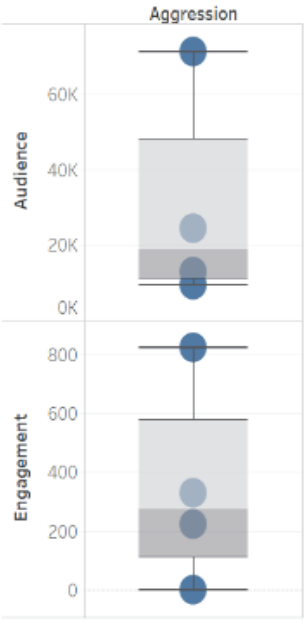

Fig. 1. Level of aggression in the user-generated content

«The fanatical desire of the mayor of Moscow to relocate half of the Russian Federation to Moscow is realized in large-scale housing construction in all areas of the city, both in the form of infill development and under the pretext of the so-called «renovation» program».

The protest against the development of the area is lasting, which increases the strength of the protest mood, demonstrates the residents' readiness to drastic measures. In addition, the negative connotation is also associated with political overtones, a negative attitude towards the Moscow government and the Presidential Administration (Fig. 2).

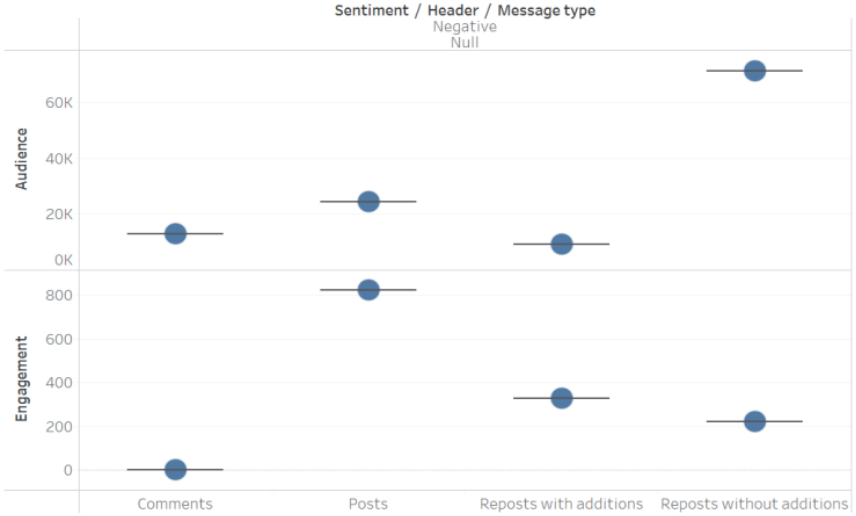

Fig. 2. Sentiment of the user-generated content

2.2. Khovrino hub

The key topics of the content dedicated to the Khovrino hub are negative and characterize the residents' discontent with the construction. The main points of the actors' protest content with a high level of aggression are: building human ant-hills; fraud with the land of the natural complex; the illegal sale of Moscow land by the mayor; environmental deterioration; the need to change urban planning policies (Fig. 3):

«Residents of #Khovrino made another protest trying to protect the last undeveloped site in the area from the construction by human ant-hills!»

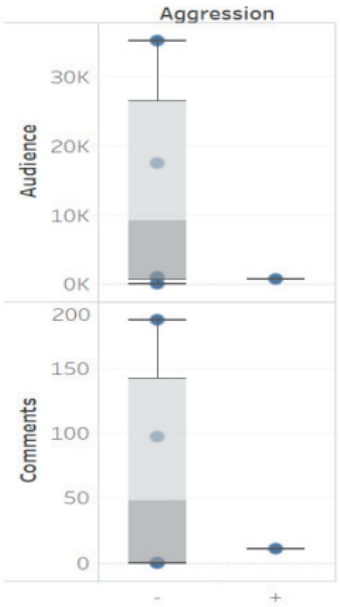

Fig. 3. Level of aggression in the user-generated content

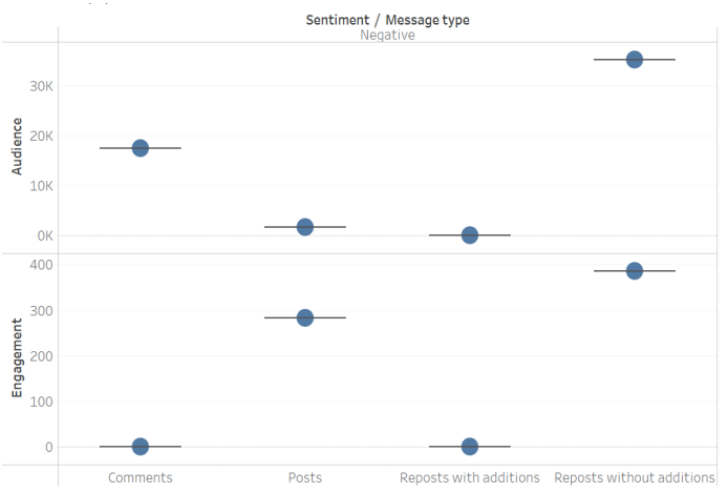

Fig. 4. Sentiment of the user-generated content

The negative connotation is related to content devoted to the following situations: worsening transport situation, construction of skyscrapers under the guise of hubs, lowering the standard of living for local residents, noise from vehicles, pollution of the grounds, and construction of a Transport Logistic Center (TLC). In addition, the residents' discontent with the construction of the hub is integrated with political protests of this period (Fig. 4).

2.3. Varshavskaya hub

The key topics of the content are formed by official messages on the progress of construction and are, naturally, characterized by a neutral and positive tone.

There is virtually no aggression in the analyzed content (Fig. 5).

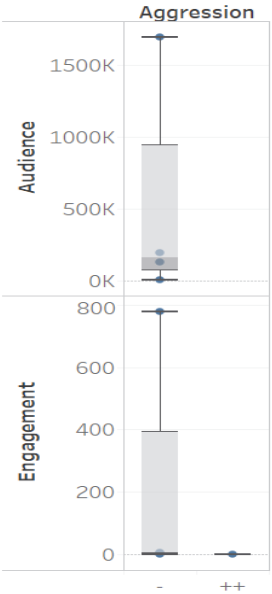

Fig. 5. Level of aggression in the user-generated content

Negative connotation arises in the users' messages associated with a limited range of problems: deceiving the population under the guise of the hub construction; deterioration of living conditions for local residents as a result of this construction; undifferentiated discontent (Fig. 6):

«Unintelligible project) Some kind of chaotic parking in the background. Here one should look only at the lobby. Hub objects are not shown on the renders.»

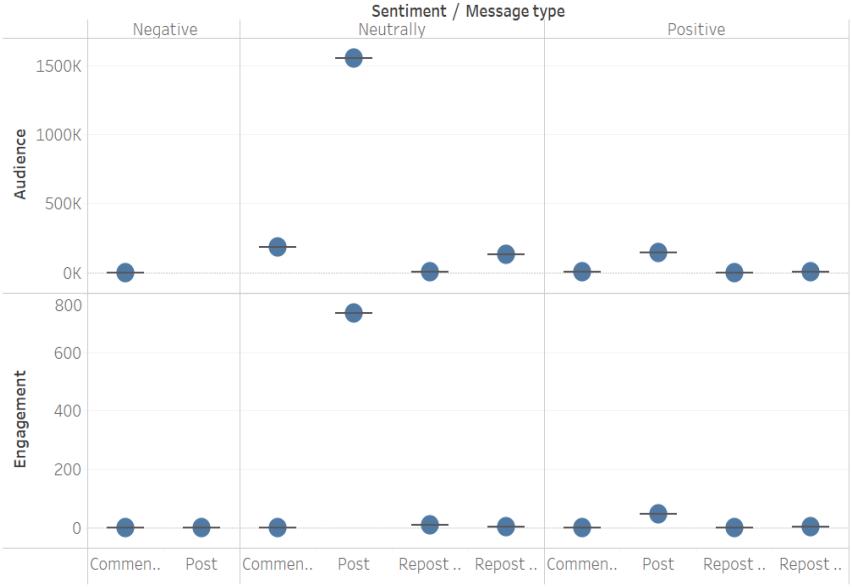

Fig. 6. Sentiment of the user-generated content

2.4. Social stress index calculation

To confirm the validity of the research results, the level of social stress was analyzed that characterizes the perception by the actors of all three road construction facilities (see Table 2). The method of analysis is presented in [6].

Table 2

Social stress index

Level of social stress	Facility	Social stress index
High level of social stress	Michurinsky avenue hub	12.2
Medium level of social stress	Khovrino hub	2
No social stress	Varshavskaya hub	0

Conclusion

Neutral and positive content is made up by official messages on the progress of construction, which do not attract attention and do not affect the perception of the situation by users.

The most dangerous conflict zone is the Michurinsky ave. hub. The user-generated content is characterized by a high degree of social stress; it allows predicting an escalation of the conflict between the residents and the city authorities, both in the online and offline space. The construction of Khovrino hub causes a medium degree of social stress; the analysis makes it possible to predict protest actions in the virtual space. The Varshavskaya hub project is characterized by the absence of social stress and bears no risks during implementation.

The construction of the hubs is perceived solely as an initiative and responsibility of Mayor Sergey Sobyanin and the city authorities. It has been observed that a negative user assessment of the Moscow Mayor's activities, the course of renovation in particular, is transferred to all transport projects.

The nature of user complaints is integrated; there are also the substitution of concepts and the transfer of conflict situations from the construction of similar facilities in Moscow and the Moscow Region (there are even associations with the Shies problem).

The residents' discontent with the construction of the hubs is correlated with political protests of the analyzed time period. Contexts with negative connotation are associated with the political problems of the election campaign at the Moscow City Duma in the summer of 2019. The greatest negativity is associated with actions in the interests or within the work of the United Russia party, which is obviously a reflection of the general emotional background of the protest media content.

Negative opinion and aggression are also associated with political overtones and a negative attitude towards the Moscow government and the Presidential Administration.

The analysis of the residents' reaction to the implementation of road construction projects on the basis of digital content material made it possible to identify conflictogenic digital zones and main causes of conflicts, to predict the growth directions of aggression and to develop recommendations to neutralize the situation and prevent urban conflicts.

References

1. McCarthy R.V., McCarthy M.M., Ceccucci W., Halawi L. Applying Predictive Analytics. Finding Value in Data. Heidelberg: Springer. 2019. 205 p.

2. Finlay S.: Predictive Analytics, Data Mining and Big Data. Myths, Misconceptions and Methods. Basingstoke Hampshire: Palgrave Macmillan. 2014. 260 p.

3. von der Hude M. Predictive Analytics und Data Mining Eine Einführung mit R. GmbH: Springer Vieweg. 2020. 224 p.

4. Dinov I.D. Data Science and Predictive Analytics. Biomedical and Health Applications using R. Heidelberg: Springer. 2018. 832 p.

5. Deutschmann, E., Lorenz J., Nardin L.G., Natalini D., Wilhelm A.F.X.: (eds.) Computational Conflict Research. Heidelberg: Springer. 2020. 264 p.

6. Kharlamov A.A., Pilgun M.A. (eds) Neuroinformatics and semantic representations. Theory and Applications. Newcastle upon Tyne: Cambridge Scholars Publishing. 2020. 317 p.

О.С. ЛИТВИНОВ, А.Н. ЗАБЕЛИН

Московский государственный технический университет им. Н.Э. Баумана

oleglitv@mtu-net.ru, z307s@yandex.ru

ОСОБЕННОСТИ ПОДАВЛЕНИЯ ШИРОКОПОЛОСНЫХ ПОМЕХ В АДАПТИВНЫХ АНТЕННЫХ РЕШЁТКАХ НА НЕЙРОСЕТЕВОМ УПРАВЛЕНИИ

Рассматривается задача оптимального приёма полезных сигналов адаптивными антенными решётками (ААР) в условиях сложной сигнально-помеховой обстановки. Показано, что нейросетевой алгоритм амплитудно-фазового управления в ААР обеспечивает среднее подавление помех в полосе частот до 10%, сравнимое по эффективности с традиционным алгоритмом адаптации методом прямого обращения матрицы. Также показана возможность сокращения объёма нейронной сети при значительном сокращении вычислительных затрат в задачах адаптации.

Ключевые слова: *адаптивные антенные решётки, широкополосные помехи, нейронные сети, диаграмма направленности.*

Введение

Для решения проблемы оптимального приёма полезных сигналов в условиях сложной сигнально-помеховой обстановки в современных радиоэлектронных системах возможно применение адаптивных антенных решёток (ААР) [1–5]. В процессе работы таких систем изменяются параметры полезных сигналов и помех: их количество, мощности, направления прихода, частотные полосы и т.д.

Использование нейронных сетей (НС) в качестве адаптивного процессора позволяет значительно расширить класс решаемых задач с помощью ААР, обеспечить высокую степень универсальности применения антенны для различных сценариев сигнально-помеховой обстановки (робастность), повысить скорость адаптации за счёт организации параллельных вычислений, повысить отказоустойчивость адаптивного процессора и обеспечить масштабируемость при реализации на сверхбольших интегральных схемах [6–10].

В данной работе было проведено обучение и оптимизация двух НС прямого распространения различного объёма для задач адаптации. Обучающая выборка составлялась на основе традиционного алгоритма адаптации методом прямого обращения матрицы по критерию максимума отношения сигнал/(шум+помеха) (ОСШП). Далее было проведено сравнение усреднённых характеристик подавления помех нейросетевыми алгоритмами амплитудно-фазового управления ААР и традиционным алгоритмом адаптации.

Применение рассмотренных алгоритмов возможно в системах связи, радиолокации, радионавигации и других сферах, где требуется повысить качество принимаемых сигналов.

Адаптивная антенная решётка

Адаптивная антенная решётка (ААР) – антенная система, параметры которой автоматически изменяются для обеспечения наилучшего приёма полезного сигнала на фоне изменяющихся внешних воздействий [1].

Получение желаемой ДН в отсутствии помехи обеспечивают *весовые коэффициенты* (ВК), при наличии помехи они служат для её подавления. На рис. 1 приведена структурная схема ААР, состоящая из самой антенной решётки, адаптивного процессора и диаграммообразующей схемы [2].

На антенную решётку (АР) приходит гармонический сигнал, состоящий из полезного сигнала и сигнала помехи: $X = S + J$. Каждый приёмный элемент вырабатывает свой отклик на принятый сигнал в виде комплексной амплитуды, и отправляет его в адаптивный процессор (блок обработки сигналов), который вычисляет наилучшие весовые коэффициенты для каждого из N приёмных каналов: $W = (w_1, w_2, \ldots, w_N)$. Далее диаграммо-образующая схема (ДОС) формирует выходной сигнал Y системы, в котором составляющая помехи минимальна: $Y = \sum_{i=1}^{N} X_i w_i$.

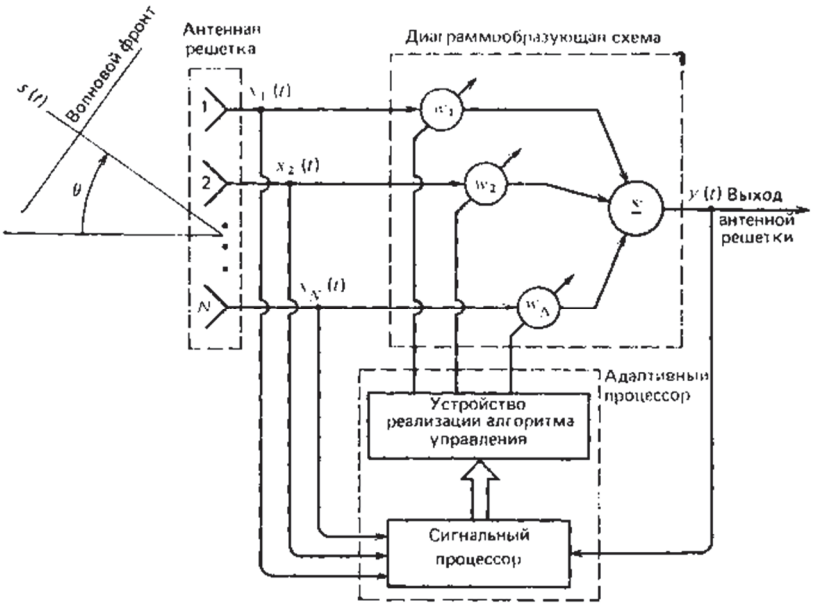

Рис. 1. Структурная схема ААР

Адаптивный процессор определяет основные характеристики всей системы адаптации и осуществляет многоканальную обработку сигналов.

Традиционный алгоритм адаптации

Сигнал, принимаемый АР поступает на неё в различные моменты времени, которые определяются направлением прихода сигнала и расположением элементов АР. Входной *узкополосный полезный сигнал* S_0 и сигнал суммы помех J_Σ в дальней зоне линейной эквидистантной ААР определяются как векторы комплексных амплитуд на каждом из N каналов [1]:

$$S_{0_T} = E \cdot \left(1, e^{iu_0}, e^{i2u_0}, \ldots, e^{i(N-1)u_0}\right). \quad (1)$$

$$J_{\Sigma_T} = \sum_{k=1}^{L} j_k \left(1, e^{iu_k}, e^{i2u_k}, \ldots, e^{i(N-1)u_k}\right). \quad (2)$$

$$u_k = \frac{2\pi d}{\lambda} \sin\left(\vartheta_k\right). \quad (3)$$

где u_k – набег фазы для k-го сигнала, d – шаг решётки, λ – длина волны, ϑ_k – угол прихода k-го сигнала, L – количество помех, E и J_k – среднеквадратичные напряжения источников сигнала и помех.

В данной работе моделируется оптимальное подавление *помехи в полосе частот*, которая характеризуется центральной частотой f_0 и шириной спектра ΔF. Действие широкополосной помехи, при математическом описании сводится к действию множества эквивалентных пространственно-разнесённых помех на частоте f_0, отстоящих от направления на помеху и друг от друга на угол $2N/\beta$, равном полуширине ДН решётки по нулям [5]. Вектора комплексных амплитуд эквивалентных помех определяются следующим набегом фаз на АР:

$$J_{\pm 2l_T} = \left(1, e^{iu_{\pm 2l}}, e^{i2u_{\pm 2l}}, \ldots, e^{i(N-1)u_{\pm 2l}}\right), \tag{4}$$

$$u_{\pm 2l} = \frac{2\pi d}{\lambda} \sin\left(\vartheta_1 \pm \frac{2l}{N\beta}\right), \tag{5}$$

где ϑ_1 – угол прихода помехи, β – межэлементное расстояние в полуволнах.

Выбор алгоритма адаптации в соответствии с определённым *критерием качества* влияет на структуру построения адаптивного процессора.

Критерий максимума ОСШП обеспечивает быстрое и глубокое подавление помех, его применяют для слабых и кратковременных сигналов. Его функционал качества определяется как:

$$F(W) = \frac{W_T^* A W}{W_T^* M W}, \tag{7}$$

где A – ковариационная матрица полезного сигнала, M – ковариационная матрица помех и шумов.

Максимум функционала (7) достигается при оптимальных ВК, равных:

$$W_{opt} = \mu M_\Sigma^{-1} S_{\vartheta_0}^*, \tag{8}$$

где M_Σ^{-1} – обратная матрица от ковариационной матрицы помех, $S_{\vartheta_0}^*$ – полезный сигнал, приходящий с нулевого направления (единичный вектор), μ – константа, пропорциональная уровню ДН в направлении сигнала.

Элементы ковариационной матрицы определяют взаимное влияние огибающих принятых сигналов на различных элементах ААР. Примем, что собственные шумы одинаковы во всех каналах и не коррелированы между собой, а амплитуды приходящих на ААР сигналов, помех и собственных шумов одинаковы. При этом, в процессе составления *обучающей выборки* для нейронной сети амплитуды помех выбирались различными.

В качестве основных *характеристик эффективности* алгоритмов адаптации для установившегося режима возможна оценка значений глубины подавления помех, ослабления приёма полезного сигнала и ОСШП на выходе ААР. В данной работе далее сравниваются усреднённые значения данных характеристик по углам прихода помехи от –90 до +90 градусов и по значениям относительной полосы частот от 0 до 10 %.

Нейросетевой алгоритм

Одним из перспективных направлений развития адаптивных антенн является использование НС в качестве адаптивного процессора [6–8].

В данной работе проводилось численное моделирование *многослойной НС прямого распространения* (feedforward) для подбора ВК ААР при максимизации ОСШП на выходе антенны. Использовалось обучение с учителем с помощью *метода обратного распространения ошибки* (backpropagation). Моделирование проводилось в среде Matlab с использованием пакета расширения Neural Network Toolbox.

Для обучения НС, на её вход подавались амплитуды и фазы вектора суммарного входного сигнала X_k, приходящего на ААР. В качестве обучающей выборки на выходе сети использовать амплитуды и фазы вектора ВК адаптивной антенны W_k для различных углов прихода узкополосных и широкополосных помех.

Пакетный способ обучения был выбран для нахождения ВК сети, наиболее точно сходящихся к оптимальным [9].

Обучающие выборки формировались для углов прихода помех от –90 до +90 градусов с шагом 0.25 градуса. Разность фаз помех и полезного сигнала полагалась равной нулю, значения напряжения источника помех для векторов обучающей выборки принимали различные значения. Обучающие массивы были составлены для узкополосных помех в количестве от 1 до 9, и широкополосных помех с относительной шириной полосы, равной 10 %. Все входные данные подвергались нормировке до области значений сигмоидальной функции, их среднее значение по всему обучающему множеству было близко нулю.

Отличие *тестовой выборки* от обучающей обеспечивалось другим количеством помех, их значениями ширины полосы и иными амплитудами помех.

При численном моделировании НС производится оптимизация их объёма. Необходимо учитывать, что *увеличение количества нейронов* в скрытых слоях НС увеличивает количество вычислительных операций и время, затрачиваемое на них [7]. Кроме того, увеличение сети повышает точность

её работы, но может привести к явлению перетренировки сети – ситуации, когда НС хорошо аппроксимирует функцию только на обучающей выборке, и плохо обобщает результаты при работе с незнакомой выборкой.

Далее проводится численное моделирование ААР на традиционном и нейросетевом управлении.

Численное моделирование

В табл. 1 приведены сравнения средних характеристик адаптации *для НС с 2 скрытыми слоями* различного объёма. Для обучающей выборки использовался традиционный амплитудно-фазовый алгоритм, обучение производилось 130 эпох при малом объёме обучающей выборки 1448 векторов. Среднее время обучения каждой конфигурации НС составляло 4 минуты для четырёхядерного процессора Intel Core i5 8-го поколения 1,8 ГГц.

Таблица 1

Сравнение средних характеристик адаптации для архитектуры НС с 2 скрытыми слоями при различном количестве нейронов в них

Количество нейронов	Глубина подавления, дБ	Ослабление сигнала, дБ	ОСШП на выходе, ед.	Количество весов НС
30	–12,85	–0,90	9,36	2100
28	–11,49	–0,90	9,33	1904
26	–14,12	–0,91	9,37	1716
24	–14,16	–0,94	9,37	1536
22	–13,06	–0,90	9,37	1364
20	–11,21	–0,95	9,30	1200
18	–12,03	–0,92	9,31	1044
16	–11,02	–0,90	9,36	896
14	–11,56	–0,90	9,36	758
12	–9,41	–0,92	9,33	624
10	–8,44	–0,89	9,33	500

Из приведённой таблицы видно, что наиболее оптимальные характеристики адаптации с помощью НС из 2 скрытых слоёв достигаются при использовании 22–26 нейронов в скрытых слоях. При этом имеется возможность сократить объём сети до 14–16 нейронов на слой с приемлемым уровнем ОСШП на выходе ААР, что особенно актуально при ограниченных вычислительных ресурсах.

Также было проведено сравнение средних характеристик адаптации *для НС с 1 скрытым слоем*, но при тех же исходных данных, средняя глубина

подавления помех, усреднённая в диапазоне от 26 до 54 нейронов на скрытый слой (от 1040 до 2160 весов НС) оказалась равной –10,09 дБ против –12,70 дБ, усреднённой от 18 до 30 нейронов на скрытый слой для НС с 2 слоями (от 1044 до 2100). Видно, что НС с 2 скрытыми слоями обеспечивает более эффективное решение задач адаптации, по этой причине НС с 1 скрытым слоем далее не рассматривается.

Для *более подробной оценки качества* подавления помех в ААР на нейросетевом управлении были выбраны следующие конфигурации НС с 2 скрытыми слоями: по 24 нейрона и по 14 нейронов на скрытый слой.

Обучение выбранных НС осуществлялось на *обучающей выборке увеличенного объёма* 14480 векторов, в которую были добавлены дополнительные ситуации сигнально-помеховых обстановок не использованных ранее амплитуд помех, их относительных полос и общего числа помех.

Таблица 2

Сравнение средних характеристик адаптации для архитектуры НС с 24 нейронами в слоях при различном количестве эпох обучения

Количество эпох	Глубина подав, дБ	Ослабление сигнала, дБ	ОСШП на выходе, ед.	Время обучения, мин
100	–17,24	–0,89	9,40	45,0
150	–19,19	–0,90	9,42	67,5
200	–18,67	–0,90	9,41	90,0
250	–19,16	–0,94	9,41	112,5
300	–18,06	–0,90	9,41	135,0

Таблица 3

Сравнение средних характеристик адаптации для архитектуры НС с 14 нейронами в слоях при различном количестве эпох обучения

Количество эпох	Глубина подав, дБ	Ослабление сигнала, дБ	ОСШП на выходе, ед.	Время обучения, мин
100	–13,99	–0,89	9,39	10,3
150	–14,86	–0,89	9,40	15,5
200	–14,27	–0,90	9,40	20,6
250	–15,62	–0,90	9,40	25,8
300	–14,15	–0,88	9,39	30,3

В табл. 2 и 3 приведены сравнения усреднённых характеристик адаптации для НС при различном количестве эпох обучения. За оптимальное количество эпох были приняты: 150 для НС с 24 нейронами и 250 для НС с

14 нейронами на слой. Для сравнения, традиционный алгоритм адаптации обеспечивает среднее подавление помех –18,35 дБ, среднее ослабление сигнала –0,91 дБ и среднее ОСШП 9,41 единицу.

На рис. 2 показаны графики средних характеристик глубины подавления помех и ослабления полезного сигнала в зависимости от ширины полосы помех для традиционного и двух нейросетевых алгоритмов. Из полученных результатов видно, что алгоритмы на НС обеспечивают решение задач адаптации на высоком уровне.

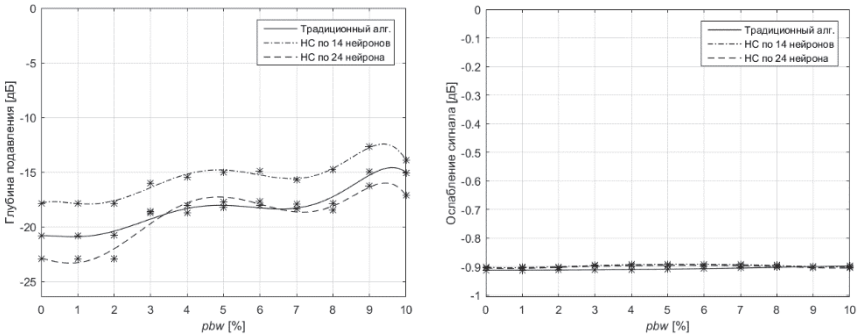

а *б*

Рис. 2. Зависимости характеристик адаптации от ширины полосы помех для традиционного и нейросетевых алгоритмов адаптации:
а – глубина подавления помех, *б* – ослабление полезного сигнала

Выводы

В результате численного моделирования ААР можно прийти к следующим выводам:

1. Для примера ААР из 10 элементов оптимальные характеристики адаптации (средняя глубина подавления –19,2 дБ, среднее ослабление сигнала –0,9 дБ при 1536 настраиваемых весах НС) достигаются при использовании НС прямого распространения с двумя скрытыми слоями, содержащими по 24 нейрона. ААР на нейросетевом амплитудно-фазовом управлении обеспечивает среднее подавление помех в полосе частот до 10 %, сравнимое со значением –18,6 дБ для традиционного алгоритма адаптации методом прямого обращения матрицы по критерию максимума ОСШП. Использование НС не увеличивает значение среднего ослабления полезного сигнала, для обоих алгоритмов оно составляет –0,9 дБ.

2. Для примера ААР из 10 элементов существует возможность сокращения объёма НС до 14 нейронов на скрытый слой, что обеспечивает значительное сокращение вычислительных затрат при обучении и работе НС (средняя глубина подавления –15,6 дБ, среднее ослабление сигнала –0,9 дБ при 758 настраиваемых весах НС).

Проведённое численное моделирование показывает целесообразность применения НС для задач адаптации. Они обеспечивают более высокую степень универсальности применения алгоритма для различных сценариев сигнально-помеховой обстановки (робастность). При этом необходимо учитывать, что при значительно большем количестве элементов ААР актуально применение алгоритмов частичной адаптации.

Список литературы

1. Пистолькорс А.А., Литвинов О.С. Введение в теорию адаптивных антенн. М.: Наука, 1991. 200 с.

2. Монзиго Р.А., Миллер Т.У. Адаптивные антенные решётки: введение в теорию: пер. с англ. под ред. В.А. Лексаченко. М.: Радио и связь, 1986. 448 с.

3. Van Trees H.L. Optimum Array Processing. Part IV of Detection, Estimation and Modulation Theory. - New York: Wiley-Interscience, 2002. P. 1–41, 428–916.

4. Григорьев В.А., Щесняк С.С., Гулюшин В.Л., Распаев Ю.А., Лагутенко О.И., Щесняк А.С. Адаптивные антенные решётки: учебное пособие в 2-х ч. Ч. 1. СПб: Университет ИТМО, 2016. 179 с.

5. Литвинов О.С. О подавлении помехового сигнала в полосе частот адаптивной антенной решёткой // Радиотехника и электроника. 1982. Т. 27. Вып. 11. С. 2264–2267.

6. Литвинов О.С., Муродьянц Д.В. Исследование спектральных характеристик подавления помех в адаптивных антенных решётках на нейросетевом управлении. В кн.: Нейроинформатика-2018, тез. докл. XX междунар. науч.-техн. конф., Москва, 2018. С. 136–143.

7. Rawat A., Yadav R.N., Shrivastava S.C. Neural network applications in smart antenna arrays: A review // International Journal of Electronics and Communications. 2012. Vol. 66. №11. P. 903–912.

8. Fadlallah N., Rammal M., Vaudon P. A phased arrays beams synthesis using neural network model // WSEAS Transactions on Communications. 2005. Vol. 4 № 3. P. 135–139.

9. Хайкин С. Нейронные сети: полный курс: 2-е изд., испр.: пер. с англ. под ред. Н.Н. Куссуль. М.: Вильямс, 2006. 1104 с.

10. Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика. М.: Мир, 1992. С. 41–54.

А.В. АГЕЕВ[1], **В.С. СМОЛИН**[2], **С.М. СОКОЛОВ**[2]
[1]Московский государственный технический университет им. Н.Э. Баумана
[2] Федеральный исследовательский центр «Институт прикладной математики им. М.В. Келдыша» Российской академии наук, Москва
alekseu147147@yandex.ru, smolin@keldysh.ru, sokolsm@list.ru

О ЗАДАЧЕ ФОРМИРОВАНИЯ СИСТЕМЫ УПРАВЛЕНИЯ НА ОСНОВЕ НЕЙРОННОЙ СЕТИ

Рассматриваются преимущества, которые может принести использование нейросетей в автоматических системах управления динамическими объектами. Предлагается методика иерархического построения адаптивных законов управления, и приводятся результаты её применения на простом мехатронном устройстве – сферическом приводе прямого управления (СППУ), управляющим структурированным подсветом в системе технического зрения (СТЗ).

Ключевые слова: *нейронная сеть, автоматическое управление, нейросетевое управление, алгоритм управления, нейросетевая аппроксимация.*

1. Введение

Современные теории автоматического управления позволяют формировать системы управления для широкого класса задач, что успешно применяется на практике. В системах, где величина задержки мала по сравнению с временами переходных процессов в управляемой системе, а нелинейности либо несущественны, либо поддаются аналитическому описанию, теория автоматического управления позволяет решить задачу формирования оптимальной системы управления. Предполагается, что использование нейросетевых подходов позволит уменьшить влияние задержек и нелинейностей на эффективность построения законов управления.

Основным свойством нейросетей является их способность к обучению аппроксимации функций на основе примеров, без знания физической природы преобразования. Именно это свойство даёт надежду на эффективное применение нейросетей в сложных системах, нелинейными свойствами которых нельзя пренебречь. Вместо расчёта оптимального закона управления на основе знаний свойств управляемой системы, нейросетевой подход поз-

воляет на основе практического выявления реальных характеристик адаптивно сформировать оптимальный в заданном смысле закон управления с учётом нелинейных свойств системы.

В более широкой постановке задача управления не сводится только к достижению целевых значений параметров, но и к формированию этих целевых значений. При решении данной задачи после определения типов и параметров наблюдаемых объектов необходимо продолжить обработку данных и определить цели для узкой задачи управления. Сейчас постановка целей относится к компетенции человека. Но данная задача также может быть решена с использованием нейросетевого подхода в AI.

2. Задача нейросетевого управления

Применение нейронных сетей для построения системы управления позволяет построить аппроксимацию закона управления путем обучения сети на основе экспериментально выявляемых соответствий изменений состояний объекта в результате применения различных управляющих воздействий.

Для аппроксимации свойств динамики систем обычно применятся рекуррентные нейронные сети [1], которые обучаются на временных рядах параметров состояний системы. В последнее время широко используется сети ResNet [2], снижающие проблему затухающих и взрывающихся градиентов. Так же именно для решения задачи аппроксимации динамики процесса разработаны такая модель нейронной сети как OdeNet [3].

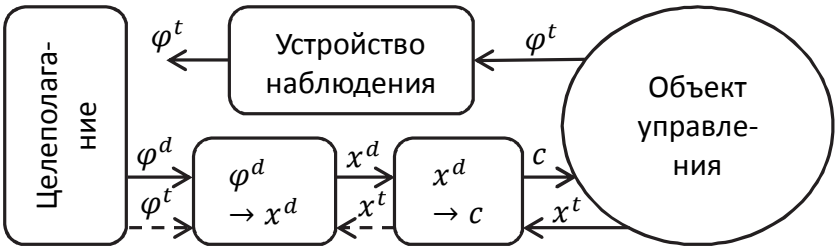

Рис. 1. Простейшая структура системы управления: x^t – вектор параметров с датчиков, φ^t – с устройства наблюдения; φ^d, x^d – целевые значения; c – управляющее воздействие. Параметры x^t и φ^t подаются на блок $\varphi^d \rightarrow x^d$ только при обучении системы. Все переменные – векторные

После обучения нейронная сеть (в схеме решения задачи управления) получает на вход текущее x^t и целевое x^d состояния объекта управления, а на выходе выдает управляющее воздействие с, для перевода объект управления в ожидаемое состояние. Обычно параметры φ^t, в которых задаётся цель и используемые в контуре управляющего воздействия x^t могут не совпадать по своей природе. Это приводит к необходимости преобразования наблюдаемых параметров объекта φ^t в параметры внутреннего контура управления x^t. Преобразования $\varphi^d \to x^d$ и $x^d \to c$ аппроксимируются нейросетью. Простейшая схема решения задачи управления показана на рис. 1.

Задача аппроксимации преобразований $\varphi^d \to x^d$ и $x^d \to c$ схожа с задачей аппроксимации эволюции динамических систем, рассматриваемой в [1, 2, 3]. Но имеет свои особенности, заключающиеся в том, что преобразования $\varphi^d \to x^d$ и $x^d \to c$ формируются опытным путём, на основе обучения, но и измеряемые при обучении параметры x^t и φ^t содержат не только ошибку, но и задержку при их получении. Задержка получения φ^t заметно больше задержки в контуре x^t, особенно в случае, реализации наблюдения внешними устройствами, а контура управления x^t – непосредственно на объекте управления.

3. Предлагаемый путь решения задачи нейросетевого управления

Основная ожидаемая польза от нейросетей в задачах управления состоит в возможности использования большого числа настраиваемых параметров, которые позволяют описать сложные законы управления. Классическими средствами теории автоматического регулирования тоже можно формировать сколь угодно сложные законы управления, но их разработка требует длительных и дорогостоящих исследований. Нейросети обучаются сложным законам управления в автоматическом режиме, без участия высококлассных специалистов. За счёт обучения можно также частично компенсировать разброс параметров и некоторые недостатки управляемой системы, на конкретном образце устройства адаптивный закон управления будет учитывать его конструктивные особенности.

Важной проблемой для всех систем управления является величина задержки τ в контуре управления. Уменьшение, а лучше сведение к нулю τ позволяет улучшить качество управления. Последние десятилетия уменьшение τ было принято достигать за счёт повышения тактовой частоты цифровых устройств, формирующих законы управления.

Высокая скорость передачи цифровых сигналов позволяет снизить значение τ практически до нуля по сравнению характеристическими временами переходных процессов механических устройств. Если закон управления относительно простой и/или управляемое устройство планируется к крупному тиражированию, то экономически оправдана разработка специализированных преобразователей, задержка прохождения сигнала через которые также незначительна. Иначе рациональнее использование универсальных цифровых устройств – контроллеров и компьютеров.

Цифровая обработка сигналов, при всех её успехах, проигрывает аналоговой обработке в задачах управления по временам задержки τ в контуре обратной связи. Одной из основных причин этого являются сложившиеся стандарты пакетной передачи данных между цифровыми устройствами. Обеспечивая высокую скорость и надёжность потоковой передачи данных, пакетные стандарты заметно увеличивают время ответа на пакет по сравнению с аналоговой реакцией. Это связано с необходимостью дождаться получения пакета целиком, обработать содержащиеся в нём данные и сформировать обратный пакет и только затем заняться его отсылкой, которая тоже займёт некоторое время. Высокие тактовые частоты как передачи, так и обработки информации в современных цифровых устройствах позволяют эффективно использовать цифровые средства в системах управления, но чем быстрее реагирует объект управления, тем больше сложностей вызывает разработка цифрового управления.

Адаптивное формирование нейросетевых законов управления позволяет в некоторой степени компенсировать задержку τ в контуре цифрового управления. Большое количество настраиваемых параметров позволяет нейросети после обучения формировать аппроксимацию прогноза, какие управляющие воздействия будут оптимальными для тех состояний устройства, в которые оно перейдёт по истечению времени τ.

Но, естественно, точность прогноза падает с увеличением времени τ. Уменьшать τ возможно не только техническими средствами, но и разбиением процесса управления на несколько уровней: сложные законы управления состоят из простых действий, для реализации которых нужны относительно простые законы управления.

Сложный закон управления, естественно, реализуется по времени дольше, чем любое из составляющих его действий (в цифровой системе управления все действия – дискретные). Это позволяет не только реже ставить цели для более сложных законов, но и следить за процессом их достижения, используя более медленные каналы связи: на рис. 2 показана общая структура управления мехатронной системой: контроллер осуществляет

аналоговое управление объектом с, а компьютер задаёт цели управления с использованием обмена пакетами данных.

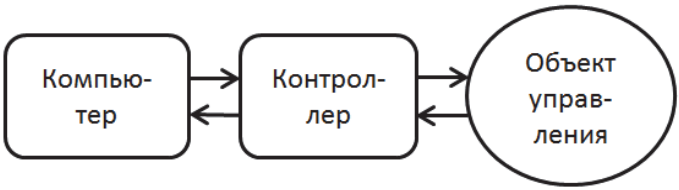

Рис. 2. Структура управления мехатронной системой

Рост числа уровней увеличивает суммарную задержку в общей цепи управления объектом, но позволяет найти компромисс между малым значением τ и возможностью реализации сложных законов на универсальных цифровых устройствах. Для исследования простейших принципов построения нейросетевого управления достаточно двух уровней.

4. Простое устройство для моделирования – СППУ

В качестве объекта управления для проведения исследования используется сферический привод прямого управления (СППУ) [4], являющийся частью системы технического зрения (СТЗ) со структурированным подсветом. СППУ состоит из следующих частей (рис. 3).

1. Вращающаяся система – карданов подвес, в котором закреплен лазерный целеуказатель и постоянный магнит.
2. Система парных соосных соленоидов расположенных вокруг вращающейся системы, подвешенной на кардановом подвесе.

Непосредственное управление СППУ осуществляет микроконтроллер Atmega128 с четырьмя датчиками Холла. Они используется для быстрого получения информации о состоянии вращающейся системы, двумерного вектора $x^t(x_1^t; x_2^t)$, а микроконтроллер выполняет управление напряжением на катушках с помощью ШИМ. Целевые значения $x^t(x_1^t; x_2^t)$ поступают от компьютера, к которому подключается микроконтроллер.

В СТЗ входит также видеокамера. Цель СППУ – подсветка области, которую наблюдает видеокамера для исследования пространства, окружающего мобильного робота (рис. 4). Камера выполняет ввод зрительных данных из поля зрения с подсветкой. Полученные изображения обрабатываются в режимах обучения и определения расстояния до цели.

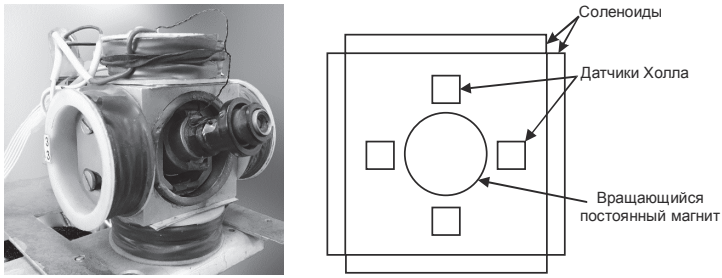

а *б*

Рис. 3. Общий вид СППУ (*а*) и его схема, вид спереди (*б*)

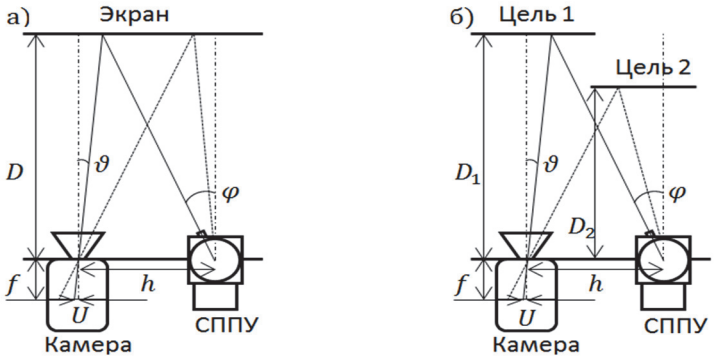

Рис. 4. Схема применения СТЗ с целью определения расстояния до цели: а) обучение соответствию φ показаниям датчика Холла – φ для обучения вычисляется по h, U, f и D: б) определение D_i по h, U, f и φ от датчиков Холла. φ – угол поворота СППУ; h – расстояние между камерой и СППУ; f – фокусное расстояние; U – значение отклонения пятна на изображении от его центра. D – расстояние до целевого объекта

Для подсветки области интереса микроконтроллер поворачивает целеуказатель путем регулирования скважности ШИМ. Микроконтроллер, получая задание в виде целевых углов поворота $(\varphi_1^c; \varphi_2^c)$ и текущего состояние $(\varphi_1^t; \varphi_2^t)$ вращающейся системы, должен выработать управляющее воздействие. Поскольку система изменяет свое состояние с большой скоростью (достигающей 9 радиан в секунду), то необходимо быстрая корректировка и контроль состояния объекта управления. Для этого используются

показания датчиков Холла, они напрямую подключены к контроллеру, и показания возможно снимать с частотой до 10 кГц. Скорость обмена с управляющим устройством значительно меньше. Датчики Холла срабатывают быстрее, но из-за особенностей конструкции, показания датчиков зашумлены. Датчики Холла близко расположены к краям катушек, и их показания зависят от тока в катушках. Отображения $\varphi^d \to x^d$, $x^d \to c$ должны учитывать ток в катушках, влияние их магнитного поля.

Во время выполнения подсветки области, возможны два режима управления: а) позиционного управление, установка заданных углов отклонения и их удержание; б) траекторное управление описывание заданных траекторий, например, окружностей или прямых.

В системе управления СППУ выделяется иерархия: 1) управляющее устройство, которое выдает задания для СППУ и выполняет управление роботом; 2) микроконтроллер СППУ, выполняющий управление движением лазерного целеуказателя.

Производительность микроконтроллера накладывает ограничения на объем нейронной сети, которая не должна забирать все вычислительные ресурсы на себя. В процессе функционирования СППУ выполняет следующие задачи:

1. Обмен пакетами с управляющим устройством, находящийся выше по уровне иерархии;

2. Сбор данных с датчиков Холла и вычисление приблизительного состояния вращающейся системы $\left(x_1^t;\ x_2^t\right)$, которые входят в отправляемые пакеты.

5. Локализация и декомпозиция в задаче нейросетевой аппроксимации

Аппроксимация законов управления СППУ с использованием стандартных архитектур нейросетей была исследована в предыдущей работе авторов [5]. Одной из основных проблем, препятствующей широкому использованию нейросетей в задачах управления является высокий уровень относительной ошибки аппроксимации, который может достигать не только единиц, но и десятков процентов. При решении качественных задач распознавания такие относительные ошибки аппроксимации несущественны, но в задачах управления не позволяют осуществить точное позиционирование. Как было продемонстрировано в [5], при использовании стандартных архитектур нейросетей увеличение числа слоёв и количества элементов в слое позволяют снизить уровень ошибки, но при этом значение ошибки

стремится не к нулю, а к некоторому минимуму, определяемому особенностями задачи. Данное наблюдение подтверждается авторами [2], которые в личных контактах отметили, что хотя теоретические результаты показывают возможность стремления ошибки к нулю по мере роста числа параметров сети, но на практике, при использовании метода обратного распространения ошибки (BPE) этого не происходит.

В [6] развивалась идея, что причина этого явления состоит в том, что использование BPE для обучения параметров нейросети непосредственно направлено на воспроизведение соответствий между примерами входных и выходных сигналов, которые подаются при обучении. Всевозможные методы регуляризации позволяют улучшить результаты обучения по методу BPE для целей формирования аппроксимации преобразования на основе примеров для произвольного входного сигнала. Но всё равно, даже с использованием регуляризации, ошибка аппроксимации остаётся параметром, который не входит явно в число оптимизируемых.

Теоретическую основу для аппроксимации непрерывных функций дискретными отсчётами даёт теорема отсчётов [7] (теорема Котельникова, в англоязычной литературе – теорема Найквиста-Шеннона). Она устанавливает, что расстояние между дискретными отсчётами в пространстве входного сигнала должно уменьшаться с ростом максимальных значений пространственных частот, на которые может быть разложена аппроксимируемая функция. И задаёт коэффициент пропорциональности.

На практике в различных участках пространства состояний входного сигнала наличие высокочастотных компонент в выходной функции может быть различным. В процессе обучения участки с высокочастотными компонентами выявляются по большему числу ошибок аппроксимации, которые им соответствуют. В [6] описан метод конкурентного обучения, основанный на адаптации входных связей, при котором участки с высокочастотными компонентами становятся областями притяжения для локализации нелинейностей нейронов скрытых слоёв:

$$\Delta\theta_i = \alpha\Delta y(x - \theta_i), \qquad (1)$$

где Δy – ошибка аппроксимации в точке x, θ_i – вектор входных связей, а α – малый параметр. Результат обучения по закону (1) приводит к равномерному распределению ошибки аппроксимации по элементам скрытых слоев, и величина этой ошибки равномерно стремится к нулю.

Линейность суммирования вклада элементов скрытых слоёв в формируемое преобразование приводит к тому, что осуществляемое нейросетью приближение является аппроксимацией первого порядка. Кусочно-линейный характер аппроксимации проявляется при использовании элементов ReLU. Другие типы нелинейности элементов скрытого слоя не исправляют

ситуацию, поскольку настройка соответствия нелинейных свойств элементов скрытых слоёв и кривизны аппроксимируемой функции при обучении по методу ВРЕ не производится. В этом случае ReLU, не имеющие регулируемой кривизны нелинейности, показывает даже более высокую эффективность при аппроксимации преобразований.

В [6] вместо ReLU была использована нелинейность типа SoftPlus:

$$\mathrm{SoftPlus}(a) = \frac{1}{\propto}\ln(e^{\propto a} + 1), \qquad (2)$$

где a – линейная активность элемента, а $\propto$ – параметр, связанный со значением кривизны нелинейного преобразования $\mathrm{SoftPlus}(a)$.

Совместная настройка локализации и кривизны нелинейности элементов скрытого слоя позволила в [6] значительно (более, чем в 30 раз) повысить точность аппроксимации функции по отношению к применению метода ВРЕ при одинаковом числе элементов внутреннего слоя.

Более важное значение имеет возможность декомпозиции высокоразмерной задачи управления на несколько низкоразмерных. В СППУ такая возможность присутствует, что использовалось уже в предыдущей работе авторов [5]. Необходимо отметить, что снижение размерности задачи аппроксимации, в том числе нейросетевой, всегда ведёт к снижению уровня ошибок, осуществление декомпозиции высокоразмерных задач является важнейшим компонентом обеспечения успешности решения задачи.

6. Результаты

Замена рассмотренных в [5] моделей нейросетей с несколькими скрытыми полносвязанными слоями, обучаемыми по методу ВРЕ на нейросети с конкурентной активностью и совместной настройкой локализации и кривизны нелинейности элементов скрытого слоя [6] позволила повысить точность позиционирования целеуказателя СППУ в 7–8 раз при снижении среднего времени позиционирования на 30 %. Дополнительным результатом стало уменьшение времени обучения суммарной нейросети в 3–5 раз.

В развитие результатов [6] был разработан формальный подход к многомерному вычислению конкурентной активности элементов нейросети на основе их линейного входного возбуждения. На основе квадрата евклидова расстояния ρ_i^2 между входным возбуждением $\vec{X}$ и вектором входных весов связей $\vec{M}_i$ i-го элемента конкурентного слоя

$$\rho_i^2 = D_i^2 = (\vec{X} - \vec{M}_i)^2 = \vec{X}^2 - 2\vec{M}_i\vec{X} + \vec{M}_i^{\,2} \qquad (3)$$

рассчитывается линейная входная активность элементов

$$\tilde{A}_i = \vec{X}^2 - \rho_i^2 = 2\vec{M}_i\vec{X} - \vec{M}_i^{\,2}. \qquad (4)$$

Легко видеть, что при любом $\vec{X}$ линейная входная активность элементов будет максимальна у i-го элемента конкурентного слоя, у которого ρ_i^2 минимально. Выходная же конкурентная активность

$$A_i = \begin{cases} \tilde{A}_i - \theta, & \tilde{A}_i - \theta \geq 0; \\ 0, & \tilde{A}_i - \theta < 0, \end{cases} \quad (5)$$

$A_i = \tilde{A}_i - \theta$, где θ выбирается одинаковым для всех элементов конкурентного слоя таким образом, чтобы

$$\sum_{i-1}^{n} A_i / g_i = 1, \quad (6)$$

где g_i – максимальные значения A_i при всех значениях $\vec{X}$, которые выявляются статистическими методами. Поскольку в (6) все значения $A_i \geq 0$, то равенство в (6) может быть выполнено при единственном значении n, которое и определяет размерность пространства многомерной аппроксимации.

Понимание простой структуры задачи управления СППУ позволило разбить задачу аппроксимации на несколько взаимодействующих нейросетевых аппроксиматоров с максимальной размерностью 2. В перспективе представляется возможным организовать адаптивное формирование структуры низкоразмерных взаимодействующих аппроксиматоров на основе нейросетей с конкурентной активностью.

7. Выводы

Проведённые работы по исследованию способов повышения эффективности применения нейросетевого управления для простого мехатронного устройства – СППУ – показали плодотворность выбранных подходов. Дальнейшие работы будут направлены на развитие теории низоразмерных аппроксимаций и расширение применения полученных результатов на более сложные системы.

Список литературы

1. Trischler A., D'Eleuterio G. Synthesis of recurrent neural networks for dynamical system simulation // arXiv.org. 2015. https://arxiv.org/abs/1512.05702v2

2. Чащин А.В., Бочев М.А., Оселедец И.В., Овчинников Г.В. Предсказание эволюции динамических систем остаточными нейронными сетями // Препринты ИПМ им. М.В. Келдыша. 2019. № 131. 26 с. http://library.keldysh.ru/preprint.asp?id=2019-131

3. Daulbaev T., Katrutsa A., Markeeva L., Gusak J., Cichocki A., Oseledets I. Interpolated adjoint method for neural odes // arXiv.org. 2020. https://arxiv.org/abs/2003.05271

4. Соколов С.М., Трифонов О.В., Ярошевский В.С. Система управления сферическим приводом прямого управления с датчиками Холла в контуре обратной связи // Препринты ИПМ им. М.В. Келдыша. 2008. № 94. 20 с.

5. Агеев А.В., Смолин В.С., Соколов С.М. Исследование применимости нейронной сети для управления сферическим приводом // XXI международной научно-техническая конференция «Нейроинформатика-2019»: Сборник научных трудов. В 2-х ч. Ч. 2. Долгопрудный: МФТИ, 2019. С. 100–108.

6. Краснов М.М., Смолин В.С. Локальная кривизна и точность нейросетевой аппроксимации // XXI международной научно-техническая конференция «Нейроинформатика-2019»: Сборник научных трудов. В 2-х ч. Ч. 2. Долгопрудный: МФТИ, 2019. С. 175–185.

7. Котельников В.А. О пропускной способности эфира и проволоки в электросвязи – Всесоюзный энергетический комитет // Материалы к I Всесоюзному съезду по вопросам технической реконструкции дела связи и развития слаботочной промышленности, 1933. Репринт статьи в журнале УФН, 176:7 (2006), 762–770.

О.С. ЛИТВИНОВ[1], Д.В. МУРОДЬЯНЦ[2], Я.М. КАРАНДАШЕВ[2]

[1]Московский государственный технический университет им. Н.Э. Баумана

[2]Научно-исследовательский институт системных исследований РАН

oleglitv@mtu-net.ru, dmitriy1994.94@mail.ru, karandashev@niisi.ras.ru

ИССЛЕДОВАНИЕ ХАРАКТЕРИСТИК ПОДАВЛЕНИЯ ШУМОВ В АДАПТИВНЫХ АНТЕННЫХ РЕШЕТКАХ ПРИ НЕЙРОСЕТЕВОМ УПРАВЛЕНИИ ФАЗОВРАЩАТЕЛЯМИ В РАЗЛИЧНЫХ РЕЖИМАХ ИХ ФУНКЦИОНИРОВАНИЯ

В данной работе проводился анализ характеристики сигнал/шум на выходе адаптивной антенной решетки при различных режимах управления – традиционном, фазовом, дискретном фазовом и со связью амплитуды и фазы при дискретной фазе. Для последних трех была использована специально обученная для каждого режима нейронная сеть. Было показано, что использование трех последних режимов управления показывает результаты, которые близки к результатам общего традиционного амплитудно-фазового управления.

Ключевые слова: *адаптивные антенные решетки, нейронные сети, фильтрация сигналов.*

Введение

За последние 10-15 лет появилась и получила широкое распространение новая отрасль антенной техники – адаптивные антенные решетки. Основная задача проектирования ААР заключается в создании блока управления весовыми коэффициентами, участвующих в формировании конечного сигнала с минимальной помеховой составляющей. При наложении ограничений на изменение амплитуды ВК для уменьшения потерь мощности полезного сигнала задача выбора оптимальных ВК не имеет аналитического решения. В связи с чем решено использовать нейронную сеть в качестве блока управления ААР. Получена зависимость отношения сигнал/ шум на выходе адаптивной антенной решетки при трех различных режимах управления:

1) непрерывном фазовом, при котором непрерывно изменяется фаза весовых коэффициентов при постоянной единичной амплитуде;

2) дискретном фазовом, когда количество углов, на которые могут быть повернуты фазовращатели, ограничено;

3) режимом со связью амплитуды и фазы при дискретной фазе, когда амплитуда выбиралась исходя из основного выражения для весовых коэффициентов в традиционном амплитудно-фазовом управлении

Данная работа является развитием исследований [1, 3, 4].

Адаптивные антенные решетки

Адаптивная антенная решетка (ААР) – тип антенны, в которой обеспечивается оптимальное значение ее параметров в условиях априорной неопределенности воздействующих помех (внешних и внутренних) [2].

Основная схема ААР представлена на рис. 1.

Основная задача проектирования ААР состоит в создании блока обработки сигналов, который по заданному входному сигналу выдавал значения ВК, максимизирующих функционал отношения мощности сигнала к шуму:

$$F(W) = \frac{(\boldsymbol{W^T})^* \boldsymbol{AW}}{(\boldsymbol{W^T})^* \boldsymbol{MW}}, \quad (1)$$

где корреляционная матрица полезного сигнала $\boldsymbol{A} = \boldsymbol{S}^* \cdot \boldsymbol{S^T}$, корреляционная матрица приходящих помех $\boldsymbol{M} = \boldsymbol{J}^* \cdot \boldsymbol{J^T} + n_0^2 \boldsymbol{I_n}$, $\boldsymbol{S}$ – фазар полезного сигнала, $\boldsymbol{J}$ – фазар помехи, $\boldsymbol{I_n}$ – единичная матрица собственных шумов, n_0^2 – средняя мощность собственного шума каналов, * – комплексное сопряжение [2].

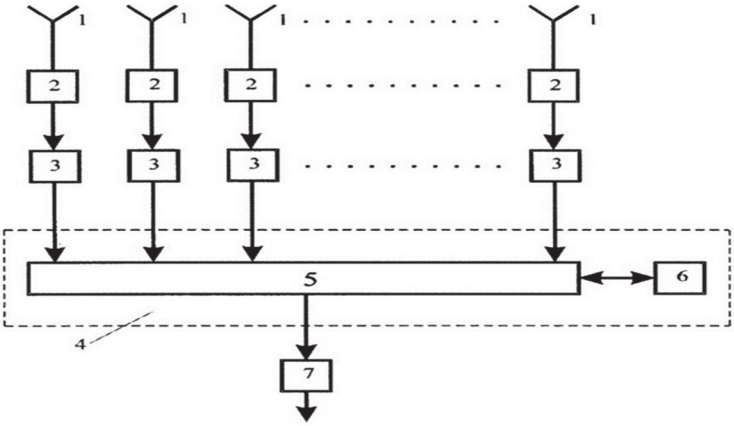

Рис. 1. Схема адаптивной антенной решетки

В работе [2] показано, что максимум функционала (1) достигается на ВК, равных

$$\boldsymbol{W_{opt}} = \mu \boldsymbol{M^{-1}} \boldsymbol{S^*}, \quad (2)$$

где μ – нормировочная константа, выбираемая например из условия фиксации первого ВК $w_1 = const$.

В данной работе рассматривается дополнительный критерий сохранения мощности полезного сигнала на выходе, для чего накладываются ограничения на изменения амплитуды ВК: $|w_i| = \text{const}$, и рассматриваются три режима управления (в сравнении с традиционным)

Данная задача не имеет аналитического решения, и более того она неоднозначна. Поэтому было решено использовать в качестве блока обработки сигналов нейронную сеть (многослойный перцептрон), которая обладает свойствами анализировать и обобщать многомерные массивы информации, и вырабатывать нужный отклик на входные воздействия.

Постановка задачи

В данной работе проводилось обучение нейронной сети для подбора весовых коэффициентов (ВК) адаптивной антенной решетки (ААР) для максимизации отношения сигнал/шум (С/Ш) на выходе в зависимости от входного сигнала, поступающего на ААР. Моделирование проводилось в среде Python.

Число весовых коэффициентов (ВК) ААР полагалось равным 5. Полезный сигнал приходил по нормали к ААР. Разность фаз помехи и полезного сигнала полагалась равной нулю, отношение мощности полезного сигнала к мощности помехи на входе полагалось равным 20 дБ.

Входной сигнал представляет собой узкополосный сигнал, характеризующийся вектором комплексных амплитуд $\boldsymbol{X} = (x_1, x_2, \dots, x_N)$, каждая составляющая которого равна комплексной амплитуде на входе приемного элемента ААР. Входной сигнал состоит из полезного сигнала, характеризующимся вектором комплексных амплитуд $\boldsymbol{S_0}$ и сигнала помехи $\boldsymbol{J}$:

$\boldsymbol{S_0} = E\{1, e^{iu_0}, \dots, e^{i(N-1)u_0}\}$,
$\boldsymbol{J} = \sum_{k=1}^{N} \boldsymbol{j_k}$,
$\boldsymbol{j_k} = J_k\{1, e^{iu_k}, \dots, e^{i(N-1)u_k}\}$,

где $u_k = \frac{2\pi}{\lambda} dsin\vartheta_k$, d – шаг решетки, λ – длина падающей волны, ϑ_k – угол прихода k-го сигнала, E – комплексная амплитуда полезного сигнала, J_k – комплексная амплитуда помехи.

$$\boldsymbol{X} = \boldsymbol{S_0} + \boldsymbol{J},$$

где $\boldsymbol{X}$ – суммарный сигнал на вход ААР.

Теперь для обучения нейронной сети необходимо создать обучающую выборку для каждого из трех режимов управления:

1) Непрерывное фазовое управление

Вход обучающей выборки представляет собой совокупность монохроматических помех, приходящих под углами $\alpha = \frac{\pi}{20} n$, где $n = 1 \dots 9$. Далее необходимо методом градиентного спуска определить углы φ_k, максимизирующие функционал сигнал/шум (1).

2) Дискретное фазовое управление

Вход обучающей выборки представляет собой совокупность монохроматических помех, приходящих под углами $\alpha = \frac{\pi}{20} n$, где $n = 1 \dots 9$. Далее необходимо методом перебора определить углы $\varphi_k = 0, \frac{\pi}{2}, \pi, \frac{3\pi}{2}$ максимизирующие функционал сигнал/шум (1).

3) Режим со связью амплитуды и фазы при дискретной фазы

Вход обучающей выборки представляет собой совокупность монохроматических помех, приходящих под углами $\alpha = \frac{\pi}{20} n$, где $n = 1 \dots 9$. Фаза выбирается как при режиме 2), а амплитуда ВК выбирается согласно формуле (2).

По полученным выборкам $\boldsymbol{X_k}$ и $\boldsymbol{W_k}$ строилось обучение нейронной сети (НС) методом обратного распространения ошибки [3], где

$$\boldsymbol{W_k} = \{\varphi_{1k}, \dots, \varphi_{Nk}\}.$$

Дальше проводился анализ успешности работы нейронной сети в качестве блока управления ААР при изменении числа помех. В обучающей выборке помеха представляла собой монохроматическую волну определенной длины волны, а в модельной задаче подавления шумов ААР на нейросетевом фазовом управлении помеха представляла собой сумму двух и трех монохроматических помех под углами $\frac{\pi}{2}$ между соседними помехами.

Также для сравнения с результатами работы ААР на нейросетевом фазовом управлении была создана ААР на общем амплитудно-фазовом управлении, где выбор весовых коэффициентов определялся в соответствие с формулой (2).

Результаты

Рассмотрена зависимость отношения мощности сигнала к шуму от угла прихода монохроматической помехи или кластера помех для нейросетевой ААР на непрерывном фазовом, дискретном фазовом, дискретном фазовом со связью с амплитудой и традиционном амплитудно-фазовом управлении.

Из рис. 2 видно, что отношение сигнал/шум на выходе ААР резко убывает при стремлении угла прихода помехи к углу нормали или к скользящему углу, что в первом случае объясняется совпадением полезного сигнала и помехи, а во втором случае трудностью обработки сигнала, обладающего высокой пространственной частотой. На всех трех графиках можно видеть, что наилучшие результаты по максимизации сигнал/шум наблюдаются у общего традиционного амплитудно-фазового управления, далее идет непрерывное фазовое, потом дискретное фазовое со связью с амплитудой, а наихудшие результаты демонстрируются у дискретного фазового. На графиках есть некоторые особенности, а именно: на рис. 3 и 4 дискретное фазовое управление со связью с амплитудой имеет провал на углах между 0,45 и 0,58 радиан, и резко уходит вниз при приближении к конечному углу, показывая, что наше предположение, что добавление к дискретному фазовому управлению связи с амплитудой из общего управления не всегда может приводить к улучшению результатов.

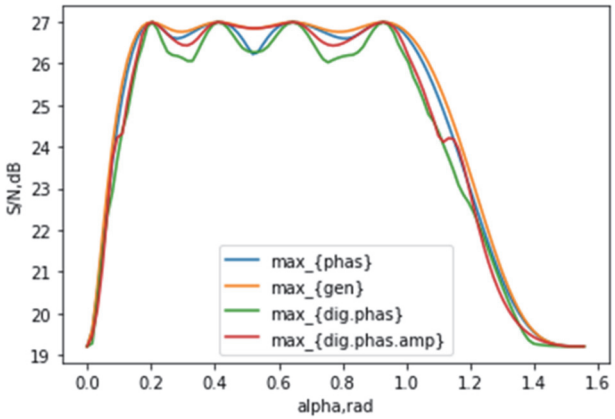

Рис. 2. Зависимость отношения мощности сигнала к шуму на выходе нейросетевой ААР фазового (max_{$phas$}), общего амплитудно-фазового (max_{gen}), дискретного фазового (max_{dig.phas}) и дискретного фазового со связью с амплитудой (max_{dig.phas.amp}) управления от угла прихода монохроматической помехи

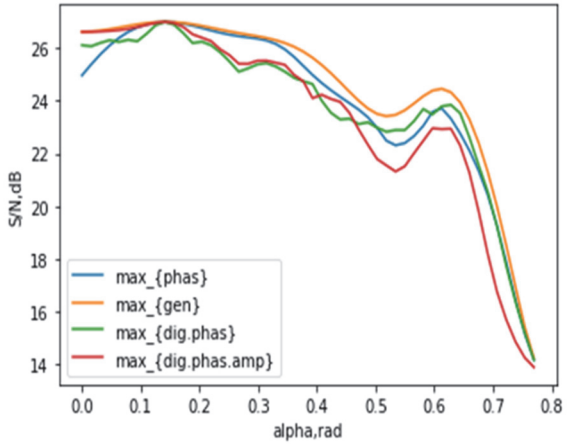

Рис. 3. Зависимость отношения мощности сигнала к шуму на выходе нейросетевой ААР фазового (max_{$phas$}), общего амплитудно-фазового (max_{gen}), дискретного фазового (max_{dig.phas}) и дискретного фазового со связью с амплитудой (max_{dig.phas.amp}) управления от угла прихода кластера из двух помех

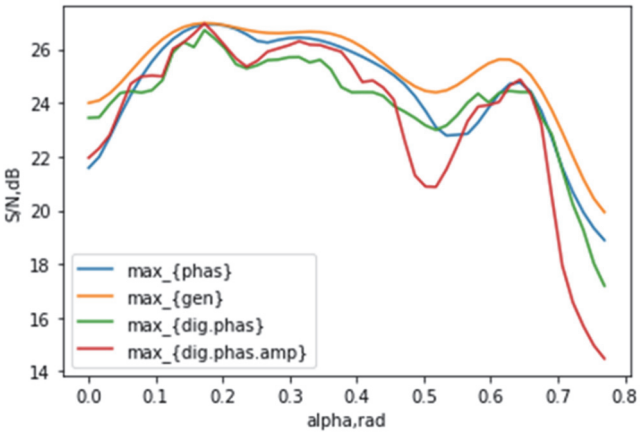

Рис. 4. Зависимость отношения мощности сигнала к шуму на выходе нейросетевой ААР фазового (max_{$phas$}), общего амплитудно-фазового (max_{gen}), дискретного фазового (max_{dig.phas}) и дискретного фазового со связью с амплитудой (max_{dig.phas.amp}) управления от угла прихода кластера из трех помех

На рис. 2 можно отметить небольшую особенность, где дискретное фазовое управление со связью с амплитудой на диапазоне углов от 0.48 до 0.61 радиан почти полностью совпадает с общим амплитудно-фазовым управлением, и соответственно показывая с ним наилучшие результаты, чем другие два типа управления.

Выводы

Из полученных графиков можно сделать вывод, что нейронная сеть успешно справляется с подавлением нескольких помех, обучившись при этом на одной помехе. Также можно отметить, все три типа управления нейросетевой ААР показывают результаты подавления шумов, близкие к традиционной ААР общего управления, и могут быть выбраны из соображений простоты технической реализации (как в случае фазового управления). Типы управления можно расположить в порядке убывания успешности максимизации сигнал/шум на выходе следующим образом: общее амплитудно-фазовое управление, непрерывное фазовое управление, дискретное фазовое управление со связью с амплитудой, дискретное фазовое управление. Дискретное фазовое управление со связью с амплитудой на не-

которых участках показывает аномальное плохое поведение (а на некоторых, как отмечено выше, почти совпадает с общим амплитудно-фазовым), что может объясняться определенным модулем самой амплитуды, полученной из формулы общего управления при оптимизируемой дискретной фазе, что требует дополнительного исследования (необходимо подобрать оптимальный коэффициент, на который будут умножаться амплитуды, что повлияет на отношение сигнал/шум при оптимизации дискретной фазы).

Список литературы

1. Литвинов О.С., Муродьянц Д.В. Подавление шумовых помех в адаптивных антенных решетках на основе нейросетевых алгоритмов // Антенны. 2018. № 2. С. 40–44.

2. Пистолькорс А.А., Литвинов О.С. Введение в теорию адаптивных антенн. М.: Наука, 1991.

3. Литвинов О.С., Муродьянц Д.В., Борута В.С., Винтайкин Б.Е. Особенности алгоритмизации нейросетевого управления в адаптивных антенных решетках // Антенны. 2019. № 7. С. 53–58.

4. Литвинов О.С., Муродьянц Д.В., Борута В.С., Винтайкин Б.Е. Сравнение эффективности подавления помех в адаптивных антенных решетках на нейросетевом управлении, сб. науч.-техн. конф. Антенны и распространение радиоволн, 2019. С.67–69.

5. Хайкин С. Нейронные сети: Полный курс: 2-е изд. М.: Вильямс, 2008. 1103 с.

6. Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика. М.: Мир, 1992. 240 с.

7. Zhonghui Zhao, Huiling Zhao, Minghuan Zheng, and Junjie Tang Real-Time Phase-Only Nulling Based on Deep Neural Network With Robustness, IEEE Access, 24 Sep. 2019. Vol. 7. P. 1–8.

8. Bilel Hamdi, Selma Limam, and Taoufik Aguili Uniform and Concentric Circular Antenna Arrays Synthesis for Smart Antenna Systems Using Artificial Neural Network Algorithm, Progress In Electromagnetics Research B, Vol. 67, 91–105, 2016.

9. Houhong Xiang, Baixiao Chen, Minglei Yang, Cunxu Li. Altitude measurement based on characteristics reversal by deep neural network for VHF radar, IET Radar, Sonar & Navigation, 2018. P. 98–103.

А.С. ТАРАСОВ, М.Б. НИКИФОРОВ, В.Ю. ТАРАСОВА
Рязанский государственный радиотехнический университет им. В.Ф. Уткина
vb2005@yandex.ru

ПРИМЕНЕНИЕ ВОЗМОЖНОСТЕЙ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ СОПРОВОЖДЕНИЯ ПОДВИЖНЫХ ОБЪЕКТОВ

В данной статье рассматриваются нейросетевые подходы, которые могут найти применение в задачах сопровождения подвижных объектов на видео. Были предложены сегментационные, нейро-корреляционные алгоритмы, а также классический корреляционный алгоритм с постоянным дообучением эталонного изображения

Ключевые слова: *сопровождение объектов, свёрточные нейронные сети, системы реального времени.*

Введение

Поиск и сопровождение подвижных объектов являются одними из ключевых задач области технического зрения. Они находят своё применение в различных системах обеспечения безопасности, видеонаблюдения, навигации. Эта проблема рассматривалась в работах [1–7], но она не полностью решена в настоящее время. При обнаружении объекта поиска возникают трудности из-за проективных и аффинных преобразований [8], обструкции объекта, шума датчика видеоизображения. Для практических применений алгоритм поиска объекта должен обрабатывать видеоизображение со скоростью данных от датчика.

В данной работе рассматривается применимость нейросетевых подходов для решения задачи сопровождения объектов. Таким образом, система уже обладает достаточными априорными сведениями об объекте на момент начала её сопровождения.

Существующие подходы

Самыми известными, базовыми подходами к сопровождению объектов являются корреляционный поиск и вычисление оптического потока.

Корреляционный поиск представляет собой обнаружение некоторого прямоугольного шаблона (фрагмента с областью цели) на текущем кадре. Наиболее точный результат даёт только полный перебор всех расположений с областью цели. В каждой из этих точек вычисляется так называемая

корреляционная функция, которая представляет собой численную меру близости фрагмента с целью с предыдущего кадра и выбранного фрагмента с текущего.

Наиболее часто применяются такие корреляционные функции как:

$$F(p_x, p_y) = \sum_{x=0}^{n} \sum_{y=0}^{m} |i_{src}(x + p_x, y + p_y) - i_{area}(x, y)|, \quad (1)$$

$$F(p_x, p_y) = \sum_{x=0}^{n} \sum_{y=0}^{m} (i_{src}(x + p_x, y + p_y) - i_{area}(x, y))^2. \quad (2)$$

Здесь, i_{src} и i_{area} – изображения текущего кадра и фрагмента с объектом, m и n – высота и ширина кадра, p – координаты с предполагаемым расположением цели.

Данный метод достаточно хорошо работает в том случае, если цель занимает не менее 50 % площади прямоугольника, не увеличивается/уменьшается в кадре, не меняет яркость и не перекрывается резко другими объектами. Кроме того, на полный перебор всех возможных расположений требуются большие временные затраты.

Поэтому предлагаются различные модификации данного метода: поиск в окрестностях предыдущего расположения, метод Мультистарт, градиентные спуски и др. [9].

Другим подходом является использование оптического потока Лукаса-Канаде для выявления направления перемещения пикселей во времени. Анализируя значения векторов смещения цвета в этой области, делается прогноз о направлении движения объекта [10].

Предполагается, что группа соседних пикселей смещается в течение кадра на небольшое расстояние без изменения цвета. Тогда это предположение можно записать следующим образом:

$$\begin{pmatrix} I_x(x_1, y_1) & I_y(x_1, y_1) \\ \vdots & \vdots \\ I_x(x_n, y_n) & I_y(x_n, y_n) \end{pmatrix} \begin{pmatrix} u \\ v \end{pmatrix} = \begin{pmatrix} -I_t(x_1, y_1) \\ \vdots \\ -I_t(x_n, y_n) \end{pmatrix}. \quad (3)$$

Здесь I_t (x_1, y_1) – интенсивность цвета в соответствующей точке, u и v – искомый вектор смещения [10].

Однако следует учитывать, что расстояние между соседними пикселями изменяется. Это приводит к тому, что их цвет меняется в окрестности этой точки. В результате система принятия решений не может иметь единого решения. Используется только некоторое приближение.

Этот метод очень эффективен для изображений с низким уровнем шума, однако, когда появляются дополнительные объекты с повышенным уровнем шума, этот метод становится не очень эффективным.

Для улучшения работы этого метода в работе используется технология вариационного оптического потока [11, 12]. Кроме того, вместо плотного оптического потока чаще всего используется разреженные карты, в которых оптический поток вычисляется только в «удобных» для этого точках.

Рис. 1. Оптический поток для кадра

Корреляционный алгоритм с постоянным дообучением

Первым предлагаемым подходом является модификация корреляционного алгоритма. Вместо фрагмента с объектом с предыдущего кадра, предлагается использовать некоторый паттерн и маску, которые формируются в процессе работы автомата сопровождения объекта и адаптируются под текущую ситуацию. Паттерн – это прямоугольник, содержащий обновляемую информацию о цели. С каждым новым кадром паттерн обучается при помощи нейронной сети Кохонена. Области на паттерне, которые наиболее часто подвергаются изменениям, помечаются как нестабильные и не участвуют в корреляционном сопоставлении.

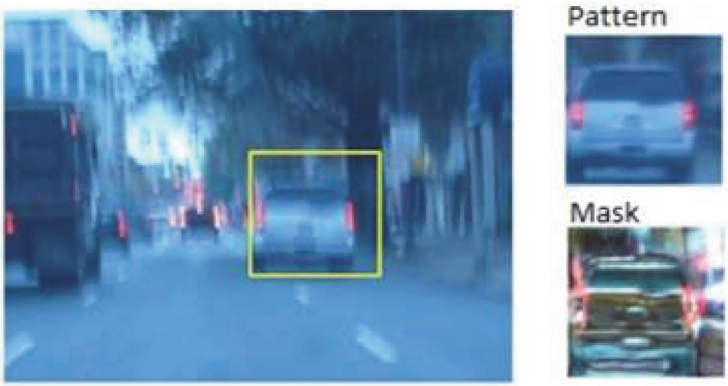

Рис. 2. Паттерн и маска для кадра слева

Данный подход позволяет разрешить часть проблем, которые возникают при применении классических корреляционных методов: На основе анализа маски осуществляется увеличение/уменьшение области сопровождения объекта. Наличие маски позволяет сохранять границы расположения объекта даже в том случае, если объект занимает менее 30 % площади.

Применение сегментационных нейронных сетей

Для корректного сопровождения объекта в условиях низкой контрастности или недостаточной освещённости предлагается метод, основанный на сегментации пары изображений.

В ходе работы было установлено, что обладая сведениями о попиксельной разнице между двумя кадрами (рис. 3, *в*) и маской объекта (рис. 3, *б*) удаётся получить отчётливое расположение объекта в новом кадре.

В ходе работы была разработана собственная архитектура. В её основе лежат принципы сегментационных сетей U-Net [13] и SegNet [14], однако, вместо одного входного изображения подаётся сразу два: разница и маска (рис. 4, *а*). В результате формируется некоторый результат, содержащий информацию о местах на изображениях, в которых цель переместилась (подсвечиваются области, из которых цель ушла, и в которых цель появилась).

Позже, на основе этой информации и расположении цели в предыдущем кадре определяется новое расположение цели.

а *б* *в*

Рис. 3. Примеры входных данных из датасета VOT 2016.
Исходное изображение (слева), маска объекта (центр),
разница между исходным кадром и следующим (справа)

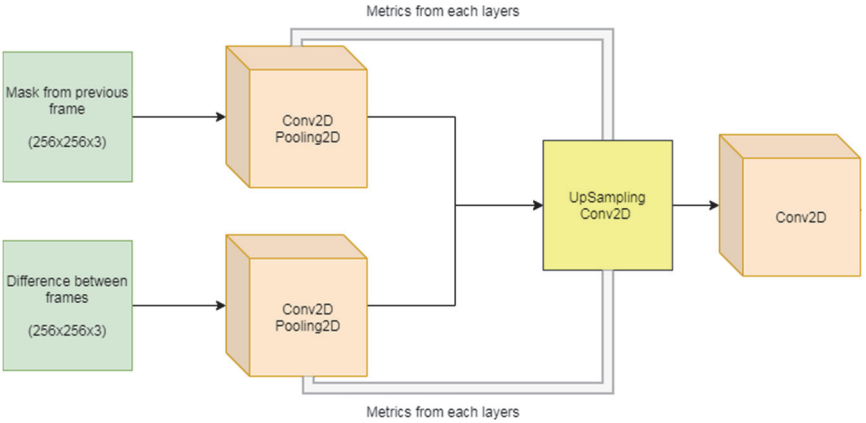

Рис. 4. Архитектура первой части представленного метода

Полученное после блока свёрток изображение (блок Conv2D), именуемое в дальнейшем *Out* преобразуется в результирующую маску при помощи специального преобразования:

Изображение (*Out*) умножается на исходную маску (*Mask*). Результатом такого умножения будет область, в которой цель была на предыдущем кадре, но на текущем отсутствует (*Mul*).

Затем, определяется область, на которой объект отсутствовал на предыдущем кадре и появится только в текущем (Next). Для этого из полученного изображения вычитается маска.

Маской для нового расположения цели (Result) будет старая маска, из которой убран результат умножения (Mul) и прибавлены новые области

$$Mul = Mask * Out; \quad (4.1)$$
$$Next = Out - Mask; \quad (4.2)$$
$$Result = Mask - Mul + Next. \quad (4.3)$$

а *б* *в*

Рис. 5. Слева на право: выход с нейросети (Out), результат произведения (Mul), результат вычитания (Next)

После того, как результат был получен, из него удаляются лишние шумы и помехи при помощи U-Net.

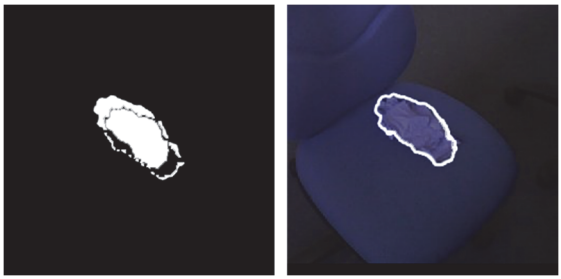

a *b*

Рис. 6. Полученный результат после выделения маски и после постобработки результата нейросетью U-NET

Оценка скорости работы

Важным фактором при оценке качества работы автомата сопровождения объектов является скорость. Если исходить из того, что большинство видеосистем работают с частотой дискретизации 24 кадра в секунду (41 ms per frame), то и автомат сопровождения также должен укладываться в эти рамки.

Таблица 1

Корреляционный алгоритм с постоянным дообучением

Условия испытания	Дообучение	Поиск	Итого
CPU only (Intel 6600)	12 ms	9 ms	21 ms
CPU only AMD Phenom X2	31 ms	29 ms	50 ms

Таблица 2

Сегментационные нейросети

Условия испытания	Поиск цели	Пост обработка	Итого
CPU+GPU (Tesla K80)	1 ms	0.5 ms	1.5 ms
CPU+GPU (NVidia 1060ti)	2 ms	1 ms	3 ms
CPU only (Intel 6600)	154 ms	63 ms	217 ms
CPU only (AMD Phenom X2)	913 ms	129 ms	1 042 ms

Таким образом, представленные алгоритмы способны работать в условиях реального времени при наличии графического ускорителя и современного CPU.

Результаты

Результатом проделанной работы стал программный стенд, который позволяет анализировать точность работы различных алгоритмов и подходов к сопровождению объектов. Собираемая информация о точности работы различных алгоритмов предназначается для дальнейшей разработки экспертной системы, которая бы на основании априорных сведений предлагала бы наиболее подходящий метод для сопровождения объектов.

Для оценки качества работы представленного метода была подготовлена выборка фрагментов из набора данных VOT-2014.

Для оценки качества работы представленного метода применяется метрика BBOX_DIFF, представляющая собой разницу между предсказанным расположением объектом и эталонным.

$$BBOX_{DIFF} = \sqrt{\left(\frac{(P_{x1} - E_{x1})}{E_{x2} - E_{x1}}\right)^2 + \left(\frac{(P_{y1} - E_{y1})}{E_{y2} - E_{y1}}\right)^2} + \sqrt{\left(\frac{(P_{x2} - E_{x2})}{E_{x2} - E_{x1}}\right)^2 + \left(\frac{(P_{y2} - E_{y2})}{E_{y2} - E_{y1}}\right)^2}.$$

Здесь $P(x_1, y_1, x_2, y_2)$ – координаты предсказанного прямоугольника с расположением объекта, $E(x_1, y_1, x_2, y_2)$ – координаты эталонного (размеченного) прямоугольника с расположением объекта.

Сбоем будем назвать ситуацию, при которой значение указанной величины превысит 0,4 (отклонение от эталонного расположения более, чем на 40 %). В этом случае, с большой долей уверенности можно говорить, что автомат сопровождения потерял цель. Для выбранного набора видеофрагментов оценивается величина COUNT (суммарное число кадров с корректным сопровождением до первого сбоя, больше – лучше) и ACCURACITY (средняя точность работы до первого сбоя, меньше – лучше).

В рамках эксперимента, предлагаемый метод был сопоставлен с методами из VOT-2014 Challenge, находящимися в открытом доступе. Результаты сравнения представлены в таблице:

№	Метод	COUNT	ACCURACITY
1	Предлагаемая комбинация методов	710	0,183
2	TLD	713	0,261
3	SiamMask	698	0,142
4	GOTURN	512	0,229

Исходя из представленных результатов, можно утверждать, что предлагаемый метод обладает высокой точностью работы в сравнении с известными алгоритмами, применяемыми для решения подобных задач.

Список литературы

1. Anshtedt T. Videoanalitics: myths and real – Moscow: Sequrity Focus, 2012, 176 p.

2. Guoshen Yu. ASIFT: An Algorithm for Fully Affine Invariant Comparison, Image Processing On Line. 2011. Vol. 1.

3. Viola P. Rapid Object Detection using a Boosted Cascade of Simple Features. Accepted Conference on Computer Vision and Pattern Recognition (CVPR 2001). 2001. P. 511–518.

4. Sokolov S.M. Vision system for information support of automatic landing and movement along the runway of aircraft. 2015. Vol 1(162). P. 96–109.

5. Philatov V.I. The system of teaching visual concepts based on the correlation of lexemes and key points. 2016. Vol. 16–4. P. 689–696.

6. Roth D. The SNoW Learning Architecture. Technical Report UIUCDCS–R–99–2102, UIUC Computer Science Department. 1999. P. 8–10.

7. Suvorov D.A. TLD: algorithm of tracking, 2012.

8. Diyazitdinov R.R. Application of the Kalman filter to assess the illumination Promising information technologies in scientific research, design and training (PIT 2012), Samara: Publishing House of the Samara Scientific Center of the Russian Academy of Sciences. 2012. P. 21–25.

9. Elesina S.I., Nikiforov M.B., Loginov A.A., Kostyashkin L.N. Combining images in the correlation-extreme navigation system, Moscow: Tehnika, 2015. 208 p.

10. Agafonov V.Ju. Application of optical flow methods for image alignment estimation, Education and science in Russia and abroad. 2017. Vol. 6.

11. Bratulin A.T., Belyakov P.V., Kholopov E.Yu., Ustyukov D.I. Highspeed method for calculating dense optical flux on FPGA.

12. Belyakov P.V., Nikiforov M.B. An FPGA-optimized architecture of variational optical flow. Conference: 2018 IEEE East-West Design & Test Symposium (EWDTS). 2018. P. 129–136.

13. Ronneberger Olaf, Fischer Philipp, Brox Thomas. U-Net: Convolutional Networks for Biomedical Image Segmentation // CoRR. 2015. Vol. abs/1505.04597. – 1505.04597.

14. Jiawei Zuo, Guangluan Xu, Kun Fu, Xian Sun, Hao Sun, «Aircraft Type Recognition Based on Segmentation With Deep Convolutional Neural Networks», Geoscience and Remote Sensing Letters IEEE. 2018. Vol. 15. No. 2. P. 282–286.

А.С. ТАРАСОВ, В.Ю. ТАРАСОВА
Рязанский государственный радиотехнический университет им. В.Ф. Уткина
vb2005@yandex.ru, Valentina2008.91@mail.ru

РАЗРАБОТКА СИСТЕМЫ ПОИСКА ПОХОЖИХ ИЗОБРАЖЕНИЙ В ЛОКАЛЬНЫХ ХРАНИЛИЩАХ

В статье рассматривается разработка системы поиска похожих изображений. Для анализа изображений предложена совместная работа методов выделения информационной и цветовой составляющих, на основании которых каждое изображение приобретает числовой хэш. Изображения сравниваются исключительно на основе данных вычисленного хэша. Для сравнения используется полносвязная нейронная сеть.

Ключевые слова: *поиск изображений, свёрточные нейронные сети, хэширование.*

Введение

Поиск похожих изображений является одной из актуальных задач современности. Системы, предназначенные для поиска идентичных изображений, находят своё применение в глобальных поисковых системах (модуль «поиск по картинке» систем Яндекс и Google), в библиотечных системах (поиск книги по обложке), при поиске фото в семейных архивах, а также при поиске изображений в электронных каталогах открытого доступа (краеведческий музей, кадастровые карты).

Главная задача подобных систем – найти по имеющемуся фото такие изображения, которые бы максимально соответствовали ожиданиям пользователя. Метод полного перебора неэффективен для коллекций, содержащих более 500 фотографий, а на персональном компьютере, переносном устройстве, электронном каталоге или в сети Интернет их значительно больше. Алгоритм поиска должен анализировать содержание, например, форму объектов, их текстуру, цвет [1].

Для определения степени соответствия двух изображений используется хэширование. Мера близости показывает степень соответствия одного изображения другим.

Для эффективного поиска по коллекциям большого объема необходимо разработка специальных алгоритмов и программных средств, позволяющих за несколько секунд отвечать на пользовательские запросы [1–3].

Научная новизна работы заключается в применении комбинируемого метода, основанного на операциях свертки и подвыборки, а также цветовой составляющей для поиска похожих изображений по искомому изображению.

Практическая значимость ожидаемых результатов состоит в создании программного обеспечения на основе разработанного алгоритма, позволяющего повысить эффективность поиска похожих изображений.

Применяемые подходы

Если рассматривать изображение как матрицу с размерами *M*x*N*x*C* пикселей (где *M* и *N* – ширина и высота, а *C* – количество цветовых каналов), то с математической точки зрения мерой различия будет среднеквадратическая отклонение между элементами матриц:

$$\mathrm{C}(A,B) = \sum_{x=0}^{N}\sum_{y=0}^{M}\sum_{c=0}^{3}(A_{x,y,c} - B_{x,y,c})^2. \quad (1)$$

По такой методике работает часть программ поиска похожих изображений [4]. Недостатков у такого метода несколько. Во-первых, для каждой новой пары изображений необходимо заново просчитывать данную величину, во-вторых, такой подход может давать ошибочный результат при съёмке различных по смыслу объектов в одинаковых условиях.

Например, на рисунке 1а представлена фотография кота, а на рис. 1, *б* – одуванчики. Несмотря на то, что фото различные, указанный метод сочтёт их похожими.

Рис. 1. Картинки с высокой мерой близости

Иной подход применяется в крупных поисковых системах. Вместо попиксельного сравнения, выполнение которого трудозатратно, осуществляется анализ информационной составляющей изображения. Загруженное изображение анализируется при помощи нейронных сетей, например,

VGG19 и определяется класс-ключевое слово, которое максимально подходит для данной картинки.

В работах [5, 6, 7] рассматриваются подходы, основанные на вейвлет-преобразовании, перцептивных хэш-функциях. Однако, данные подходы уступают в точности сверточным нейронным сетям.

Помимо проблемы многообразия методов поиска похожих изображений, оценки их результативности, трудозатратности и эффективности, исследователи сталкиваются с проблемой идентичности. Возникает вопрос: А какие фотографии следует считать идентичными, а какие – нет? Для того, чтобы приблизиться к решению данной проблемы, был проведен опрос среди 20 человек. Каждому из опрашиваемых предлагались пары фотографий, и требовалось указать, какова мера близости этих изображений. Результатом опроса стал набор из 2000 пар изображений и мера их близости.

Полученные результаты стали основой для выполнения дальнейших исследований.

Было выдвинуто 2 предположения: первое заключалось в том, что идентичные фотографии имеют идентичные характеристики, такие как экспозиция, контрастность, основные цвета, баланс цвета и др. Второе основано на том, что идентичные изображения имеют идентичную информационную нагрузку. Например, можно ли считать идентичными фотографии, на которых расположен один и тот же объект, снятый при абсолютно иных условиях.

Для оценки этих предположений предлагалось использовать полносвязную нейронную сеть оценивающую эффективность того или иного метода на основе полученной выборки.

Оценка информационного содержания

Оценка информационного содержания основывается на подсистеме преобразования изображений в некоторый хэш. Каждая фотография представляется в виде хэша, который должен описывать то, что изображено на фотографии, быть информативным и позволять оперативно сравнивать два изображения. Сравнение осуществлять без использования дополнительной информации (например, дата, название, место съемки), то есть недоступна никакая другая информация кроме пикселей изображений. Необходимо сформировать хэши, для которых близкие по содержанию изображения будут близкими по сформированным хэшам.

Для выполнения операции хэширования предлагается использование сверточной нейронной сети, на вход которой поступает изображение, сжа-

тое до размеров 256x256 точек. Такого размера достаточно для обнаружения и классификации наиболее значимых частей изображения и при этом обработка изображения такого размера не занимает много времени. При вычислении информационной составляющей важно полагаться на наиболее часто встречающиеся элементы на фотографиях пользователей. Было предложено 56 классов и 200 объектов для обнаружения конкретных ситуаций. Классом будем считать глобальные условия съёмки (скан документа, пейзаж, ночная съёмка). Объект – это конкретные элементы на фото (дерево, карандаш, луна). Для обучения такой нейронной сети использовалась база ImageNet [8].

Полученная нейронная сеть с высокой (89 %) точностью позволяет определить классы и объекты, присутствующие на изображении. Однако, для решения задачи хэширования изображений наиболее информативным является предпоследний слой нейросети.

Это связано с тем, что данные в последнем слое стремятся к граничным значениям (либо 0, либо 1). В то время как в предпоследнем слое уже сформированы основные метрики, взвешенное суммирование которых даёт тот или иной класс, при этом сами значения равномерно распределены в пределах диапазона.

Оценка точности работы представленного метода составила 82 %.

Оценка цветовой составляющей

Для повышения точности работы было рассмотрено второе предположение, основанное на анализе цветовых характеристик изображения.

В ходе анализа в получаемых хэш поочерёдно добавлялись такие характеристики как: экспозиция, контрастность, баланс белого, соотношение ярких и тёмных частей, ключевые цвета. Результаты представлены в табл. 1.

Таблица 1

Влияние различных цветовых характеристик на точность работы алгоритма

№	Характеристики	Точность
	Без цветовых характеристик	82,56 %
1	Экспозиция	89,61 %
2	Контрастность	83,15 %
3	Баланс белого	83,71 %
4	Гистограмма	86,81 %
5	Средний цвет	88,59 %
6	3 ключевых цвета	92,82 %
7	3 ключевых цвета и экспозиция	93,87 %
7	3 ключевых цвета и гистограмма	93,98 %

Таким образом, наибольшую точность работы демонстрирует анализ информационной в комбинации со сведениями о ключевых цветах и гистограмме.

Для повышения скорости работы блок хэширования изображений и блок сравнения изображений были объединены в единую нейронную сеть.

Выделение информационных характеристик изображения осуществляется при помощи свёрточной нейронной сети. Входное изображение сжимается до 256x256 пикселей, после чего отправляется на вход. После прохождения 7 свёрточных блоков (свёртка, подвыборка, активация) формируется результирующий вектор из 256 значений, к которому дополнительно добавляются данные о цветовой составляющей. В случае сравнения изображений используется правая часть нейросети. Два вектора объединяются в один и подаются на полносвязную сеть. После трёх слоёв формируется результирующее значение, определяющее меру близости двух изображений.

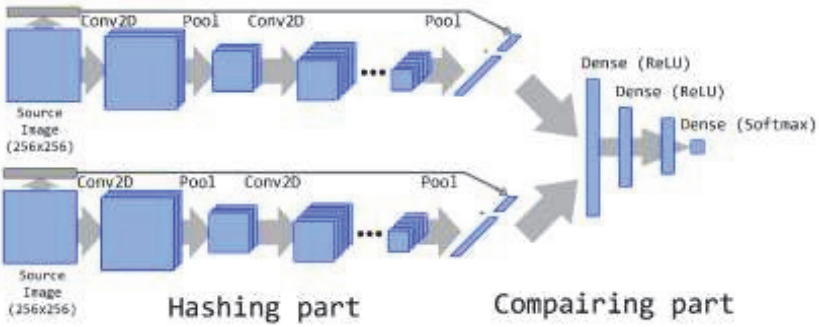

Рис. 2. Общая структура нейронной сети

Результаты

Результатом проделанной работы стала программа, позволяющая выполнять поиск похожих изображений на локальных хранилищах (изображениях, расположенных непосредственно на самом ПК или съёмных носителях, таких как жесткие диски, оптические накопители, карты памяти и др.). Работа разработанного программного комплекса состоит из двух этапов: первичное сканирование всех изображений на компьютере и съёмных носителях и поиск похожих изображений на основе картинки-запроса. Пер-

вичное сканирование необходимо для присвоения хэшей всем изображениям на появления диске. В дальнейшем, данная процедура необходима только по мере на диске новых фото.

Рис. 3. Поиск похожих изображений. Запрос: роза

Рис. 4. Поиск похожих изображений. Запрос: карта

Результаты работы программы представлены на рис. 3–5. Исходное изображение-запрос расположено в левом верхнем углу.

Рис. 5. Поиск похожих изображений. Запрос: кот

Оценка скорости работы методов

Таблица 2

Оценка скорости работы представленного алгоритма

Платформа	Время хэширования 30000 фото (HDD)	**Время поиска картинки в базе**		
		Из 1000 фото	Из 10000 фото	Из 100000 фото
Intel core i5 (7th gen)	10 min	45 ms	196 ms	418 ms
Intel Pentium (2nd gen)	15 min	67 ms	378 ms	981 ms

Исходя из данных в табл. 2 можно сделать вывод, что представленный алгоритм позволяет с высокой скоростью обнаруживать фотографии в пользовательских архивах. Долгое время хэширования изображений объясняется тем, что современные жесткие диски имеют низкую пропускную способность. При выполнении хэширования на SSD скорость повышается в 2–3 раза.

Заключение

В ходе проделанной работы было проведено исследование по определению мер близости изображений. Были выделены основные цветовые и информационные компоненты изображений, влияющие на данную меру. Была разработана структура хранения данных в виде хэшей с целью повышения скорости обработки результатов.

Список литературы

1. Бабенко А.В. Эффективные алгоритмы поиска по большим коллекциям изображений. Диссертация на соискание учёной степени кандидата физико-математических наук Москва 2017 [Электронный ресурс] http://www.keldysh.ru/council/1/2017-babenko/avtoref... (дата обращения 01.05.20).

2. Eric J. Stollnitz, Tony D. DeRose, David H. Salesin Wavelets for Computer Graphics Theory and Applications / Пер. с англ. Л.А. Кунгуровой, под ред. Е.В. Мищенко. М., Ижевск, 2002.

3. Гринченко Н.Н., Потапова В.Ю. Алгоритм поиска изображений в базе данных. В сб.: Проблемы передачи и обработки информации в сетях и системах телекоммуникаций. Материалы 18-й Международной научно-технической конференции. 2015. С. 161–164.

4. Рогов А.А., Рогова К.А., Спиридонов К.Н., Быстров М.Ю. Система поиска в электронной коллекции изображений петроглифов Карелии [Электронный ресурс] http://rcdl.ru/doc/2008/246_251_paper29.pdf (дата обращения 23.03.2020).

5. Рудаков И.В., Васютович И.М. Исследование перцептивных хэшфункций изображения // В сб.: Наука и образование МГТУ им. Н.Э. Баумана. С. 269–280.

6. Tzu-Heng Henry Lee. Wavelet Analysis for Image Processing. http://disp.ee.ntu.edu.tw/henry/wavelet_analysis.pdf

О.Ю. МАРЬЯСИН, А.И. ЛУКАШОВ
Ярославский государственный технический университет
maryasin2003@list.ru

ПРОГНОЗИРОВАНИЕ СВОБОДНЫХ ЦЕН НА ЭЛЕКТРОЭНЕРГИЮ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

Рассмотрена задача прогнозирования почасовых свободных цен на электроэнергию с использованием аппарата искусственных нейронных сетей. Для выполнения функций анализа и прогнозирования цен на электроэнергию разработано приложение на языке Python с использованием библиотек NeuroLab и Keras. Приведены результаты численных экспериментов по прогнозированию цен на электроэнергию, полученные с использованием разработанного приложения.

Ключевые слова: *цена на электроэнергию, прогнозирование, искусственная нейронная сеть, Python, NeuroLab, Keras.*

Введение

Одним из способов повышения конкурентоспособности экономики является развитие систем и методов прогнозирования рыночной конъюнктуры, в том числе на рынках продуктов инфраструктурных отраслей, к которым относится электроэнергетика. В Российской Федерации, после отмены государственного регулирования цен на электрическую энергию и мощность, цена на электроэнергию для потребителей складывается из нерегулируемой составляющей оптового рынка электроэнергии (мощности) и регулируемых тарифов на услуги по передаче электрической энергии, сбытовых надбавок гарантирующих поставщиков и платы за иные услуги, оказание которых является неотъемлемой частью процесса поставки электрической энергии потребителям. Для прогнозирования представляет интерес нерегулируемая часть цены, состоящая в общем случае из оптовой цены на электроэнергию и средневзвешенной цены на мощность на оптовом рынке.

Актуальность темы прогнозирования цен на электроэнергию обусловлена необходимостью наличия у хозяйствующих субъектов обоснованных знаний о перспективных уровнях цен в существующих условиях неопределенности и волатильности цен в целях снижения возможных рисков и по-

вышения качества планирования своей работы [1]. Например, зная почасовые значения цен на электроэнергию в будущем месяце, предприятие могло бы так перераспределить свои потребности, чтобы избежать излишних затрат в период высоких цен и в результате добиться экономии средств на энергоресурсы.

В данной работе основное внимание уделено задаче прогнозирования почасовых цен на электроэнергию на месяц вперед. Это связано с особенностями российского розничного рынка электроэнергии, на котором информация о фактически сложившихся ценах на электроэнергию становится доступной только через несколько дней после окончания расчетного периода, то есть месяца, в котором происходило потребление энергии. Это отличает представленную работу от многих других работ, посвященных данной теме, где рассматриваются задачи краткосрочного прогнозирования на сутки вперед, на несколько дней или недель вперед.

На сегодняшний день на российском рынке нет готовых, ориентированных на пользователя, компьютерных программ для прогнозирования цен на электроэнергию. Работы в данном направлении ведут ряд компаний, как непосредственно участники оптового рынка, так и организации, предоставляющие услуги по прогнозированию цен на электроэнергию. Однако данные компании не готовы делиться собственными методиками и наработками, которые приносят им прибыль в условиях рыночной конкуренции. Поэтому одной из задач, решаемой в данной работе была разработка компьютерной программы для анализа и прогнозирования свободных цен на электроэнергию, которой могли бы пользоваться не только научные работники и специалисты по методам прогнозирования, но и конечные пользователи.

Современное состояние вопроса

В мировой научной литературе тема прогнозирования рыночных цен на электроэнергию представлена очень широко. Из ранних развернутых обзоров по этой теме следует отметить [2]. В данном обзоре рассмотрено 47 статей за период с 1997 по 2006 год и выполнен анализ публикаций на основе следующих основных характеристик: тип модели, горизонт предсказания, используемые входные переменные, используемые методы предварительной обработки данных, результаты прогнозирования. Из недавних обзоров по интересующей теме можно выделить [3–5]. В [3], как наиболее объемной из данных работ, рассмотрены научные публикации, индексируемые в наукометрических базах Web of Science (304 публикации) и Scopus

(497 публикаций) за 1989–2013 годы. Обзоры [4], [5] хоть и являются относительно новыми, но тоже опираются на работы, выполненные до 2014 года.

Согласно указанным источникам все методы прогнозирования рыночных цен на электроэнергию можно разделить на следующие основные группы: методы, основанные на мультиагентных и теоретико-игровых моделях; методы на базе имитационных моделей; методы, основанные на анализе временных рядов. Последнюю группу методов можно разделить на методы, использующие стохастические модели, статистические модели и модели искусственного интеллекта, построенные на базе искусственных нейронных сетей (ИНН).

Как показано в [3] при краткосрочном прогнозирования цен на электроэнергию статистические методы и методы на базе искусственного интеллекта показали наилучшие результаты. В [6] указано, что прогнозирование почасовых значений цены существенно осложняется нелинейным поведением и быстрыми изменениями данных. В таких условиях, как утверждается в [6], прогнозирование на базе ИНН является более эффективным подходом по сравнению со статистическими методами. О том, что ИНН обладают лучшими возможностями для моделирования неизвестных законов изменения временных рядов свободных цен на электроэнергию также отмечено в [7]. Поэтому авторами было принято решение об использовании для прогнозирования свободных цен на электроэнергию аппарата ИНН.

Актуальную информацию, посвященную применению различных видов ИНН для прогнозирования цен на электроэнергию можно найти в обзорах [8], [9]. В [8] рассматриваются такие виды ИНН как многослойный персептрон (Multilayer perceptron – MLP), прямонаправленные нейронные сети (feed-forward Neural Networks – FFNN), рекуррентные (recurrent NN – RNN), каскадные, вероятностные, нечеткие ИНН, а также гибридные подходы, комбинирующие ИНН с другими известными технологиями, такими как фильтр Калмана, хаотическая динамика и вейвлет преобразование. В [9] дополнительно описаны нейронные сети на основе радиальных базисных функций (radial bias function NN – RBFNN) и нейронные сети, использующие генетические алгоритмы. Применение популярных в последнее время методов глубокого машинного обучения и глубоких нейронных сетей для прогнозирования цен на электроэнергию рассмотрено в [10], [11].

Проведенный анализ показал, что из всех типов традиционных архитектур ИНН для прогнозирования цен на электроэнергию чаще всего использовались FFNN (включая MLP, RBFNN и другие) и RNN. При этом из всех типов FFNN наиболее популярным для прогнозирования цен на электро-

энергию является MLP. На его долю приходится большая часть публикаций. Из глубоких ИНН, применяемых для прогнозирования цен на электроэнергию можно выделить сверточные нейронные сети (convolutional NN – CNN) и сети долгой краткосрочной памяти (long short term memory NN – LSTM NN).

Авторы провели анализ доступных публикаций, на которые были ссылки в рассмотренных ранее обзорах и в сети Интернет, на предмет информации о том, какие средства использовались для реализации прогнозирования на базе ИНН. Из всех публикаций, в которых была приведена информация об инструментах реализации ИНН, большая часть приходится на пакет MATLAB [12–14]. В пакет MATLAB входит Neural Network Toolbox (в настоящее время преобразован в Deep Learning Toolbox), предоставляющий мощные средства для работы с ИНН. Следующим по популярности средством для реализации прогнозирования цен на электроэнергию на базе ИНН является язык Python [10], [15]. Но если рассматривать публикации только за последние три года, то Python здесь является безусловным лидером. Python считается одним из наиболее перспективных языков программирования в области математических расчетов, машинного обучения и искусственного интеллекта. Поэтому, по мнению авторов, в настоящее время, наиболее подходящим инструментом для разработки приложения для прогнозирования на базе ИНН, является использование языка Python и одной из его библиотек для работы с ИНН.

Приложение для анализа и прогнозирования

В настоящее время к наиболее популярным библиотекам для работы с ИНН на языке Python относятся TensorFlow, Keras, NeuPy, PyTorch, NeuroLab, Lasagne, Scikit-Neural Network. Keras, NeuPy, Lasagne и Scikit-Neural Network являются высокоуровневыми библиотеками, основанными на известных платформах глубокого машинного обучения. Keras и NeuPy используют в качестве такой платформы библиотеку TensorFlow. Keras также можно подключить к Theano, на базе которой построены также библиотеки Lasagne и Scikit-Neural Network. Scikit-Neural Network кроме того использует для своей работы популярную библиотеку машинного обучения Scikit-Learn.

Авторами принято решение использовать в приложении для прогнозирования цен на электроэнергию библиотеки NeuroLab и Keras. Достоинствами библиотеки NeuroLab являются ее простота, совместимость по синтаксису функций с Neural Network Toolbox MATLAB, множество алгоритмов тренировки ИНН. NeuroLab поддерживает такие архитектуры ИНН как

MLP и некоторые виды RNN. Включение в состав приложения популярной библиотеки Keras связано с желанием авторов предоставить в распоряжение пользователю мощный инструмент глубокого машинного обучения. Keras, кроме MLP, обеспечивает поддержку таких перспективных нейросетевых архитектур как CNN и LSTM NN. Помимо этого, достоинством библиотеки Keras является ее высокая гибкость и возможность существенного ускорения вычислений с большими объемами данных при использовании специальных графических процессоров (Graphics Processing Unit – GPU).

Разработанное авторами приложение выполняет следующие основные функции:

- чтение почасовых цен за определенный период, кратный месяцу, из БД для определенной категории, мощности и уровня напряжения;
- статистический анализ выбранного набора данных. Построение графиков изменения цены в разрезе дней или часов в абсолютных или относительных значениях. Построение графиков автокорреляционных функций цены в разрезе дней или часов;
- подготовка различных наборов данных (Data Sets) для обучения нейронной сети. Сохранение сформированных наборов данных на диске, загрузка наборов с диска, экспорт наборов в формат .csv;
- выполнение функций предварительной обработки и подготовки данных для прогнозирования;
- создание ИНН заданного типа и структуры. Ввод параметров алгоритма обучения ИНН. Отображение информации о результатах обучения ИНН;
- прогнозирование цен на заданный месяц или день вперед. Отображение результатов прогнозирования в табличном и графическом виде. Расчет стандартных показателей точности прогноза;
- сохранение данных прогнозирования в файл, загрузка ранее сохраненных результатов из файла;
- запись данных о почасовых ценах за месяц из файла формата .csv в БД.

В качестве исходных данных для прогнозирования использовалась информация о свободных ценах на электроэнергию в Ярославской области России за период с 2013 по 2019 годы, публикуемая на сайте ПАО «ТНС энерго Ярославль» [16]. Данная информация представлена в виде файлов формата Microsoft Word, Microsoft Excel и pdf. При проведении анализа и прогнозирования требуется выполнять операции выборки данных за определенный период для различных условий. Поэтому для удобства работы с данными была создана база данных (БД) системы прогнозирования, куда была перенесена информация о ценах из отдельных файлов.

Разработанное приложение позволяет подготавливать различные наборы данных (Data Sets) для обучения и тестирования ИНН, а также загружать подготовленные ранее наборы с диска. Наборы данных отличаются по количеству и составу признаков. Они включают следующие основные признаки: час, день, день недели, месяц, год, данные о ценах в прошедшие моменты времени. Значения задержек в часах (lags), которые использовались для задания цен, выбирались по результатам корреляционного анализа и литературным данным [17]. В результате были выбраны значения задержек $l \in L = \{1, 2, 3, 24, 48, 168\}$.

Как было сказано ранее MLP является наиболее популярным типом ИНН, используемым для прогнозирования цен на электроэнергию. Поэтому основным типом ИНН, используемым для прогнозирования цен на электроэнергию, в разрабатываемом приложении был выбран MLP. При этом для получения допустимой точности прогнозирования достаточно всего двух скрытых слоев [17]. Исходя из этого, для прогнозирования использовалась ИНН в виде MLP с двумя скрытыми слоями и единственным нейроном в выходном слое. Разработанное приложение позволяет пользователю определять структуру ИНН, путем задания числа скрытых слоев и числа нейронов в каждом скрытом слое. Пользователь также может выбирать используемый алгоритм поиска, число циклов и точность процесса обучения.

Результаты прогнозирования

С помощью разработанного приложения авторы провели множество численных экспериментов по прогнозированию цен на электроэнергию. В ходе экспериментов исследовалась качество прогноза в зависимости от выбранных входных наборов данных, применяемой библиотеки для создания ИНН, структуры ИНН, используемых алгоритмов обучения, числа циклов обучения и других факторов. Результаты прогнозирования проверялись как на существующих данных, так и на данных о реальных ценах, которые были получены в следующем месяце. Для оценки результатов прогнозирования использовался известный показатель MAPE (Mean Absolute Percentage Error).

Свободные цены на электроэнергию имеют явный сезонный характер и сильно привязаны к текущему календарному месяцу. Анализ цен показал, что характер изменения цены в пределах месяца, положение ее минимумов и максимумов, скорее напоминает поведение цены в аналогичный месяц прошлого года, чем в предыдущий месяц того же года. Поэтому использо-

вание информации о прошлогодних ценах позволило существенно улучшить результаты прогнозирования. На рис. 1 пунктирной линией показаны результаты прогнозирования почасовой цены для ноября 2019 года по дням, для временного интервала с 10 до 11 часов, а сплошной линией – реальные значения цены. Прогнозирование выполнялось с помощью NeuroLab. Значение MAPE для данного прогноза составило 1,765. Для сравнения, на рис. 2 показаны результаты прогнозирования почасовой цены, выполненные для тех же условий, что и в предыдущем случае, но полученные с помощью Keras. Значение MAPE в этом случае составило 1,61.

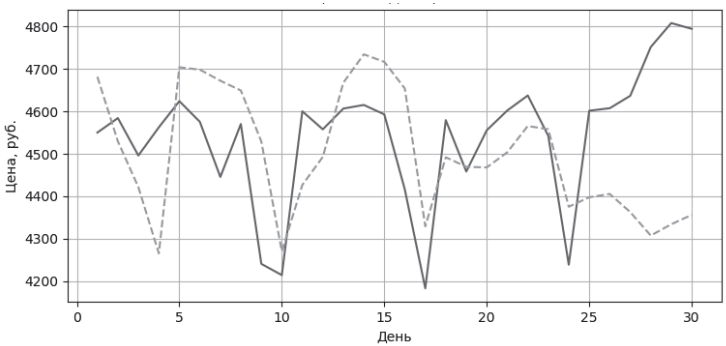

Рис. 1. Прогноз цены в ноябре 2019 г. (NeuroLab)

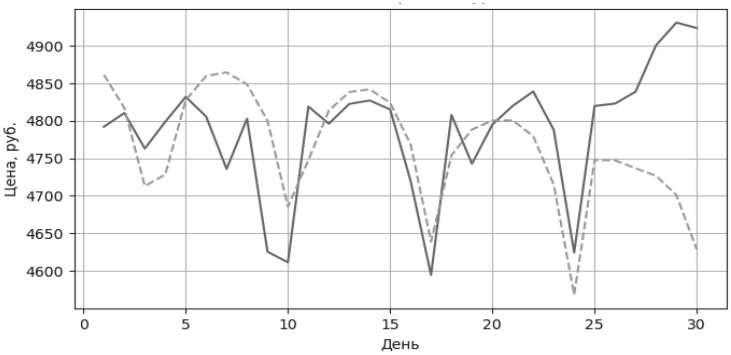

Рис. 2. Прогноз цены в ноябре 2019 г. (Keras)

В табл. 1 показаны значения MAPE, полученные при прогнозировании с использованием библиотек NeuroLab и Keras для MLP с двумя скрытыми

слоями при различном числе нейронов в скрытых слоях. Значения MAPE определялись в результате усреднения по результатам десяти прогонов прогнозирования для каждого варианта структуры. Так же было установлено, что наибольшая точность прогнозов достигалась при применении при обучении ИНН алгоритма Бройдена-Флетчера-Голдфарба-Шенно (BFGS) для библиотеки NeuroLab и алгоритма Nadam для Keras.

Таблица 1

Значения MAPE для различных вариантов структуры ИНН

ИНН	Число нейронов в скрытом слое 1	Число нейронов в скрытом слое 2	MAPE (NeuroLab)	MAPE (Keras)
1	16	4	1,86	1,72
2	20	5	1,765	1,61
3	25	5	1,803	1,53
4	24	6	1,815	1,57
5	36	6	1,911	1,61
6	64	8	2,152	1,77

В табл. 2 показаны значения MAPE, полученные при прогнозировании цен на электроэнергию для шести последних месяцев 2019 года. Прогнозирование производилось на базе MLP с двумя скрытыми слоями с 20 нейронами в первом слое и 5 нейронами во втором слое. Как и ранее, значения MAPE усреднялись по результатам десяти прогонов прогнозирования для каждого месяца.

Таблица 2

Результаты прогнозирования для различных месяцев 2019 года

Месяц	MAPE (NeuroLab)	MAPE (Keras)
Июль	3,559	3,308
Август	2,484	1,708
Сентябрь	2,726	2,066
Октябрь	2,091	1,682
Ноябрь	3,602	2,439
Декабрь	1,765	1,614

Как видно из приведенных данных, использование для прогнозирования библиотеки Keras позволяет в целом получить немного лучшие результаты по показателю MAPE.

Заключение

В работе рассмотрена задача прогнозирования почасовых свободных цен на электроэнергию с использованием аппарата ИНН. Авторы провели анализ литературных источников с целью определения наиболее популярных методов прогнозирования цен на электроэнергию, наиболее часто используемых при прогнозировании типов ИНН и существующих инструментов для реализации алгоритмов прогнозирования на базе ИНН. Для выполнения функций анализа и прогнозирования цен на электроэнергию авторами было разработано приложение на языке Python с использованием популярных библиотек для создания ИНН NeuroLab и Keras. В работе приведены результаты численных экспериментов по прогнозированию цен на электроэнергию с использованием разработанного приложения, в ходе которых исследовалась качество прогноза в зависимости от применяемой библиотеки, структуры ИНН и используемых алгоритмов обучения.

В дальнейшем планируется расширить поддержку библиотеки Keras в разработанном приложении. Такие ИНН, как CNN и LSTM NN, еще только начинают использоваться для прогнозирования цен на электроэнергию, и их потенциал еще далеко не раскрыт. Широкие возможности языка Python, его библиотек машинного обучения, глубокого машинного обучения и визуализации данных открывают новые перспективы для повышения качества анализа и прогнозирования свободных цен на электроэнергию.

Список литературы

1. Золотова И.Ю., Дворкин В.В. Краткосрочное прогнозирование цен на российском оптовом рынке электроэнергии на основе нейронных сетей // Проблемы прогнозирования. 2017. № 6. С. 47–57.

2. Aggarwal S.K., Saini L.M., Kumar A. Electricity price forecasting in deregulated markets: A review and evaluation // Electrical Power and Energy Systems. 2009. V. 31. P. 13–22.

3. Weron R. Electricity price forecasting: A review of the state-of-the-art with a look into the future // International Journal of Forecasting. 2014. V. 30 (4). P. 1030–1081.

4. Singh N., Mohanty S.R. A Review of Price Forecasting Problem and Techniques in Deregulated Electricity Markets // Journal of Power and Energy Engineering. 2015. V. 3. P. 1–19.

5. Singh N., Mohanty S.R., Mishra K.K., Neri F. A Review of Electricity Price Forecasting Problem and Techniques in Deregulated Markets // International Journal of Economics and Statistics. 2017. V. 5. P. 101–112.

6. Amjady N., Hemmati M. Energy price forecasting problems and proposals for such predictions // IEEE Power and Energy Magazine. 2006. V. 4 (2). P. 20–29.

7. Zhang J., Tan Z., Yang S. Day-ahead electricity price forecasting by a new hybrid method // Computers and Industrial Engineering. 2012. V. 63. P. 695–701.

8. Vijayalakshmi S., Girish G.P. Artificial Neural Networks for Spot Electricity Price Forecasting: A Review // International Journal of Energy Economics and Policy. 2015. V. 5 (4). P. 1092–1097.

9. Sarada K., Tulasi Ram S.S. Different ANN Models for Short Term Electricity Price Forecasting // International Journal of Recent Technology and Engineering. 2019. V. 8 (3). P. 6706–6712.

10. Lago J., De Ridder F., De Schutter B. Forecasting spot electricity prices: deep learning approaches and empirical comparison of traditional algorithms // Applied Energy. 2018. V. 221. P. 386–405.

11. Tian C., Ma J., Zhang C., Zhan P. A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network // Energies. 2018. V. 11. P. 1–13.

12. Catalao J.P.S., Mariano S.J.P.S., Mendesb V.M.F., Ferreira L.A.F.M. Short-term electricity prices forecasting in a competitive market: A neural network approach // Electric Power Systems Research. 2007. V. 77. P. 1297–1304.

13. Anbazhagan S., Kumarappan N., Neelan S. Electricity Price Forecasting in an Ontario Power Market Using Artificial Neural Network // First International Conference on Computation of Power, Energy, Information and Communication. 2012. P. 1–4.

14. Salahat S., Awad M. Short-term forecasting of electricity consumption in Palestine using artificial neural networks // International Journal of Artificial Intelligence and Applications. 2017. V. 8, No. 2. P. 11–21.

15. McGlynn D., Coleman S., Kerr D., McHugh C. Day-Ahead Price Forecasting in Great Britain's BETTA Electricity Market // IEEE Symposium on Computational Intelligence for Financial Engineering and Economics. 2018. P. 1–5.

16. https://yar.tns-e.ru/legal-entities/prices/

17. Ranjbar M., Soleymani S., Sadati M., Ranjbar A.M. Electricity Price Forecasting Using Artificial Neural Network // International Conference on Power Electronics, Drives and Energy Systems, 2006. P. 1–6.

N. KONNOVA
Bauman Moscow State Technical University
nkonnova@bmstu.ru

AUTOMATION OF THE CARDIOVASCULAR SYSTEM STATES DIAGNOSTICS ACCORDING TO FLOWMETRY DATA WITH APPLICATION OF NEURAL NETWORK ALGORITHMS

In connection with the advent of new devices and sensors for measuring flowmetry signals and the development of machine learning algorithms, it became possible to use these signals for the diagnosis of the cardiovascular system (CVS) diseases. Recent studies have shown the potential clinical benefits of flowmetry for the diagnosis and monitoring of certain heart diseases.

This article compares various machine learning algorithms and evaluates their effectiveness in solving the problem of diagnosing diseases of the cardiovascular system. Here, the results obtained with the help of multilayer perceptrons and convolutional neural networks to assign the submitted input cardiovascular data to one of the classes of states in the selected space are examined. A proprietary numerical experiment with real clinical data (confirmed by cross-validation) is performed on the basis of the most efficient neural networks with refinements for generalization and data preprocessing. As a result of the studies described in the article, the effectiveness of convolutional neural networks in the diagnosis of heart disease according to Doppler flowmetry is shown.

Keywords: *flowmetry, diagnostics of the cardiovascular system state, neural networks, machine learning, convolutional neural networks.*

Introduction

Doppler flowmetry is an ultrasound technique based on the use of the Doppler effect and allowing to obtain an envelope of blood flow velocity in a measured vessel (depending on the type of sensor: there are contact and bandage sensors; single-element and two-element sensors). The frequency range, flow rate characteristics, levels of peripheral resistance and kinematics significantly depend on the type of vessel and the patient's condition. More details about these dependencies can be found in [1, 2]. The results of processing flowmetry signals using an author’s technique, including primary processing, studying the internal organization of time series, spectral and time-frequency characteristics of signals, etc.

[1] can be used as input to algorithms and machine learning methods for constructing an automated classifier of the CVS state. The author has proposed a hierarchical model of a recognition system for assessing the functional state of the human CVS by various indicators of its activity [3, 6]. This work is a development of the author's research [1–9].

Source data and used methods

In this work, we used the data of ultrasound Doppler flowmetry of several tens of patients (both conditionally healthy and with various pathologies of the CVS), taken for each patient in different vessels: circumflex artery (CA), right coronary artery (RCA), left anterior descending artery (LAD), posterior descending artery (PDA), and others. The data are time series reduced to a frequency of 100 Hz (the initial sampling frequency depends on the type of instrument and is usually 1 kHz). The number of available points after preprocessing the data of healthy people was 36692, patients – 39113. In order to use the initial data in machine learning algorithms, they were divided into sections of 1000 ms, in which there is about one and a half period of fluctuation in blood flow velocity (see Fig. 1) Thus, we obtain a set of instances for training and testing machine learning algorithms, presented in the form of vectors of dimension 100.

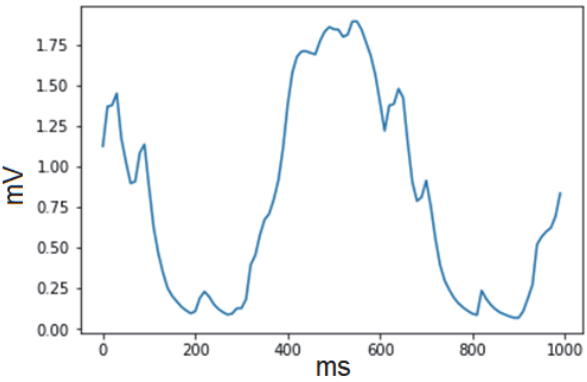

Fig. 1. An example of a quasi-period type for a blood flow fluctuation in a healthy person arterial vessel

Multilayer perceptron. A perceptron is an elementary neuron, which is a linear adder, each of the input signals of which is multiplied by some weight coef-

ficient, and the output total signal is nonzero if the sum exceeds a certain threshold value (first described in 1958 in [10]).

A multilayer perceptron [11] is a classic example of a feed-forward neural network, that is, a neural network in which there are no inverse effects of output neuron signals on the input of the network, or connections between neurons of the same layer. The scheme of a multilayer perceptron is shown in Fig. 2.

The use of the hidden layer in the architecture of a multilayer perceptron is dictated by the considerations of achieving a more adequate correspondence of the set of input signals to the set of output network parameters. An increase in the number of hidden layers makes it possible to single out higher-order statistical laws, which is an important circumstance in the case of a multidimensional input signal. The selection of the number of neurons is also an important task. Too few neurons can cause the network to not be able to learn, and too many can lead to overtraining, or overfitting (the network works well on the training set, but is not able to work on input parameters that are not included in the sample). One can either empirically select the number of neurons, or use regularization.

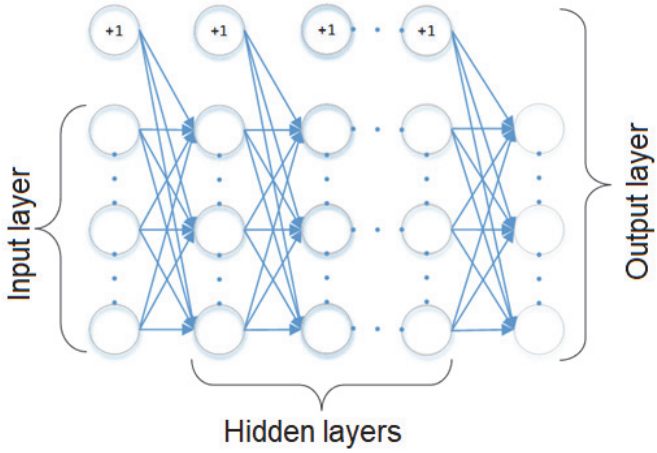

Fig. 2. Multilayer perceptron structure

Regularization is a method of adding constraints on model parameters, instead of reducing them. There are many regularization methods such as L_1, L_2, Dropout. In this work, Dropout regularization, which has been widely used recently, is used [12]. Dropout regularization consists in the fact that at each learn-

ing step each neuron is turned off with a certain probability p. An error propagation is carried out over such a thinned network (excluded neurons do not affect the learning process), after which all switched off neurons return to the neural network. Thus, at each step, one of the possible 2^N network architectures is configured, where N is the total number of neurons. When using a neural network, neurons are no longer turned off, but the output of each neuron is multiplied by $(1-p)$. Due to this, the output of the neuron will be the mathematical expectation of its response for all 2^N architectures. Thus, a neural network trained using Dropout regularization can be considered as a result of averaging 2^N networks.

In this work, ReLU (rectified linear unit) and sigmoid were chosen as activation functions (AF). Historically, the sigmoid was widely used, since its output is well interpreted as the level of neuron activation: from the absence of activation (0) to the fully saturated activation (1). However, this function is rarely used today, since it has one serious drawback – sigmoid saturation. It leads to the attenuation of gradients. The extremely undesirable property of the sigmoid is that when the function is saturated on one side or another (0 or 1), the gradient in these areas becomes close to zero. Since in the process of back propagation of the error, this (local) gradient is multiplied by the general gradient, then if the local gradient is very small, it actually resets the general gradient. As a result, the signal will hardly pass through the neuron to its weights and recursively to its data. Therefore, the sigmoidal activation function in this paper is used only in the output layer of the network to calculate the probability of belonging to the class. The ReLU activation function can be implemented using a simple threshold transformation and is not subject to saturation, in contrast to the sigmoidal activation function, therefore, it is used in hidden layers in this paper.

Convolutional neural network. Convolutional Neural Network (CNN) was first proposed for image recognition. CNNs consist of several types of layers: a convolutional layer, a subsampling layer, a layer of a fully connected network. The convolutional layer is a set of feature cards; each card has a synaptic core. The subsampling layer reduces the size of the input characteristics map (usually 2 times). This can be done in different ways, for example, one can use the max-pooling method. These two types of layers (convolutional, subsampling), alternating with each other, form an input feature vector for the last type of layer – a multilayer perceptron. The network can be trained using gradient methods.

Used assessment metrics

Let's consider the metrics used in assessing the quality of classification. The accuracy metric shows the proportion of correct results. This metric evaluates the model as a whole; alone, it is not informative in problems with an unequal ratio

of the number of objects of positive and negative classes. A class of an object is a patient's diagnosis (if the patient is healthy, then this is considered as a negative class object, if not, then as a positive). This metric is calculated using the following formula:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN},$$

where TP is the number of positive results identified as positive, TN is the number of negative results identified as negative, FP is the number of negative results identified as positive, FN is the number of positive results identified as negative.

The metric sensitivity, or recall, shows what proportion of objects of a positive class from all objects of a positive class the algorithm found. In other words, this metric demonstrates the ability of the algorithm to detect objects of a positive class. This metric is calculated using the following formula:

$$Sen = \frac{TP}{TP + FN}.$$

The specificity metric shows what proportion of objects of a negative class from all objects of a negative class the algorithm found. That is, this metric demonstrates the ability of the algorithm to detect objects of a negative class. It is calculated by the formula:

$$Spe = \frac{TN}{TN + FP}.$$

The precision metric shows how much of the objects called positive are positive. This metric does not allow writing all objects in one class with unequal distribution of classes. It is calculated by the formula:

$$Pre = \frac{TP}{TP + FP}.$$

The F_1 measure is the harmonic mean between accuracy and sensitivity. Measures of accuracy and sensitivity give an actually exhaustive assessment of the model, since accuracy does not allow the model to produce too many false-positive results, and sensitivity does not allow to reject too many objects of a positive class. Therefore, the harmonic mean between these two metrics can quite accurately characterize the model. This metric is calculated using the following formula:

$$F_1 = 2 \cdot \frac{Pre \cdot Sen}{Pre + Sen}.$$

Numerical experiment

In this paper, two multilayer perceptron (MLP) configurations and a convolutional neural network are considered as a classifier architecture. Their architectures are presented in tables 1 and 2. The second MLP configuration is different

from the first by adding a second hidden layer with similar parameters. A random forest algorithm was also tested, which at times shows higher results of classification accuracy, however, results using this algorithm are less stable and not portable if the source data changes.

Table 1

First perceptron configuration

Layer	**Parameters** Number of neurons, activation function
Input layer	100
First hidden layer	100, ReLU
Dropout regularization layer	The proportion of neurons for which a weight of 0 is assigned: 0.3; 05; 07 (an experiment was performed for each of the values)
Output layer	1, sigmoidal

Table 2

Convolutional neural network configuration

Input layer. Number of neurons	100
First convolution layer. Number of feature cards, convolution kernel size, padding[1], stride, output dimension, AF	(6;12;24), 3, 2, 1, $(100 \times 6; 100 \times 12; 100 \times 24)$, ReLU
First layer of a subsample. Type, number of elements, output dimension	Maximum value selection, 2, $(50 \times 6; 50 \times 12; 50 \times 24)$
Second convolution layer. Number of feature cards, convolution kernel size, padding, stride, output dimension	(6;12;24), 3, 2, 1, $(50 \times 6; 50 \times 12; 50 \times 24)$
Second layer of a subsample. Type, number of elements, output dimension, AF	Maximum value selection, $(25 \times 6; 25 \times 12; 25 \times 24)$, ReLU
Fully connected layer. Number of neurons, activation function	$(150; 300; 600)$, ReLU
Dropout-regularization layer. The proportion of neurons for which a weight of 0 is assigned	0.5
Output layer. Number of neurons, AF	1, sigmoidal

[1] To save size after convolution.

Adam [13] is used as an algorithm for optimizing the error functional for both configurations, and the logistic error function is used as the error functional:

$$loglos(y, \hat{y}) = -\frac{1}{N}\sum_{i=1}^{N}[y_i \log(\hat{y}_i) + (1 - y_i)\log(1 - \hat{y}_i)],$$

where y are the true values of the class labels, $\hat{y}$ are the predicted values of the class labels, N is the sample size. The number of epochs is 200. Given the relatively small amount of input data, the cross-validation method for selecting hyperparameters is used to evaluate the accuracy of classification algorithms [14].

The data set, on which the training and testing of the algorithms was performed, consisted of 353 instances of the time series of flowmetry for healthy people and 373 for patients, where each instance is a vector of blood flow velocity values taken at a frequency of 100 Hz, dimension 100. The data were separated by stratification into two groups: training and test (90% of training, 10 % of test). On training data, the optimal hyperparameters are selected, and on test data, the accuracy value of the model using these hyperparameters is calculated.

Results

Let's consider the results obtained using these models and assessment metrics.

Table 3

Dependence of the F_1 metric value on hyperparameters of the first configuration of a multilayer perceptron using the cross-validation method

D_1	0.3	0.5	0.7
F_1	0.695	0.681	0.670

Table 4

Dependence of the F_1 metric value on hyperparameters of the second configuration of a multilayer perceptron using the cross-validation method

D_1 \ D_2	0.3	0.5	0.7
0.3	0.699	0.657	0.642
0.5	0.641	0.634	0.629
0.7	0.631	0.627	0.620

The second configuration with the regularization parameters $D_1 = 0.3$ and $D_2 = 0.3$ has the best performance. This configuration was trained on the entire set of training data and tested on the test set, as a result of which the value of the F_1-measure is 0.685.

Table 5

Dependence of the F_1 metric value on hyperparameters of a convolutional neural network using the cross-validation method

K \ N	150	300	600
6	0.741	0.742	0.742
12	0.744	0.742	0.742
24	0.745	0.740	0.742

As one can see, the convolution network configuration with the parameters K = 24 and N = 150 has the best performance. This configuration was trained on the entire training data set and tested on the test set, as a result of which the value of the F_1-measure equal to 0.704 was obtained.

A numerical experiment was also carried out with the indicated neural network algorithms for the case of approximation using Chebyshev polynomials [7], which significantly reduces the input dimension and the transmitted signal duration (up to 10 times) when used in telemedicine, but it was not possible to increase the classification accuracy.

Findings

The obtained research results illustrate the possibilities of using flowmetry data in decision-making systems in the diagnosis and treatment of diseases of the human cardiovascular system. Including as subsystems based on machine learning methods. The model of time series constructed using flowmetry data can be used for secondary analysis or phase analysis [2] to build various options for implementing subsystems for recognizing the state of the CVS. The technique is applicable including for the analysis of ESCG data. Experimental observations are confirmed by the results of calculations performed using specialized developed software.

Acknowledgment

The reported study was partially funded by RFBR according to the research project № 18-29-02019.

References

1. Konnova N.S., Basarab M.A., Basarab D.A. Digital signal processing in Doppler flowmetry. Methods and Algorithms. Monograph. Lambert Academic Publishing. 2018. 233 p. (in Russian)

2. Konnova N.S., Basarab M.A., Basarab D.A., Matsievsky D.D., Mitrokhin V.N. Diagnosis of the state of the cardiovascular system using nonlinear digital signal processing of Doppler blood flow meters. Biomedical electronics (5), 3–12 (2017). (in Russian)

3. Konnova N.S., Basarab M.A.: Application of neural networks in cardiovascular decision support systems. Proc. of 7th International Conference on Advances in Computing, Electronics and Communication (ACEC 2018), theIRED. P. 73–78. Malaysia (2018). DOI: 10.15224/978-1-63248-157-3-27.

4. Konnova N.S., Basarab M.A., Basarab D.A. Image processing using artificial intelligence methods in cardiovascular decision support systems. Proc. SPIE 10836, 2018 International Conference on Image and Video Processing, and Artificial Intelligence, 108361U China (29 October 2018). DOI: 10.1117/12.2515343.

5. Konnova N.S., Basarab M.A. Identification of functional states of the cardiovascular system according to flowmetry data using machine learning methods. Proc. of 11th International Symposium on Computational Intelligence and Design (ISCID 2018). P. 221–224. China (2018). DOI 10.1109/ISCID.2018.00057.

6. Konnova N.S., Basarab M.A., Basarab D.A., Minin D.V. et all. Preparation and use of electroseismocardiography data for the diagnosis of the human cardiovascular system. Neurocomputers: development, application 1(21), 52–57 (2019). DOI: 10.18127/j19998554-201901-07. (in Russian)

7. Basarab M.A., Konnova N.S., Basarab D.A. Compression and Analysis of Ultrasonic Doppler Blood Flow Meter Data by the Discrete Chebyshev Transform. Progress in Electromagnetics Research Symposium. P. 3338–3341. Italy (2019) DOI: 10.1109/PIERS-Spring46901.2019.9017384.

8. Konnova N.S., Khaperskaya V.Yu. The use of neural networks and machine learning algorithms in the diagnosis of cardiovascular diseases based on SCG signals. Biomedical Radioelectronics 1(23), 5–20 (2020). DOI: 10.18127/j15604136-202001-01. (in Russian)

9. Konnova N., Basarab M., Khachatryan M., Domracheva A., Ivanov I. Convolutional neural networks application in cardiovascular decision support systems. Proceedings of SPIE – The International Society for Optical Engineering, 11321, 119. China (2019). DOI: 10.1117/12.2548193.

10. Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. Psychological Review 65, 386–408 (1958). DOI: 10.1037/h0042519.

11. Rychagov M.N. Neural networks: a multilayer perceptron and Hopfield networks. Mathematics in applications 1, 29–37 (2003). (in Russian)

12. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. Journal of Machine Learning Research 15, 1929–1958 (2014).

13. Kingma D.P., Adam J.B. A Method for Stochastic Optimization. The 3rd International Conference for Learning Representations, San Diego (2015).

14. Raschka S. Model evaluation, model selection, and algorithm selection in machine learning. University of Wisconsin–Madison Department of Statistics, (2018).

С.О. СТАРКОВ[1], Ю.Н. ЛАВРЕНКОВ[2]
[1]Обнинский институт атомной энергетики НИЯУ МИФИ
[2]Калужский филиал МГТУ им. Н.Э. Баумана
georglawr@yandex.ru

УПРАВЛЕНИЕ ДОСТУПОМ К СРЕДЕ ПЕРЕДАЧИ ДАННЫХ В РАСПРЕДЕЛЕННЫХ ИНФОРМАЦИОННЫХ СИСТЕМАХ НА БАЗЕ РЕКУРРЕНТНЫХ НЕЙРОННЫХ ЯЧЕЕК

Выполняется проектирование нейросетевого комплекса, состоящего из взаимодействующих динамических рекуррентных ячеек с развитыми системами обратных связей, для построения адаптивной беспроводной системы передачи данных. Разработана структура цифровой нейросетевой ячейки для выработки сигналов синхронизации, содержащей реконфигурируемые области памяти для подстройки системы синхронизации сети связи. На основе анализа способа взаимодействия нейросетевых блоков выполнена разработка алгоритма обучения и настройки параметров.

Ключевые слова: *нейросетевые рекуррентные ячейки, организация сетей связи, самонастраивающиеся алгоритмы поиска, нейросетевые структуры с развитой системой контуров обратной связи.*

Введение

Формирование линий передачи информации в сложных информационных системах между их компонентами осуществляется путем организации

беспроводных каналов связи с распределенной системой контроля и управления [1, 2]. Применение распределенного управления при организации беспроводных каналов передачи информации на основе рекуррентных нейросетевых ячеек обеспечивает безопасный обмен информацией с возможностью перестройки параметров сети связи и адаптации коммуникационных сигналов к изменяющейся топологии. Скрытность транслируемой информации достигается за счёт применения комплекса нейросетевых структур, базирующихся на объединении рекуррентных нейросетевых ячеек с возможностью управления динамикой их развития на основе формирования сложных многоконтурных обратных связей. В результате, безопасность передачи информационных сообщений достигается путем распределенного нейросетевого управления беспроводными средствами коммуникации, которое обеспечивает передачу информации без использования средств скремблирования [3]. Стратегия построения из нейросетевых элементов универсальных контроллеров, организующих скрытый обмен информационными сообщениями, базируется на гибкости объединения рекуррентных нейросетевых ячеек для создания реконфигурируемых систем управления.

Формирование беспроводной сети связи с распределенным нейросетевым управлением

Карта расположения передатчиков представлена на рис. 1.

Рассматриваемая архитектура сети связи включает в себя двенадцать передатчиков, формирующих базовые зоны покрытия A–L. На рисунке изображены зоны перекрытия сигналов от базовых станций. Такая компоновка делает возможным формирование зон с устойчивым приемом большой группы сигналов, например, в центральной области под номером 10 расположена зона перекрытия сигналов от шести передатчиков A–F. Передающие устройства применяются для трансляции сигнала синхронизации, применяемого для детектирования моментов времени, в которые передаётся полезная информация. На рис. 2 изображены сигналы, формируемые передающими устройствами в заданный интервал времени путем пространственного наложения сигналов синхронизации из соответствующих базовых зон.

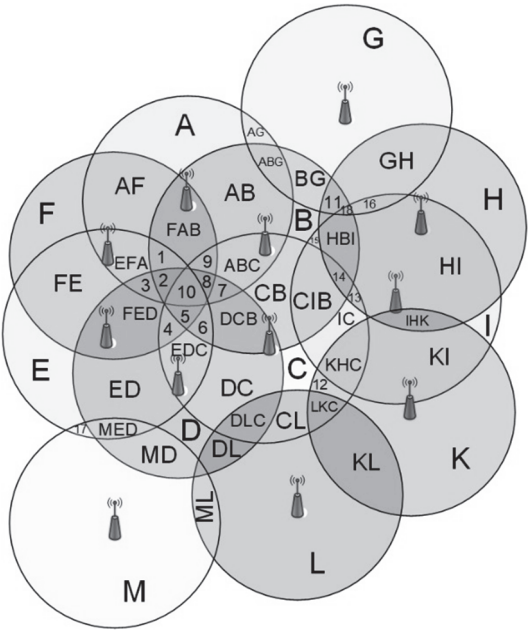

Рис. 1. Топологическая карта сети связи

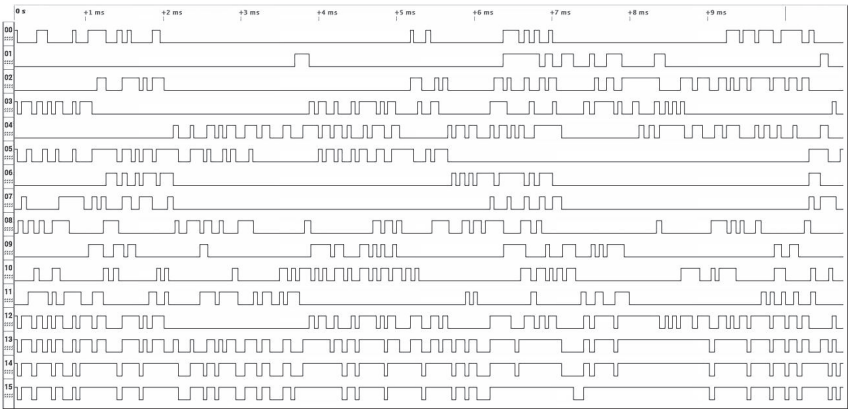

Рис. 2. Сигналы синхронизации в базовых зонах и пример формирования синхросигналов в перекрывающихся базовых областях

Для формирования синхросигналов предлагается применять искусственные нейроны, выполненные на рекуррентных ячейках. Синхросигналы распространяет группа передатчиков. Если не знать точного места расположения зон пересечения базовых станций для корректного приёма сигнала синхронизации становится затруднительным приём корректных информационных сообщений. Информационный передатчик работает в частотном диапазоне, отличном от диапазона передающих станций, генерирующих сигнал синхронизации. Для сокрытия моментов времени передачи данных применяется нейронная сеть, выполненная на основе нейронных ячеек с рекуррентными связями, производящими непрерывный информационный трафик. Полезная информация будет являться частью шумового информационного потока, определяемая в нем за счёт изменения синхросигнала, что скрывает передаваемые информационные сообщения, а также моменты активности передатчиков.

Разработка нейросетевых модулей и алгоритмов обучения

Нейронная сеть для производства информационного шума основана на применении динамических рекуррентных ячеек (ДРЯ) [4]. Импульсы из каналов обратной связи (ОС) могут воздействовать как на сам нейрон, так и подаваться на другие ДРЯ. Каждая нейросетевая ячейка обладает внутренним состоянием. Спроектированный структурный граф нейронной сети состоит из двух модификаций ДРЯ. Первая модификация ДРЯ изображена на рис. 3: f_1, f_4, f_5 – обратный гиперболический косинус, f_2 – обратный гиперболический синус, f_6 – гиперболический тангенс, f_3 – гауссова функция:

$$f_3(x) = e^{\frac{-0,5(x-c)^2}{\delta^2}}, \qquad (1)$$

где c = 0,37; δ = 0,783. Значения параметров: w_1 = -0,174, w_2 = 0,29, w_3 = 0,69, w_4 = 0,77, w_5 = -0,41, w_6 = 0,77. Для весовых множителей, входящих в контуры обратной связи установлены следующие значения: $w_\alpha = -0,097$, $w_\beta = -0,145$, $w_\gamma = 0,515$. В состав ДРЯ входит группа констант: c_1 = 0,135, c_2 = 0,495, являющихся источниками энергии для поддержания внутреннего ритма [5].

Вторая модификация ДРЯ показана рис. 4: f_1, f_2 –гиперболический синус, f_3 – гауссова функция (c = 2,35; δ = 1,78), f_4, f_5, f_6 – гиперболический синус.

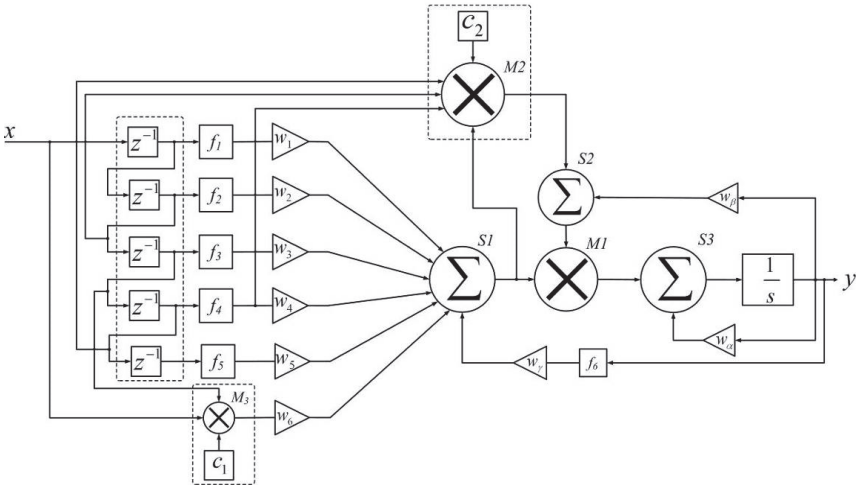

Рис. 3. Первая модификация рекуррентной ячейки

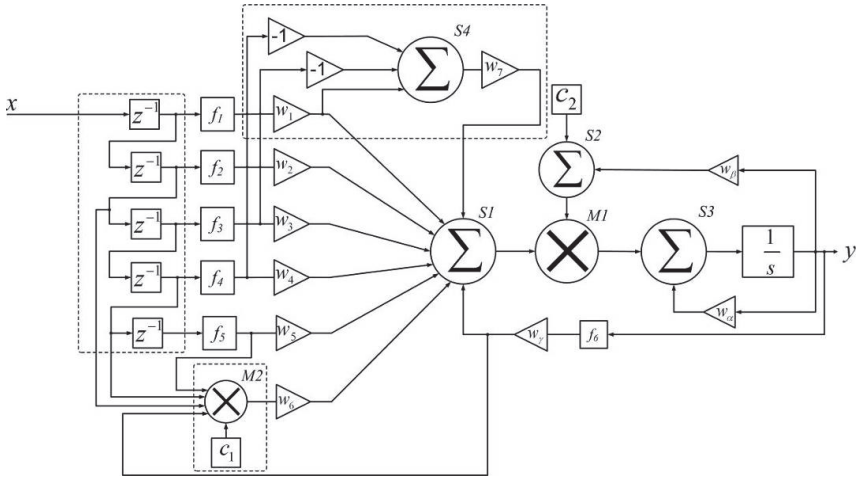

Рис. 4. Вторая модификация рекуррентной ячейки

Весовые коэффициенты: $w_1 = 0{,}35$, $w_2 = -0{,}25$, $w_3 = 0{,}67$, $w_4 = -0{,}79$, $w_5 = 0{,}18$, $w_6 = 0{,}31$, $w_\alpha = 0{,}21$, $w_\beta = -0{,}19$, $w_\gamma = 0{,}68$. Значения констант: $c_1 = 0{,}135$, $c_2 = 0{,}02167$.

Два типа модифицированных модулей являются основой для проектирования нейронной сети, архитектура которой показана на рис. 5.

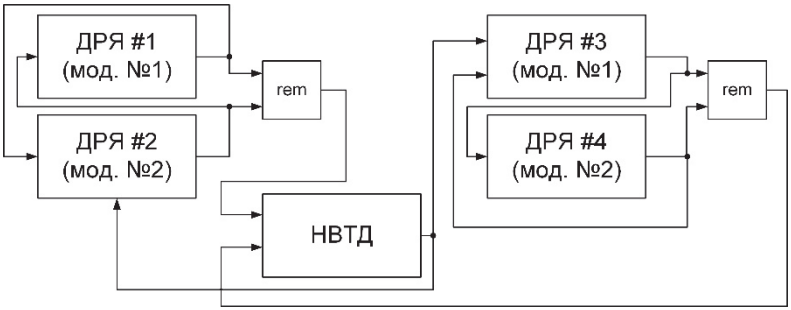

Рис. 5. Архитектура нейронной сети, формируемой из рекуррентных ячеек с модифицированной архитектурой

Структурные связи между рекуррентными ячейками показаны на рисунке. Модуль *rem* вычисляет остаток от деления значения амплитуды выходного сигнала с рекуррентной ячейки (первая модификация) на значение амплитуды выходного сигнала со второй ДРЯ (модификация второго типа). В модули № 2 и № 3 вводятся сигналы с контуров глобальной ОС (выбор внутренних структур ячеек для получения и преобразования сигналов глобальной ОС рассмотрен ниже).

Взаимодействие нейросетевых ячеек осуществляется посредством контуров глобальной ОС, базирующихся на кластере нейронов с возбуждающе-тормозящей динамикой (НВТД). Архитектура НВТД показана на рис. 6. Модуль *TFc* осуществляет реализацию передаточной функции:

$$TFc(s) = \frac{s^3 + 5s^2 + 7s + 9}{2s^3 + s^2 + 0.76s + 1.71}. \qquad (2)$$

Весовые коэффициенты и константы принимают следующие значения: $w_1 = 0{,}112$, $w_2 = 0{,}23$, $w_3 = 0{,}75$, $w_4 = 0{,}45$, $w_5 = -0{,}38$, $c_1 = c_2 = 0{,}178$.

Рекуррентные ячейки № 1 и № 2 производят сигнал для возбуждающей части нейронного элемента – x_1, а № 3 и № 4 выполняют генерацию сигнала для тормозящего входа элемента – x_2. Для решения практических задач с помощью нейросетевых моделей данного класса необходимо выбрать эле-

менты ДРЯ для ввода сигналов с контуров обратной связи. Для определения точек ввода сигналов с контуров ОС модуля НВТД применяется венгерский алгоритм [4]. В случае успешной конфигурации выходной сигнал, формируемый нейронной сетью, изображен на рис. 7.

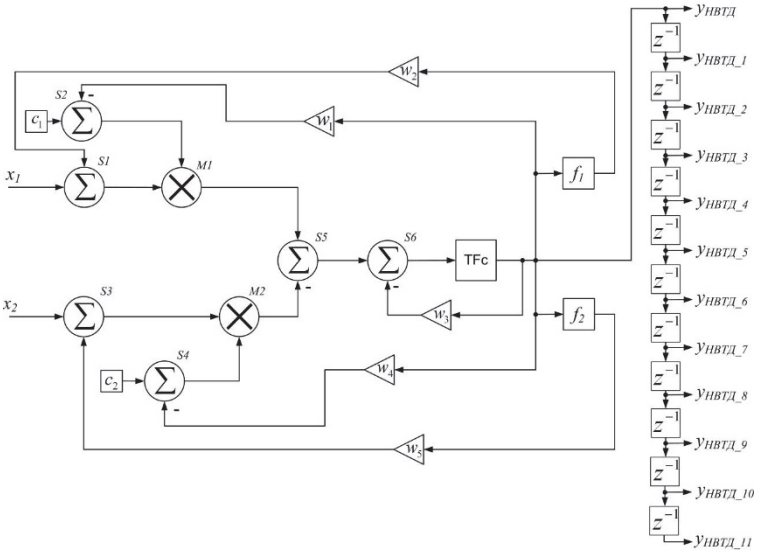

Рис. 6. Архитектура модуля НВТД

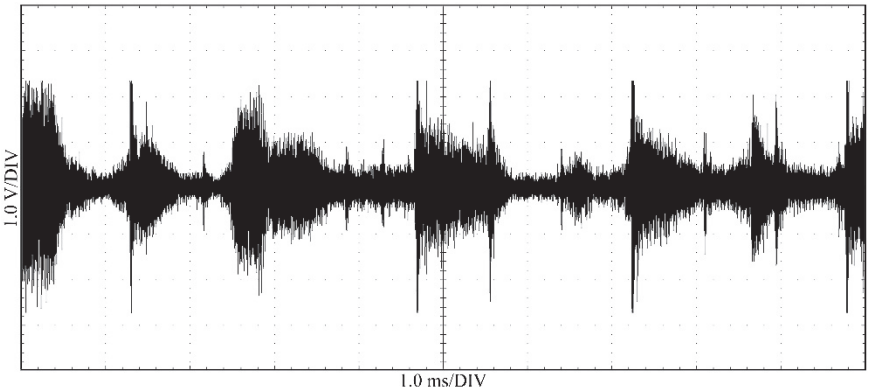

Рис. 7. Пример результирующего сигнала нейронной сети

Нейронная сеть генерирует непрерывный выходной сигнал, который для дальнейшей обработки необходимо преобразовать в двоичную последовательность. Полученный цифровой сигнал применяется для формирования информационных сообщений, передаваемых в эфир, из которых выделяется полезная информация с помощью сигнала синхронизации, формируемого динамическим нейроном. Архитектура динамического нейрона показана на рис. 8.

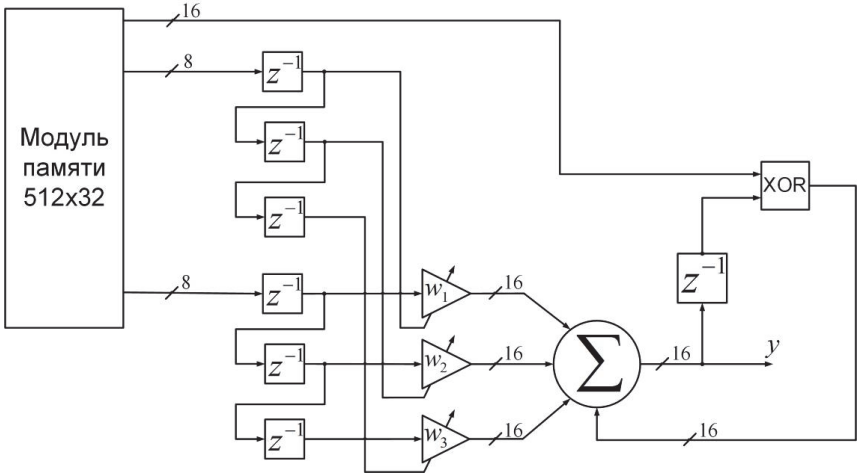

Рис. 8. Нейрон для генерации тактовых сигналов

Модуль памяти включает в себя 512 32-разрядных слов. Через 512 циклов работы системы, заключающихся в прохождении сигналов через нейрон и формировании выходного сигнала, процесс функционирования повторяется, но результирующий сигнал будет отличаться от сигнала, полученного на предыдущем этапе, из-за влияния обратной связи. Процесс генерации выходного сигнала определяется данными в модулях памяти и устройством контуров обратной связи.

Организация выходного интерфейса нейрона осуществлена в виде цифровой линии. Сигналы каждой линии используются для формирования сигналов синхронизации при передаче информационных посылок. Для формирования сложно прогнозируемой последовательности импульсов синхронизации, информация извлекается из каждого цифрового канала в случайном порядке. Для начального формирования содержимого модуля памяти применяется алгоритм на основе случайного поиска с самообучением [5].

Адаптивный алгоритм с элементами самонастройки базируется на алгоритме случайной оптимизации:

$$m_{i,j}(t+1)=\begin{cases} m_{i,j}(t)+\xi_i(t),\ if\ E(m_{i,j}(t)+\xi_i(t))<E(m_{i,j}(t)) \\ m_{i,j}(t),\ if\ E(m_{i,j}(t)+\xi_i(t))\geq E(m_{i,j}(t)) \end{cases}, \quad (3)$$

где $m_{i,j}$ – вектор, формируемый из блоков модуля данных, t – моменты времени работы системы, ξ – вектор изменения направления поиска.

Ошибка E определяет качество получаемого сигнала:

$$E=\frac{1}{e^{-(r_1-a)^2/\delta_1^2}+e^{-(r_2-4\cdot T)^2/\delta_2^2}}, \quad (4)$$

где $r_1=cs/clr$, cs – изменение состояния (0→1, 1→0), clr – частота тактирования рекуррентной ячейки, a и δ_1 – постоянные значения, определяющие требования к воспроизводимым зависимостям (a = 0,457, δ_1 = 0,425), r_2 – интервал времени между сменой состояний 0→1, T – время изменения состояния из 0→1 у сигнала синхронизации рекуррентной ячейки, $\delta_2=2{,}35\cdot T$. Способ самоадаптации реализуется в виде изменения вероятностных характеристик, т.е. в подборе значений вектора изменения направления поиска ξ. Правильная оптимизация приводит к ориентации вектора в пространстве, приводящей к уменьшению E. Метод адаптивной перестройки параметров вычисляет вероятность выбора определённого направления поиска в виде функции, характеризующей качество оптимизации системы [9]. Функция $F(\alpha)$ линейная:

$$F(\alpha)=\begin{cases} 0,\ if\ \alpha<-1 \\ \frac{1}{2}(1-\alpha),\ if\ -1\leq\alpha\leq 1 \\ 1,\ if\ \alpha>1 \end{cases} \quad (5)$$

Процедура обучения заключается в изменении параметра α:

$$\alpha(t+1)=\alpha(t)+\eta sign(\Delta m_j \Delta E_j(t-1)), \quad (6)$$

где η – коэффициент скорости самоадаптации, *sign* – функция определения знака.

Рассмотренный алгоритм применяется для настройки блока памяти рекуррентной ячейки. Динамика нейрона после оптимизации приводит к генерации выходных последовательностей, показанных на рис. 9.

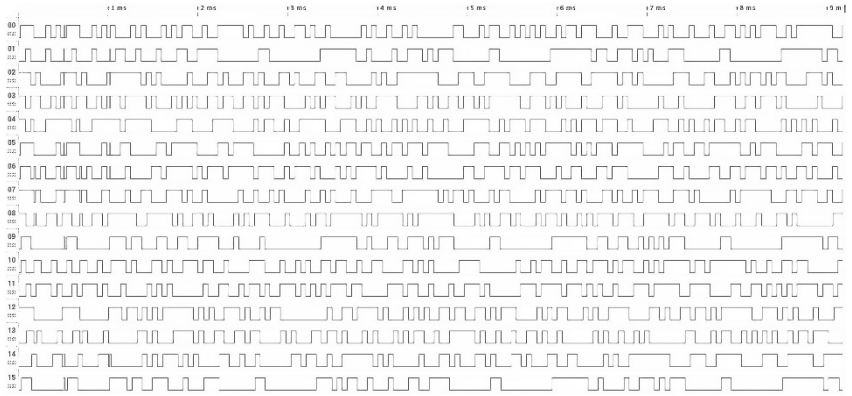

Рис. 9. Выходные сигналы рекуррентной ячейки

После реконфигурирования и настройки рекуррентных ячеек, нейронные сети, построенные на их основе, могут применяться для решения задачи безопасной передачи информации с применением пространственно-распределённых передатчиков. Передатчики, применяемые для передачи синхроимпульсов, формируют тактовые последовательности с применением рекуррентной ячейки. Каждая рекуррентная ячейка начинает процесс функционирования с одинаковыми начальными состояниями, данная особенность делает возможным восстановление синхроимпульсов каждым передатчиком. Передача информации в эфир производится в интервалы времени, отведенные для функционирования станций [6]. На определенном временном интервале выбранная станция осуществляет передачу тактовых последовательностей, которые могут применяться в областях покрытия станций. Передатчики, транслирующие информационные сообщения, могут восстанавливать последовательности тактовых импульсов (рекуррентная ячейка является частью передающей системы). Знание всех параметров рекуррентных ячеек, является ключевой информацией, на основе которой становится возможным вычисление значения шумового сигнала в определенные временные интервалы [7]. Информационные передатчики, выделяя тактовые импульсы, заменяют маскирующие биты шумовой последовательности на биты корректного передаваемого сообщения. Переключение синхросигнала $0 \rightarrow 1$ свидетельствует о наличии в эфире бита полезной информации.

Заключение

В статье рассмотрено проектирование и настройка нейронной сети, базирующейся на применении рекуррентных ячеек, которая может применяться для безопасной передачи информации в беспроводных сетях связи. Проанализирована системы передачи информационных сообщений, базирующаяся на группе передатчиков, которые транслируют информационные и тактовые сигналы на различных частотах. Спроектированная нейросетевая структура, базирующаяся на модифицированных рекуррентных ячейках, генерирует информационные посылки для формирования «информационного шума» и затруднения обнаружения корректных информационных последовательностей третьей стороной. Рекуррентная ячейка обладает простой внутренней структурой, что упрощает её реализацию и применение для формирования тактовых последовательностей в структурах сети связи. Разработанные алгоритмы конфигурирования нейросетевых ячеек делают возможным настройку нейросетевых блоков для оптимального формирования сигналов синхронизации и обеспечения стабильной работы системы.

Список литературы

1. Пролетарский А.В., Баскаков И.В., Чирков Д.Н., Федотов Р.А., Бобков А.В., Платонов В.А. Беспроводные сети Wi-Fi. М.: Национальный Открытый Университет «ИНТУИТ», 2016 (Основы информационных технологий).

2. Майк Предко. PIC-микроконтроллеры. Архитектура и программирование / Майк Предко. Саратов: Профобразование, 2017. 512 с.

3. Ulrich L. Rohde, Jerry C. Whitaker. Communications Receivers: DSP, Software Radios, and Design. The McGraw-Hill Companies, Inc. 2003.

4. Eliasmith, Chris. Neural engineering: computation, representation, and dynamics in neurobiological systems / Chris Eliasmith and Charles H. Anderson. 380 p. 2004 – (Computational neuroscience). «A Bradford book.» Includes bibliographical references and index. ISBN 0-262-05071-4.

5. Николенко С., Кадурин А., Архангельская Е. Глубокое обучение. СПб.: Питер, 2018. 480 с.: ил. (Серия «Библиотека программиста»).

6. Борисов В.И., Зинчук В.М., Лимарев А.Е., Мухин Н.П., Нахмансон Г.С. Помехозащищенность систем радиосвязи с расширением спектра сигналов модуляцией несущей псевдослучайной последовательностью / В.И. Борисов, В.М. Зинчук, А.Е. Лимарев, Н.П. Мухин, Г.С. Нахмансон; под ред. В.И. Борисова. М. Радио и связь, 2003. 640 с.

7. Яхъяева Г.Э. Нечеткие множества и нейронные сети: учебное пособие / Яхъяева Г.Э. М., Саратов: Интернет-Университет Информационных Технологий (ИНТУИТ), Вузовское образование, 2017. 320 с.

M. BASARAB, I. IVANOV, B. LUNIN
Bauman Moscow State Technical University
bmic@mail.ru

NEURAL NETWORK ALGORITHM FOR FORECASTING AND PARAMETER ESTIMATION OF THE CORIOLIS VIBRATORY GYROSCOPE

The accuracy of the Coriolis vibratory gyroscope is determined by the technological factors of manufacturing its resonator and the heterogeneity of its physical characteristics. The elimination of heterogeneities primarily requires the accurate determination of their parameters (amplitudes, locations). In this work, the problem of identifying the parameters of the Coriolis vibratory gyroscope, using time series data for the main and quadrature signals obtained from information pickup sensors is considered. As a dynamic model of the gyroscope, a system of two second-order ordinary differential equations with coefficients associated with the parameters of the device is used. The algorithm for identifying unknown parameters is based on the use of an autoregressive model of the time series and a single-layer neural network that implements forecasting. The method gives us the possibility to get an explicit interpretation of the weight coefficients of the forecast model of the two-dimensional time series.

Keywords: *Coriolis vibratory gyroscope, time series, forecasting, autoregression.*

Introduction

The solid-state wave gyroscope (SWG) belongs to the class of the so-called Coriolis vibration gyroscopes [1–3] measuring an angular rate on the base of the precession of elastic waves excited in axisymmetric solid bodies (resonators), the effect discovered experimentally by G. Bryan [4]. In practice, the shells of revolution of cylindrical and hemispherical types (respectively, the cylindrical resonator gyroscope - CRG, and hemispherical resonator gyroscope - HRG), as well as elastic rings on torsion suspensions are most often used as such resonators.

The accuracy of the device strongly depends on technological factors of manufacturing the resonator and inhomogeneities of its geometry and physical characteristics (density, Young's modulus, etc.). The elimination of defects (called the trimming procedure) is one of the most important operations in the manufacture of the SWG and requires accurate determination of the parameters of such

inhomogeneities (amplitudes and locations) [5]. The three-dimensional equations of SWG dynamics are derived based on the models of the theory of elasticity of thin-walled shells and, as a rule, are rather cumbersome. However, given the fact that the main energy of elastic vibrations falls on the narrow edge of the shell, it is convenient to study the dynamics of the resonator based on its ring model. In the resonance mode, for a specific waveform, from the equation of dynamics of the elastic ring, a system of second-order ordinary differential equations (ODEs) for non-stationary amplitudes of the main and quadrature waves can be obtained, which are used for decomposition of the initial ideal standing wave in the presence of the angular rate of the basement or in the presence of inhomogeneities of the resonator material. These amplitudes can be evaluated, with a certain sampling rate, from signals from a pair of information pickup sensors. The problem is to identify the dynamic parameters of the SWG operation (angular rate, angular acceleration) and the parameters of the standing wave drift caused by inhomogeneities in the physical characteristics of the resonator material. It is the identification of the parameters that cause drift that is the most complicated problem, for the solution of which a number of methods have been proposed [1, 2, 5], none of which can be considered universal. In this paper, a new approach is proposed, based on the construction of a neural network autoregressive model of time series corresponding to signals from SWG sensors. Further, by means of the autoregression coefficients, the sought parameters of the inhomogeneities of the distribution of mass and quality factor in the angular coordinate are determined.

Principle of SWG operation

The principle of operation of the SWG will be considered on the ring resonator model. A standing wave is excited in the resonator along one of the forms of plane vibrations, most often the second one. This wave is characterized by four nodes and four antinode points alternating through 45° (Fig. 1, a). When an angular velocity $\Omega = \Omega(t)$ occurs, the initial wave rotates over time t through an angle, with a coefficient of 0.4 (the «Bryan factor») proportional to the angle of rotation of the basement (Fig. 1, b):

$$\varphi(t) = \varphi_0 - \frac{2}{5}\int_0^t \Omega(s)ds, \tag{1}$$

where φ_0 is the initial standing wave orientation (antinodes and nodes).

Measuring the positions of antinodes oriented at 45 ° relative to each other, we can determine the angle, and from it, from Eq. (1), the desired angular velocity, in particular, at $\Omega = \text{const}$, we have

$$\Omega = \frac{5}{2} \cdot \frac{\varphi(t) - \varphi_0}{t}.$$

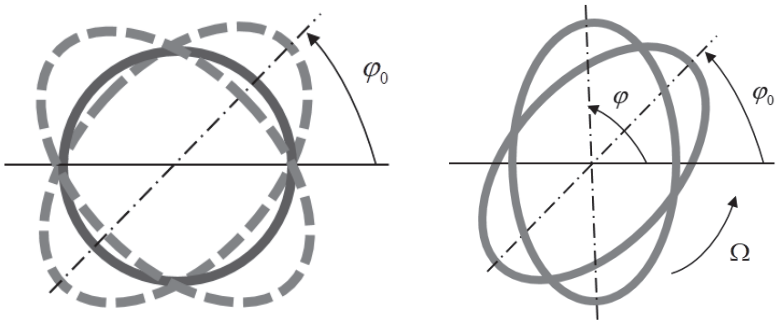

Fig. 1. The second vibrational mode of the SWG resonator (*a*) and the wave precession (*b*)

Mathematical model

Consider the ring model of free vibrations of an imperfect ring resonator with dissipation [2]:

$$\ddot{w}'' - \ddot{w} + 4\Omega\dot{w}' + 2\dot{\Omega}w' - \Omega^2(w^{\mathrm{IV}} + 3w'') + \left[\kappa^2(w'' + w)\right]^{\mathrm{IV}} + \\ + \left[\kappa^2(w'' + w)\right]'' + \xi\left[\kappa^2(\dot{w}'' + \dot{w})\right]^{\mathrm{IV}} + \xi\left[\kappa^2(\dot{w}'' + \dot{w})\right]'' = 0, \quad (2)$$

Here, $w = w(\varphi, t)$ is the radial movement of a point on the edge of the ring; $\Omega, \dot{\Omega}$ are angular rate and acceleration respectively; $\kappa^2 = EJ/(\rho SR^4)$; ρ is the density; S is the cross-section area; R is the radius of the middle neutral line; E is Young's modulus of the material; $J = h^4/12$ is the moment of inertia of the cross section relative to the neutral axis; h is the thickness; ξ is the decay time characterizing the quality factor of the resonator.

We further assume that the physical parameters are inhomogeneous in angle and therefore $\kappa^2 = \kappa^2(\varphi)$, $\xi = \xi(\varphi)$. We expand each of these parameters in a Fourier series:

$$\xi = \xi_0 + \sum_{l=1}^{N}\left(\Delta_{lc}^{(1)}\cos l\varphi + \Delta_{ls}^{(1)}\sin l\varphi\right),$$
$$\kappa^2 = \kappa_0^2 + \sum_{l=1}^{N}\left(\Delta_{lc}^{(2)}\cos l\varphi + \Delta_{ls}^{(2)}\sin l\varphi\right). \quad (3)$$

Here $\Delta_{lc}^{(1)}, \Delta_{ls}^{(1)}, \Delta_{lc}^{(2)}, \Delta_{ls}^{(2)}$ are the components of the amplitudes of the l-th harmonics of the damping defect and elastic mass anisotropy respectively.

Let the initial conditions include the displacements and accelerations of the resonator points:

$$w(\varphi,0) = \alpha_0(\varphi), \quad \dot{w}(\varphi,0) = \alpha_1(\varphi).$$

We will represent the desired solution (2) in the form of the evolution of a wave excited by the second form of oscillation (Fig. 1):

$$w(\varphi,t) = p(t)\sin(2\varphi) + q(t)\cos(2\varphi). \quad (4)$$

Substituting (3) and (4) into (2), and applying the Galerkin method with basic functions $\sin(2\varphi)$, $\cos(2\varphi)$, we obtain a system of ODEs with respect to amplitudes (4):

$$\ddot{p} + \omega_0^2\left(\xi_0 + \Delta_{4c}^{(1)}\right)\dot{p} + \left(\Delta_{4s}^{(1)} - \frac{8}{5}\Omega\right)\dot{q} +$$
$$+\left(\omega_0^2 + \frac{36}{5}\Delta_{4c}^{(2)} + \frac{4}{5}\Omega^2\right)p + \left(\frac{36}{5}\Delta_{4s}^{(2)} - \frac{4}{5}\dot{\Omega}\right)q = 0,$$
$$\ddot{q} + \omega_0^2\left(\xi_0 - \Delta_{4c}^{(1)}\right)\dot{q} + \left(\Delta_{4s}^{(1)} + \frac{8}{5}\Omega\right)\dot{p} + \quad (5)$$
$$+\left(\omega_0^2 - \frac{36}{5}\Delta_{4c}^{(2)} + \frac{4}{5}\Omega^2\right)q + \left(\frac{36}{5}\Delta_{4s}^{(2)} + \frac{4}{5}\dot{\Omega}\right)p = 0,$$

where $\omega_0 = 6\kappa_0\sqrt{5}$ is the natural frequency of the second form of oscillations of the ideal resonator.

To identify the parameters of the 4th harmonics of defects, one should consider the resonator on a fixed basement, then (5) takes the form

$$\ddot{p} + \omega_0^2\left(\xi_0 + \Delta_{4c}^{(1)}\right)\dot{p} + \Delta_{4s}^{(1)}\dot{q} + \left(\omega_0^2 + \frac{36}{5}\Delta_{4c}^{(2)}\right)p + \frac{36}{5}\Delta_{4s}^{(2)}q = 0,$$
$$\ddot{q} + \omega_0^2\left(\xi_0 - \Delta_{4c}^{(1)}\right)\dot{q} + \Delta_{4s}^{(1)}\dot{p} + \left(\omega_0^2 - \frac{36}{5}\Delta_{4c}^{(2)}\right)q + \frac{36}{5}\Delta_{4s}^{(2)}p = 0. \quad (6)$$

Using the appropriate measuring circuit, one can obtain the amplitudes at discrete time moments:

$$p_n = p(t_n), \quad q_n = q(t_n) \quad (n = 0,1,2,\ldots). \quad (7)$$

The problem is as follows: given the values of time series (7) for a limited time interval $t \in [0,T]$, evaluate all the model parameters (6) ($\Delta_{4c}^{(1)}, \Delta_{4s}^{(1)}, \Delta_{4c}^{(2)}, \Delta_{4s}^{(2)}, \omega_0^2, \xi_0$).

Method of solution

A possible identification algorithm based on the least squares method was proposed in [6]. It allows an assessment even in the presence of measurement errors due to averaging over a large number of samples p_n, q_n. At the same time, this approach is rather cumbersome, requires the formation of the sixth order system of algebraic equations and, in some cases, especially in the presence of noise, can be unstable due to poor conditioning of the matrix of a system of linear algebraic equations.

In this paper, we propose a solution to the problem posed by solving the problem of forecasting time series (7) based on the autoregressive model [7–9]. Assuming that the dynamic process described by system (6) is quite smooth and, in addition, quasi-periodic, we restrict ourselves to a single-layer linear neural autoregression network (NNAR) [8] (Fig. 2, a):

$$p_j^* = \sum_{i=1}^{m} w_{1,2i-1} p_{j-i} + \sum_{i=1}^{m} w_{1,2i} q_{j-i}, \quad q_j^* = \sum_{i=1}^{m} w_{2,2i-1} p_{j-i} + \sum_{i=1}^{m} w_{2,2i} q_{j-i}, \quad (j = m,...,M), \tag{8}$$

where p_j^*, q_j^* are the predicted values; w_{1i}, w_{2i} are the weighting coefficients; m is the length of the two-dimensional sliding window; M is the the length of the training segment of the two-dimensional time series.

Finding the weights of a neural network is carried out according to the delta rule, reccurently ($k = 0,1,2,...$), starting with some starting set $w_{1i}^{(0)}, w_{2i}^{(0)}$:

$$\begin{aligned} w_{1,2i-1}^{(k+1)} &= w_{1,2i-1}^{(k)} + \eta p_i \left(p_j^* - p_j \right), \quad w_{1,2i}^{(k+1)} = w_{1,2i}^{(k)} + \eta q_i \left(p_j^* - p_j \right); \\ w_{2,2i-1}^{(k+1)} &= w_{2,2i-1}^{(k)} + \eta p_i \left(q_j^* - q_j \right), \quad w_{2,2i}^{(k+1)} = w_{2,2i}^{(k)} + \eta q_i \left(q_j^* - q_j \right). \end{aligned} \tag{9}$$

Here $\eta \in (0,1]$ is the learning rate.

Taking into account the non-explicit dependence between parameters p_n, q_n, one can also use a shortened forecast model (Fig. 2b, the similar model can be presented for q_j^*):

$$p_j^* = \sum_{i=1}^{m} w_i \, p_{j-i} \quad (j = m,...,M). \tag{10}$$

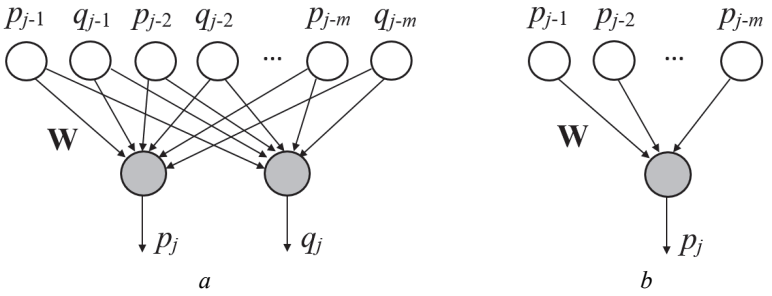

Fig. 2. Complete (*a*) and shortened (*b*) linear neural networks of autoregression

The neural network is trained by iterating through a sliding window along the training segment of the time series of length *M*, from the first sample ($j = m$) to the far right sample ($j = M$) with a single time lag.

After satisfying the convergence criterion (the smallness of the norm of the difference between the vectors of the predicted values (p_j^*), (q_j^*) and the actual measured values, (p_j), (q_j)), we will have a set of final weights of the forecast model (8).

To evaluate the parameters of model (6) by the found weight coefficients of the autoregressive model (8), the following algorithm can be used:

1. Replace the time derivatives in (6) with the help of finite differences of the *m*-th order [10], obtaining a finite-difference approximation of the system of differential equations (6).
2. Represent the extreme right values of the grid functions (p_j, q_j) through the previous values (p_{j-1}, q_{j-1}), (p_{j-2}, q_{j-2}),... in a form similar to (8).
3. Comparing both representations, we express the desired parameters $\Delta_{4c}^{(1)}, \Delta_{4s}^{(1)}, \Delta_{4c}^{(2)}, \Delta_{4s}^{(2)}, \omega_0^2, \xi_0$ in terms of weight coefficients w_{1i}, w_{2i}.

Numerical experiment

Example 1. Let us first consider the simplest case of an ideal SWG resonator, when $\kappa^2 = \kappa_0^2 = \text{const}$, $\xi = \xi_0 = \text{const}$. Then (6) has the form:

$$\begin{aligned} \ddot{p} + \omega_0^2 \xi_0 \dot{p} + \omega_0^2 p = 0, \\ \ddot{q} + \omega_0^2 \xi_0 \dot{q} + \omega_0^2 q = 0. \end{aligned} \tag{11}$$

Obviously, due to the fact that both equations of system (11) are independent, the forecast must be carried out according to scheme (10). For definiteness, we choose the amplitude p (for the amplitude q, the actions will be completely analogous). Let, for example, the length of the forecast window $m = 2$, then

$$p_j^* = w_1 p_{j-1} + w_2 p_{j-2} \quad (j = m, ..., M). \tag{12}$$

In accordance with the proposed algorithm, we replace the time derivatives in the first equation of (11) with finite-difference approximations of the second order of accuracy with respect to the time step τ [10]:

$$\ddot{p}(t_{j-1}) \approx \frac{p_j - 2p_{j-1} + p_{j-2}}{\tau}, \quad \dot{p}(t_{j-1}) \approx \frac{p_j - p_{j-2}}{2\tau}. \tag{13}$$

We substitute (13) into (11) and express p_j through the previous values:

$$p_j = \frac{2 - \omega_0^2 \tau^2}{0,5\omega_0^2 \xi_0 \tau + 1} p_{j-1} + \frac{0,5\omega_0^2 \xi_0 \tau - 1}{0,5\omega_0^2 \xi_0 \tau + 1} p_{j-2}. \tag{14}$$

Comparison of expressions (12) and (14) gives us a simple expression for the weights of the neural forecast network:

$$w_1 = \frac{2 - \omega_0^2 \tau^2}{0,5\omega_0^2 \xi_0 \tau + 1}, \quad w_2 = \frac{0,5\omega_0^2 \xi_0 \tau - 1}{0,5\omega_0^2 \xi_0 \tau + 1}. \tag{15}$$

We accept the following values of physical parameters:

- oscillation frequency $\omega_0 = 38598,5$ rad / s;
- attenuation factor $\xi_0 = 2,0 \cdot 10^{-7}$ s.

In a computational experiment, we use the parameters:

- sampling step $\tau = 1 \cdot 10^{-5}$ s;
- the length of the training interval $T = 0,0025$ s ($M = 250$ samples);
- learning rate $\eta = 1$.

During the experiment, in order to achieve a forecast quadratic error of less than 0.1 % on the interval $(T, 4T)$, it was necessary to implement 250,000 training eras. The obtained values of the weights are as follows

$$w_1 = -1, \quad w_2 = 0,851.$$

The relative error in calculating the eigenfrequency and attenuation coefficient by formulas (15) turned out to be less than $1 \cdot 10^{-7}$.

It should be noted that even a slight increase in the window length m leads to a significant decrease in the number of epochs required to ensure the same forecast accuracy, however, this complicates the task of interpreting the weight coefficients.

Example 2. Next we study the dynamics of imperfect SWG. Take the data from the previous example. Let now in (6): $\Delta_{4c}^{(1)} = 0,0114$, $\Delta_{4s}^{(1)} = 0,1462$; $\Delta_{4s}^{(2)} = -0,0154$.

Let training be carried out at the same interval $(0, T)$ and with the same step τ, but the length of the forecast window $m = 4$. The forecast results for the interval $(T, 2T)$ for 50,000 training eras are shown in Fig. 3. Values of weight coefficients are the following:

$$w_1 = -0,5231, \quad w_2 = -0,063, \quad w_3 = 0,4042, \quad w_4 = 0,8109.$$

It can be seen that using the reduced model (10), it is possible to achieve a satisfactory forecast quality. The relationship between weights and heterogeneity parameters is more complicated than in Ex. 1, however, a continuous relationship between them is still observed, which allows us to conclude that it is possible to build empirical dependencies.

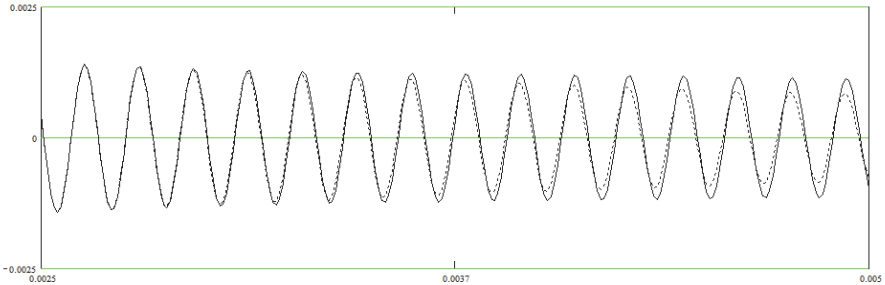

Fig. 3. Forecasting the time series for the imperfect SWG

Conclusion

A new method is proposed for estimating the parameters of an imperfect solid-state wave gyroscope based on the linear neural network autoregression model. In addition to the problem of estimating parameters, the problem of predicting the dynamics of oscillations is solved, which is important in optimizing inertial navigation algorithms. The method is flexible and efficient, and also allows one to get an explicit interpretation of the weight coefficients of the forecast model of the two-dimensional time series. The proposed approach can be used to evaluate the parameters of other types of CVGs [3].

References

1. Matveev V.A., Lipatnikov V.I., Alyokhin A.V. Design of the solid-state wave gyroscope. Bauman Press, Moscow (1997). (in Russian)

2. Lunin B.S., Matveev V.A., Basarab M.A. Solid-state wave gyroscope. Theory and design. Radiotekhnika, Moscow (2014). (in Russian)

3. Apostolyuk V. Coriolis Vibratory Gyroscopes. Theory and Design. Springer, Heidelberg (2016).

4. Bryan G.H. On the Beats in the Vibrations of a Revolving Cylinder or Bell. Proc. Camb. Phil. Soc. Math. Phys. Sci. 7, 101–111 (1890).

5. Basarab M.A., Matveev V.A., Ivoilov M.A. Genetic Algorithms for Balancing the Solid-State Wave Gyro. Proc. of the 16th St.-Petersburg Int. Conf. on Integrated Navigation Systems, 103-104 (2009).

6. Shatalov M., Lunin B.S. Vibratory Gyroscopes: Identification of Mathematical Model from Test Data. Proc. of the 14th St.-Petersburg Int. Conf. on Integrated Navigation Systems (2007).

7. Tarkhov D.A. Neural networks. Models and algorithms. Radiotekhnika, Moscow (2005). (in Russian)

8. Hyndman R.J., Athanasopoulos G. Forecasting: Principles and Practice. 2nd Ed. O'Texts, Melbourne (2018).

9. Golovko V.A. Neural networks: Training, organization, and application. Radiotekhnika, Moscow (2005). (in Russian)

10. Samarskii A.A. Introduction to numerical methods. Lan', Moscow (2005). (in Russian)

Г.Ф. МАЛЫХИНА, М.А. МЯЭ
Санкт-Петербургский политехнический университет Петра Великого
g_f_malychina@mail.ru

АВТОМАТИЧЕСКАЯ КЛАССИФИКАЦИЯ КРИСТАЛЛОВ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

Роботизация процессов сортировки кристаллов в горной промышленности является актуальной задачей, для решения которой необходимо разработать новые методы и алгоритмы. Перспективными источниками данных являются фотокамеры, позволяющие получать снимки кристаллов в нескольких проекциях. В этом исследовании разработаны алгоритмы автоматической сортировки кристаллов на основе обработки снимков кристаллов, полученных в семи проекциях. Сортировка основана на оценке прозрачности и цвета кристаллов. На этапе морфологической обработки предложен путь получения шаблона кристалла, характеризующего его форму. Применение шаблона позволило получить гистограммы цветов кристаллов. Главные компоненты гистограммы цветов являются признаками качества кристалла, которые поступают на вход многослойного персептрона, который принимает решение по отдельной проекции кристалла. Специальная нейронная сеть обобщает решения, полученные по каждой проекции. Такая архитектура позволяет уменьшить размер нейронной сети.

Ключевые слова: *машинное обучение, классификация кристаллов, роботизированная система.*

Введение

Роботизация производственных процессов в горной промышленности является современной проблемой, для решения которой необходимо разрабатывать современные методы и алгоритмы. К таким проблемам относится автоматическая классификация кристаллов, основанная на машинном обучении.

Использование машинного обучения позволит решить следующие приоритетные задачи:

- повышение производительности труда и эффективности работы производства;
- получение стабильно высокого качества сортировки, не зависящего от человеческого фактора;
- расширение товарной номенклатуры продукции.

В процессе сортировки кристаллы необходимо разделять по размеру, по форме и по качеству кристаллов [1]. В частности, качество алмазов определяется прозрачностью и цветом кристаллов. Наибольшую ценность представляют прозрачные алмазы и алмазы с небольшим оттенком, используемые в ювелирной промышленности. Менее ценятся алмазы насыщенных коричневых цветов, которые идут на переработку с последующим изготовлением из них точильных камней, порошков для полировки и других инструментов. В алмазной промышленности все добываемые кристаллы должны быть отсортированы по форме, прозрачности и цвету, причем от этих характеристик существенно меняется стоимость сырья [2]. Проблемы объективной оценки цвета прозрачности алмазов неоднократно анализировали исследователи при разработке технических средств автоматического определения характеристик алмазов и бриллиантов [3]. В производственном процессе используют фотокамеры, предоставляющие последовательность цветных снимков семи неортогональных проекций кристаллов и их анализа в роботизированной системе [4].

Целью статьи является разработка алгоритма системы автоматической классификации кристаллов на основе кадров фотосъемки с использованием машинного зрения и нейронных сетей.

Определение прозрачности и цветности кристаллов

Для автоматического анализа прозрачности кристалла предложено определять шаблон кристалла в виде бинарного черно-белого изображения. Для этого выполнена цепочка преобразований. На первом шаге выполнено преобразование тензора третьего порядка, характеризующего исходное RGB-изображение кристалла, к тензору второго порядка, характеризующему изображение в градациях серого.

На следующем шаге для определения границ кристаллов выполнен алгоритм Кэнни, устойчивый к присутствующему на изображении шуму [5]. Робастность этого алгоритма обеспечивается предварительным сглаживанием изображения низкочастотным гауссовым фильтром. В отличие от алгоритмов Собеля и Приюта алгоритм Кэнни вычисляет градиент интенсивности в четырех направлениях, и фиксирует перепады интенсивности на границах объектов путем обработки градиентов с двумя порогами [6].

Заполнение областей внутри границ Кэнни основано на рекуррентной процедуре условной дилатации $(\oplus)$:

$$X_k = \left(X_{k-1} \oplus B\right) \cap I^C, \qquad k = 1, .., K, \tag{1}$$

где I^C – комплементарное изображение, содержащее границы, X_k – новое изображение с заполнением областей на шаге k, B – примитив. После завершения операции заполнения $I = X_K$

Выполненные преобразования не всегда позволяют найти границы прозрачного кристалла. Поэтому предполагая, что кристаллы имею выпуклую форму, на следующем шаге выполнена операция замыкания, которая включает многократную дилатацию и многократную эрозию (Θ), выполняемые K раз:

$$T = \left(I * B\right)_K = \left(\left(I \oplus B\right)_K \Theta B\right)_K \quad (2)$$

В результате получен шаблон T – бинарное изображение формы кристалла.

Определение гистограммы цветов

Признаками классификации кристаллов является гистограмма цветов, которая содержит информацию о прозрачности и о цвете кристалла. Для того, чтобы исключить влияние фона, тензор третьего ранга, представляющий RGB-изображение поэлементно умножено на полученный шаблон кристалла:

$$I_{1RGB} = I_{RGB} \cdot T. \quad (3)$$

В результате получено RGB-изображение кристалла на черном фоне. Для этого изображения вычисляем гистограммы цветов. Гистограммы представляют собой тензор второго ранга с тремя строками цветов и N столбцами гистограмм:

$$\boldsymbol{H} = \begin{pmatrix} p(R_1) & p(R_2) & \dots & p(R_N) \\ p(G_1) & p(G_2) & \dots & p(G_N) \\ p(B_1) & p(B_2) & \dots & p(B_N) \end{pmatrix}, \quad (4)$$

где $p(R_i) = {}^{n_{Ri}}\!/_{n}$, $p(G_i) = {}^{n_{Gi}}\!/_{n}$, $p(B_i) = {}^{n_{Bi}}\!/_{n}$ – значения элементов гистограммы.

Вектор входных признаков получаем путем преобразования формы тензора второго ранга, характеризующего гистограмму цветов, в тензор первого ранга:

$$\boldsymbol{x} = (p(R_1), \dots, p(R_N), p(G_1), \dots, p(G_N), p(B_1), \dots, p(B_N)). \quad (5)$$

Можно предположить, что тензор содержит значительную избыточность, которая может быть уменьшена применением метода главных компонент. С этой целью вычисляется эмпирическая ковариационная матрица компонентов тензора входных данных:

$$\boldsymbol{C} = \left[c_{i,j}\right], c_{i,j} = \frac{1}{N-1}\sum_{l=1}^{m}(x_{l,i} - \bar{X}_i)\,(x_{l,j} - \bar{X}_j). \quad (6)$$

Векторы главных компонент имеют наибольшее рассеяние – ортонормированный набор собственных векторов матрицы **C**, расположенных в порядке убывания собственных значений. Отбор главных компонент позволил значительно снизить избыточность данных.

Нейронная сеть

Для классификации кристаллов целесообразно использовать нейросетевой алгоритм, который позволяет адаптировать систему к конкретному виду кристаллов, обучать и настраивать алгоритм при изменении требований к сортам кристаллов, работать в условиях шума, правильно выполнять классификацию ранее не предъявлявшийся типов кристаллов.

Применение в некоторых исследованиях метода восстановления трехмерной формы кристалла из двумерных проекций [7], [8] было отвергнуто по причине большого объема вычислений и нестабильности работы алгоритма при восстановлении сложной формы кристалла по относительно небольшому числу проекций.

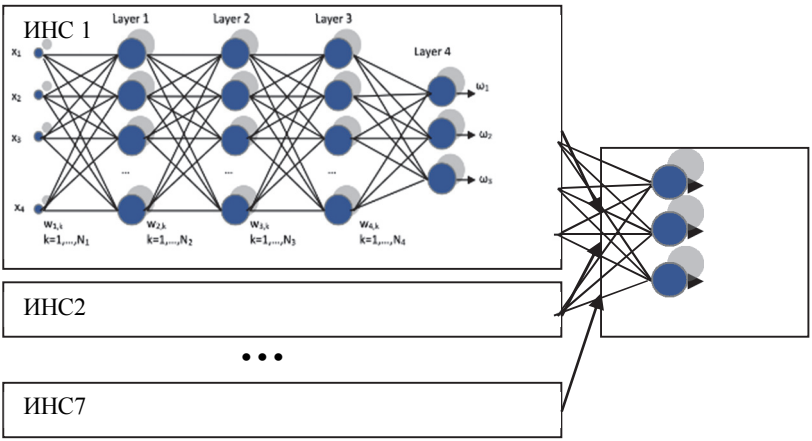

Рис. 1. Структура коллектива нейронных сетей

Напротив, было предложено использовать коллектив нейронных сетей [9], каждая из которых предназначена для классификации кристаллов по одной из проекций, и обобщающая небольшая нейронная сеть, которая предназначена для принятия решения о сорте кристалла [10]. Структура нейронных сетей показана на рис. 1.

Для классификации каждой проекции изображения был применен многослойный персептрон, с нелинейными активационными функциями $\phi_i = \tanh(z_i)$ нейронов во внутренних слоях и вероятностными нейронами выходного слоя: $\phi_i = \dfrac{\exp(z_j)}{\sum_{j \in group} \exp(z_j)}$, где i – индекс выходного нейрона, j – индекс каждого нейрона в группе выходных нейронов, z_j – выходной сигнал нейрона из группы выходных нейронов.

Результаты классификации кристаллов

Исходными данными послужили 600 кристаллов, для которых получены снимки в семи проекциях. Все кристаллы разделены на три группы низкого, среднего и высокого качества. Для обучения были использованы 300 кристаллов (по 100 кристаллов низкого, среднего и высокого качества) по 7 проекций для каждого кристалла. Таким образом, обучение нейронной сети было выполнено на основе общего количества 300*7 = 2100 изображений. Остальные 2100 изображений были использованы для валидации. Для тестирования мы имели возможность использовать изображения 600 кристаллов, представленных в семи проекциях.

Предварительная обработка изображений включала следующие операции морфологической обработки изображений: получение границ перепадов интенсивности, заполнение внутренних полостей, замыкание и многократное выполнение дилатации и эрозии. На рис. 2 показаны примеры выполнения морфологических операций для кристаллов, прозрачность которых не позволяет определить граница более простым методом.

На рисунке 2.b. показано, что после применения алгоритма Кэнни (формула 1) были нарушены границы кристалла по причине его прозрачности. После заполнения внутренних областей, замыкания, дилатации и эрозии по формуле (2) был получен шаблон изображения кристалла, показанный на рисунке 2.c. После применения шаблона к исходному изображению был удален фон и выделено цветное изображение кристалла в соответствии с формулой (3).

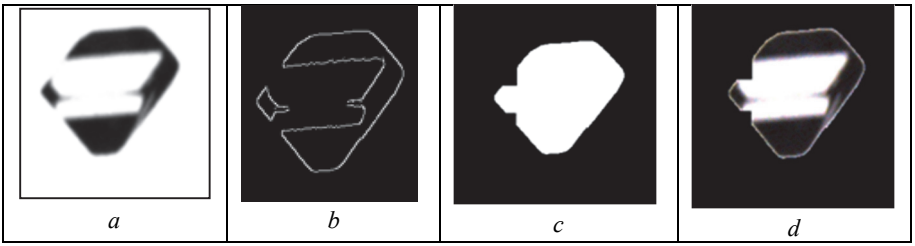

Рис. 2. Морфологическая обработка изображения кристалла:
a – исходное цветное RGB – изображение кристалла; *b* – результат применения алгоритма Кэнни; *c* –Шаблон изображения; d – применение шаблона к исходному изображению

Для каждой проекции кристалла по формуле (4) были получены гистограммы цветов для кристаллов низкого качества, показанные на рис. 3 и для кристаллов высокого качества, обладающих хорошим цветом и прозрачностью, показанные на рис. 4.

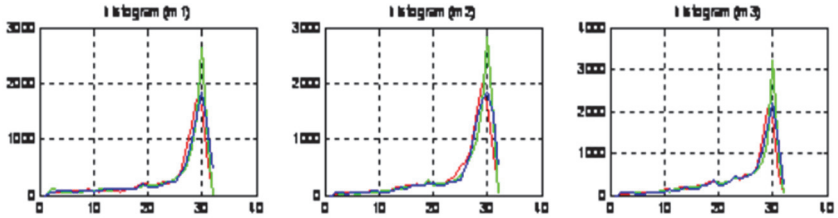

Рис. 3. Гистограммы цветов трех проекций кристалла низкого качества

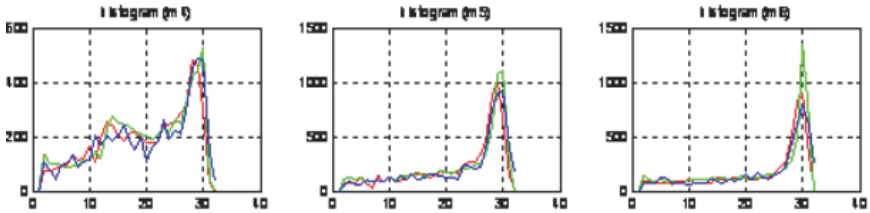

Рис. 4. Гистограммы цветов трех проекций кристалла высокого качества

Были вычислены гистограммы с 32 столбцами для трех цветов. Таким образом, всего 96 значений столбцов гистограмм интенсивности красного, зеленого и синего характеризуют кристалл в одной проекции. Гистограммы имеют различия. Для кристаллов высокого качества гистограммы содержат большее число светлых пикселей, чем кристаллы низкого качества, кроме того, в областях прозрачности интенсивность зеленого цвета выше.

Значительная избыточность данных подтверждается тем, что, с допустимой потерей 0,1 %, для работы каждой нейронной сети оказалось достаточно использовать всего 21 нейрон входного слоя вместо 96 нейронов. Следовательно, избыточность гистограмм составила 78 %. Семь нейронных сетей состоят из 21 входа, двух внутренних слоев и выходного слоя. Достаточный размер нейронной сети (5,5,3) был определен на основе данных обучения и верификации.

Обобщающая нейронная сеть размером (3.3) имеет два слоя.

В результате классификации вероятность ошибочной классификации для всех сортов кристаллов не превысила 0.02 %.

Заключение

Предложен метод классификации кристаллов по цвету и прозрачности для роботизированной системы сортировки продукции горной промышленности. Алгоритм позволяет классифицировать кристаллы алмаза с точностью 99.98 %, опираясь на их цветность и прозрачность.

Предложенный алгоритм является частью комплексного алгоритма, включающего классификацию кристаллов по цвету, прозрачности и форме.

Дальнейшее развитие алгоритмического обеспечения роботизированной системы сортировки кристаллов связано с анализом формы кристаллов, для этой цели могут быть использованы семиинварианты изображений. Совокупность классификаций по цвету, прозрачности и форме кристаллов позволяет однозначно определить сорт кристалла для дальнейшего распределения на предприятии.

Эта исследовательская работа была поддержана Проектом академического совершенства 5–100, предложенным Санкт-Петербургским политехническим университетом Петра Великого.

Список литературы

1. Горбунова Е.В., Коротаев В.В., Чертов А.Н. Возможности сортировки алмазного сырья оптико-электронными методами. Научно-технический вестник Технический вестник информационных технологий, механики и оптики. 2012. Т. 12. № 4. С. 13–18.

2. Завьялова М.А. Обидин. Ю.В. Быстродействующий колориметрический метод для автоматической классификации алмазов по цвету. Вестник СГГА. 2010. Вып. 2 (13). С. 101–106.

3. Чертов А.Н. Об особенностях сепарирования алмазов в цветовом пространстве RGB. Известия высших учебных заведений. Приборостроение. Т. 51. № 9. Санкт-Петербург, 2008.

4. Викторов М.А. Современные классификации алмазов: сравнительная характеристика. Вестн. Моск. Ун-та. Сер. 4. Геология. 2011. Т. 5. № 5.

5. Rafael C. Gonzalez, Richard E. Woods, Digital Image Processing, 4th Edition University of Tennessee, 2018. 1192 p.

6. Gupta Saurabh, Girshick Ross, Arbeláez Pablo, Malik Jitendra, Learning Rich Features from RGB-D Images for Object Detection and Segmentation. arXiv:1407.5736v1, 2014. P. 1–16.

7. Haykin, Simon. Neural Networks and Learning Machines, 3rd Edition, Prentice Hall, 2009. 889 p

8. Militsyn A., Malykhina G. Application of Dynamic Neural Network to Seach for Objects in Images. Industrial Engineering, Applications and Manufacturing (ICI-EAM). 2016, 2-nd International Conference IEEE Xplore: 27 April 2017, DOI: 10.1109/ICIEAM.2016.7911625.

9. Malykhina G., Guseva A. Application of Siamese neural networks for thq type of emergency determination. ACM-International Conference Proceeding Series. P. 1–5. 2019 doi.org/10.1145/3373722.3373775.

10. Gostev I.M., Sevastianov L.A. Influence of Noise on the DTW Metric Value in Object Shape Recognition. RUDN Journal of MIPh. 2018. Vol. 26 № 4. P. 331–342.

Секция 5

Нейронные сети и когнитивные науки

С.И. ФОКИН
Научно-практический центр
«Психосоматическая нормализация», Санкт-Петербург
fokin_s@mail.ru

МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ПЕРВИЧНОГО НЕЙРОНА РЕЦЕПТОРА

Для определения зависимости силы ощущения от интенсивности стимула необходимо учитывать каждый этап трансдукции стимула. Представленная математическая модель описывает зависимость частоты потенциалов действия первичного нейрона рецептора от его физиологических свойств и интенсивности стимула. Тестовые расчёты удовлетворительно объясняют экспериментальные психофизические феномены, необъяснимые с точки зрения классической психофизики: «эффект насыщения» и различия, определяемые типом нервной системы.

Ключевые слова: *рецептор, нейрон, частота потенциалов действия, ионные каналы, стимул, ощущение, психофизический эксперимент.*

Введение

Все мы знаем из обыденного опыта, что чем интенсивней стимул – тем сильнее наше ощущение, им вызываемое. Общеизвестно, однако, что функция «стимул-ощущение» не линейна для любых модальностей. Изучением этой зависимости с XIX века занимается специальная наука – психофизика, но исследователям до сих пор не удалось обнаружить универсальную формулу «основного психофизического закона». Ни логарифмическая зависимость Фехнера [1], ни степенная функция Стивенса [2], не могут объяснить специфическую динамику многих экспериментальных данных. И это закономерно, ибо попытки заменить многоступенчатый сенсорный механизм простой моделью «чёрного ящика» изначально уязвимы: должны быть отдельно рассмотрены все этапы трансдукции стимула в сенсорной системе.

В конце XX века нейрофизиологи сошлись во мнении, что одной из форм кодирования интенсивности стимула является частота потенциалов действия (ПД). В русле этой парадигмы и на основании универсальной

модели Ходжкина-Хаксли [3], применённой к условиям психофизического эксперимента, автором была разработана математическая модель первичного нейрона рецептора. Под первичным нейроном рецептора в настоящей работе подразумевается то место на сенсорном пути трансдукции стимула, где впервые появляются потенциалы действия (ПД) – универсальные компоненты языка нервных систем любых живых существ.

Предлагаемая авторская математическая модель первичного нейрона рецептора подходит для количественного описания формирования в нём потенциалов действия как при непосредственном воздействии на свободные нервные окончания (например, тактильная или болевая чувствительность), так и при опосредованном его стимулировании, например, количеством выделяемого в синаптическую щель нейромедиатора (слуховая или зрительная системы). Как при непосредственном, так и при опосредованном воздействии на афферентный нейрон рецептора частота возникающих в нём ПД пропорциональна интенсивности стимула. Однако, как показывают экспериментальные данные [4], пропорциональность эта отнюдь не прямая, но удовлетворительно описывается степенной функцией вида (в [4] формула записана словами):

$$\nu = C(S - S_0)^n, \tag{1}$$

где ν – частота потенциалов действия, Гц; C – постоянная, учитывающая единицы измерения стимула S; S, S_0 – текущее и пороговое значения стимула данной модальности; n – показатель степени, может быть меньше, равен или больше единицы для рецепторов разных модальностей [4].

Выражение (1) совпадает с одной из форм записи так называемого степенного «закона Стивенса» [2], связывающего интенсивность стимула S и силу ощущения R (вместо частоты ν в формуле Стивенса стоит сила ощущения R). Стивенс предложил аппроксимировать психофизические зависимости R(S) степенной функцией в середине 20-го века взамен ранее повсеместно использовавшихся с 1860 года аппроксимаций по так называемому логарифмическому «закону Фехнера» [1]:

$$R = C(\lg S - \lg S_0). \tag{2}$$

Обозначения в формуле (2) те же, что и в формуле (1).

Однако, «до настоящего времени основной психофизический закон ни в форме логарифмической зависимости Г. Фехнера, ни в форме степенной зависимости С. Стивенса не получил всеобщего и окончательного признания. Экспериментальные данные, полученные разными исследователями, не оказались однозначными: одни говорят в пользу логарифмиче-

ского закона, другие – в пользу степенного» [5]. К цитате можно добавить, что вряд ли без знания физических механизмов преобразования стимула в ощущение, с помощью только лишь аппроксимации экспериментальных данных простой формулой, вообще можно «угадать» основной психофизический закон, связывающий интенсивность стимула с силой ощущения. Хотя такие попытки и предпринимались после С. Стивенса: например, Ю.М. Забродин предложил объединить «законы» Фехнера и Стивенса одной формулой в дифференциальном виде [6].

Сопоставляя динамики кривых «интенсивность стимула – сила ощущения», полученные в психофизических экспериментах на макроуровне организмов [5], с динамиками графиков «интенсивность стимула – частота импульсов ПД», полученных в последнее время на нейронном уровне рецепторов [4], можно сделать вывод об их эквидистантности. Следовательно, этап прямого или опосредованного преобразования стимула в потенциалы действия в первичных нейронах рецептора является определяющим на всём пути его трансдукции в ощущение, поэтому мы и начали свои исследования именно с него.

Постановка задачи

Результаты психофизических экспериментов однозначно указывают на то, что в формуле основного психофизического закона должны учитываться не только значения стимула, но и особенности нервной системы испытуемого [5, 7]. На этапе трансдукции стимула в первичном нейроне рецептора индивидуальные особенности преобразования будут определяться физиологическими свойствами нейрона. Учесть эти свойства позволяет модель нобелевских лауреатов А. Ходжкина и А. Хаксли, описывающая универсальный механизм формирования потенциалов действия в нервной ткани [3]. Используем указанный механизм для рассмотрения частного случая функционирования первичного нейрона рецептора в условиях психофизического эксперимента и построения соответствующей математической модели.

Тестирование нашей модели проведём для физиологических параметров первичного нейрона рецептора, близких к реальным (обозначения см. в след. разделе). Исходя из характерных размеров нейронов (~ 20 мкм) и кабельных свойств их мембран [10], для тестовых расчётов были вычислены характерные сопротивления натриевых и калиевых ионных каналов [8]: $R_{пок.Na} = 1{,}196 \cdot 10^9$ Ом; $R_{пок.K} = 8{,}547 \cdot 10^7$ Ом; $R_{(пок+реп)K} = 6 \cdot 10^6$ Ом, $R_{пикNa} = 4{,}274 \cdot 10^6$ Ом. Отношение сопротивлений при этом, разумеется, будет обратным отношению проводимостей соответствующих каналов:

$R_{покК}/R_{покNa} = 1/14$. Сопротивления получились такими «неровными» потому что они взаимосвязаны друг с другом и с площадью поверхности клетки, т.е. её мембраны. Электроёмкость мембраны была также взята характерной для нервной ткани [10]: $C_m \approx 62{,}68$ пФ (подробности см. в [8]).

Для тестовых расчётов были взяты следующие значения характерных мембранных потенциалов и ЭДС: $U_{пок} = -80$mv; $U_{зкк} = -65$mv; $U_{пор} = -45$mv; $U_{пик} = 35$mv; $E_K = -90$ мВ; $E_{Na} = 60$ мВ. Знаки потенциалов и ЭДС здесь указаны исходя из общепринятого представления о том, что в состоянии покоя внутриклеточная среда является электоотрицательной по отношению к внеклеточной. Однако, формулы (3)–(6) были получены в соответствии с правилами знаков электротехники ([11], с. 252) на основании электрической схемы, аналогичной схеме Ходжкина-Хаксли ([3], р. 501) при условии, что ветвь «утечки» учтена в соответствующих ветвях натриевого и калиевого токов (рис. 1).

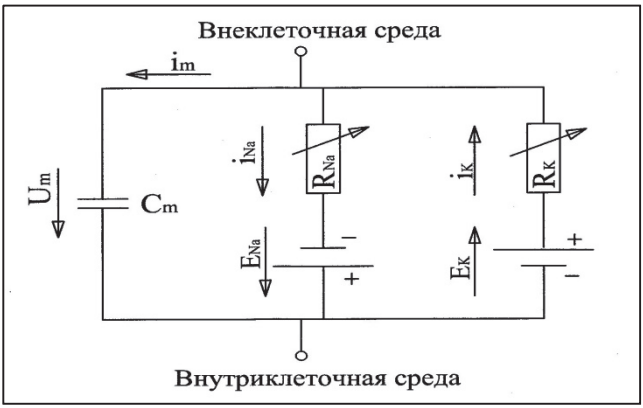

Рис. 1. Электрическая схема мембраны первичного нейрона рецептора

Поэтому в формулы (3)–(6) значения характерных потенциалов и ЭДС должны подставляться со следующими знаками [8]: $U_{пок} = 80$мВ; $U_{зкк} = 65$мВ; $U_{пок} = 45$мВ; $U_{пик} = -35$ мВ; $E_K = 90$ мВ; $E_{Na} = 60$ мВ.

Зависимость сопротивления стимулуправляемых натриевых каналов мембраны первичного нейрона рецептора от величины стимула также предполагается известной, её определение благодаря достижениям современной экспериментальной нейрофизиологии не является проблемой [4, 12, 13].

Результаты и обсуждение

В работах автора [8, 9] общая модель Ходжкина-Хаксли была применена к частному случаю психофизического эксперимента, в котором значения интенсивности стимула, как правило, постоянны и имеют небольшую продолжительность (например, время звучания сигнала в акустических экспериментах порядка одной секунды [5]). Следовательно, при построении математической модели первичного нейрона рецептора для условий психофизического эксперимента можно не учитывать ни процессы адаптации, ни изменение интенсивности стимула во времени. Такие условия позволили значительно упростить дифференциальные уравнения модели Ходжкина-Хаксли и получить их аналитическое решение для частоты импульсов ПД (вывод нижеприведённых формул дан в [8]):

$$\nu_{\text{пд}} = \frac{1}{(\Delta t_{\text{деп}} + \Delta t_{\text{пик}} + \Delta t_{\text{реп}})}, \quad (3)$$

$$\Delta t_{\text{деп}} = \frac{-C_m \cdot R_{\text{пок.К}}}{(X_{\text{ст.}}+1)} \cdot \ln\left(\frac{X_{\text{ст.}}\cdot(U_{\text{пор.}}+E_{Na})+U_{\text{пор.}}-E_K}{X_{\text{ст.}}\cdot(U_{\text{зкк.}}+E_{Na})+U_{\text{зкк.}}-E_K}\right), \quad (4)$$

$$\Delta t_{\text{пик}} = \frac{-C_m \cdot R_{\text{пок.К}}}{(X_{(\text{ст+пик})}+1)} \cdot \ln\left(\frac{X_{(\text{ст+пик})}\cdot(U_{\text{пик}}+E_{Na})+U_{\text{пик}}-E_K}{X_{(\text{ст+пик})}\cdot(U_{\text{пор.}}+E_{Na})+U_{\text{пор.}}-E_K}\right), \quad (5)$$

$$\Delta t_{\text{реп}} = \frac{-C_m \cdot R_{(\text{пок.+реп})K}}{(X_{\text{реп.}}+1)} \cdot \ln\left(\frac{X_{\text{реп.}}\cdot(U_{\text{зкк}}+E_{Na})+U_{\text{зкк}}-E_K}{X_{\text{реп.}}\cdot(U_{\text{пик.}}+E_{Na})+U_{\text{пик.}}-E_K}\right), \quad (6)$$

$X_{\text{ст.}} = R_{\text{пок.К}}/R_{(\text{пок.+ст.})Na}(S)$, постоянен в течение $\Delta t_{\text{деп}}$;
$X_{(\text{ст.+пик.})} = X_{\text{ст.}} + X_{\text{пик.}} = X_{\text{ст.}} + R_{\text{пок.К}}/R_{\text{пик.Na}}$, постоянен в течение $\Delta t_{\text{пик}}$;
$X_{\text{реп.}} = X_{\text{ст.}} \cdot R_{(\text{пок.+реп.})К}/R_{\text{покК}}$, постоянен в течение $\Delta t_{\text{реп}}$;

где C_m – электрическая ёмкость мембраны рецептора, Ф; R_K – суммарное электросопротивление калиевых ионных каналов рецептора в течение текущего промежутка времени Δt_i, Ом; E_{Na}, E_K – натриевая и калиевая ЭДС рецептора, соответствующие равновесным натриевому и калиевому потенциалам, мВ;

X$_{\text{ст}}$ – ***переведённый стимул*** или ***калий-натриевый параметр мембраны*** (новые термины и величина), равный отношению суммарного электросопротивления одиночных калиевых ионных каналов мембраны нейрона к суммарному электросопротивлению одиночных натриевых каналов: $X_{cm}(t) = R_K(t)/R_{Na}(t)$; $X_{\text{ст}}(t)$ зависит от интенсивности стимула S, передаточной функции нейрона, его физиологических свойств и времени. Название «*переведённый стимул*» или «*переведённое воздействие*» для X

выбрано в связи с тем, что в процессе трансдукции физическая интенсивность любого стимула «переводится» на универсальный язык нервной системы – в потенциалы действия (ПД) первичных нейронов рецепторов.

Понятно, что в психофизическом эксперименте $X_i(t) = \text{const}$ будет сохраняться периодически в течение трёх характерных промежутков времени:

1) $\Delta t_{пп}$ – когда мембранный потенциал изменяется с $U_{зкк}$ до $U_{пор.}$; X при этом определяется постоянными сопротивлениями натриевых и калиевых каналов утечки (покоя) плюс суммарным сопротивлением стимулзависимых натриевых каналов, открывшихся под действием стимула $S = \text{const}$;

2) $\Delta t_{пик}$ – когда мембранный потенциал изменяется с $U_{пор.}$ до $U_{пик.}$; $X_{(ст.+пик)}$ при этом определяется перечисленными в п. 1 сопротивлениями плюс суммарное сопротивление открывшихся при $U_{пор.}$ потенциалуправляемых натриевых каналов;

3) $\Delta t_{пик}$ – когда мембранный потенциал изменяется с $U_{пик}$ до $U_{зкк}$; $X_{реп.}$ при этом определяется перечисленными в п. 1 сопротивлениями плюс суммарное сопротивление открывшихся при $U_{пик}$ потенциалуправляемых калиевых каналов (п/у натриевые каналы при этом инактивировались);

R с индексами – суммарные сопротивления соответствующих ионных каналов мембраны рецептора для описанных в п. 1–3 промежутков времени.

Здесь частота ПД вычисляется без учёта первого и последнего импульсов и поэтому не зависит от потенциала покоя, $U_{пок}$, а зависит только от порогового значения мембранного потенциала, $U_{пор}$, и потенциала закрытия калиевых каналов, $U_{зкк}$. Как уже обсуждалось в [8], в связи с тем, что в реальности не все стимулзависимые натриевые и потенциалзависимые натриевые и калиевые каналы открываются/закрываются одновременно, то и $U_{пор}$, и $U_{зкк}$ являются некими условными значениями мембранного потенциала, при которых наблюдается: для $U_{пор}$ - перегиб на кривой $U_m(t)$ в деполяризационной области; для $U_{зкк}$ – падение мембранного потенциала (реполяризация) сменяется его ростом (деполяризация). В реальности же «растянутость» во времени и неоднородность по поверхности мембраны открытия/закрытия стимулзависимых и потенциалзависимых ионных каналов приведёт к некоторой зависимости $U_{пор}$ и $U_{зкк}$ от интенсивности стимула, но такие тонкие настройки мы пока учитывать не будем, ограничимся тем, что и $U_{пор}$, и $U_{зкк}$ в вышеприведённых формулах будем считать постоянными для данного периферического нейрона рецептора.

Подставив наши тестовые данные в формулы (3)–(6), получим:

$$\Delta t_{\text{реп}} = -\frac{5.357}{(X_{\text{ст}}+1)} \ln\left(\frac{105X_{\text{ст}}-45}{125X_{\text{ст}}-25}\right), \quad (4^*)$$

$$\Delta t_{\text{пик}} = -\frac{5.357}{(X_{(\text{ст+пик})}+1)} \ln\left(\frac{25X_{(s+p)}-125}{105X_{(s+p)}-45}\right), \quad (5^*)$$

$$\Delta t_{\text{реп}} = -\frac{0.376}{(X_{\text{реп}}+1)} \ln\left(\frac{125X_{\text{реп}}-25}{25X_{\text{реп}}-125}\right). \quad (6^*)$$

Промежутки времени $\Delta t_{\text{деп}}$, $\Delta t_{\text{пик}}$, $\Delta t_{\text{реп}}$ в формулах (4*)–(6*) выражены уже в миллисекундах.

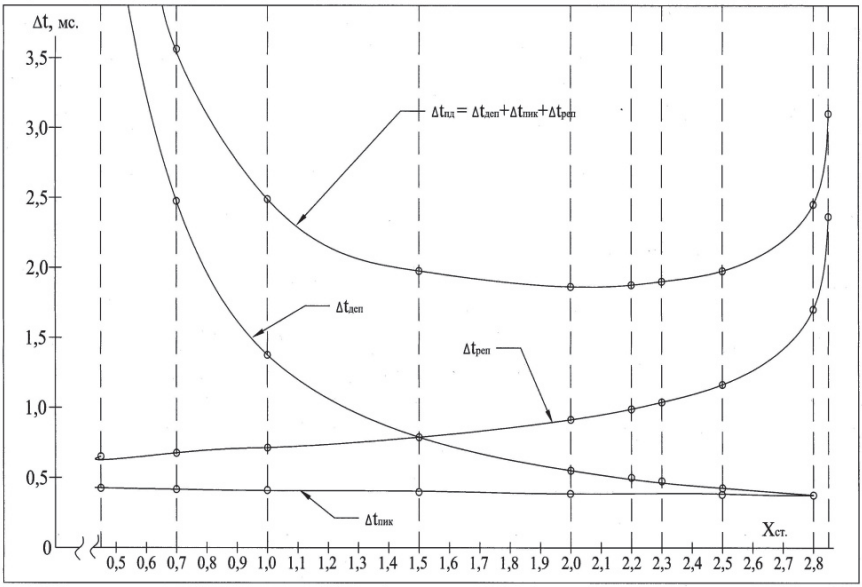

Рис. 2. Продолжительность импульса ПД, $\Delta t_{\text{ПД}}$,
и его составляющих: деполяризационной – $\Delta t_{\text{деп}}$, пиковой – $\Delta t_{\text{пик}}$
и реполяризационной - $\Delta t_{\text{реп}}$, в зависимости от величины
переведённого стимула $X_{\text{ст}}$

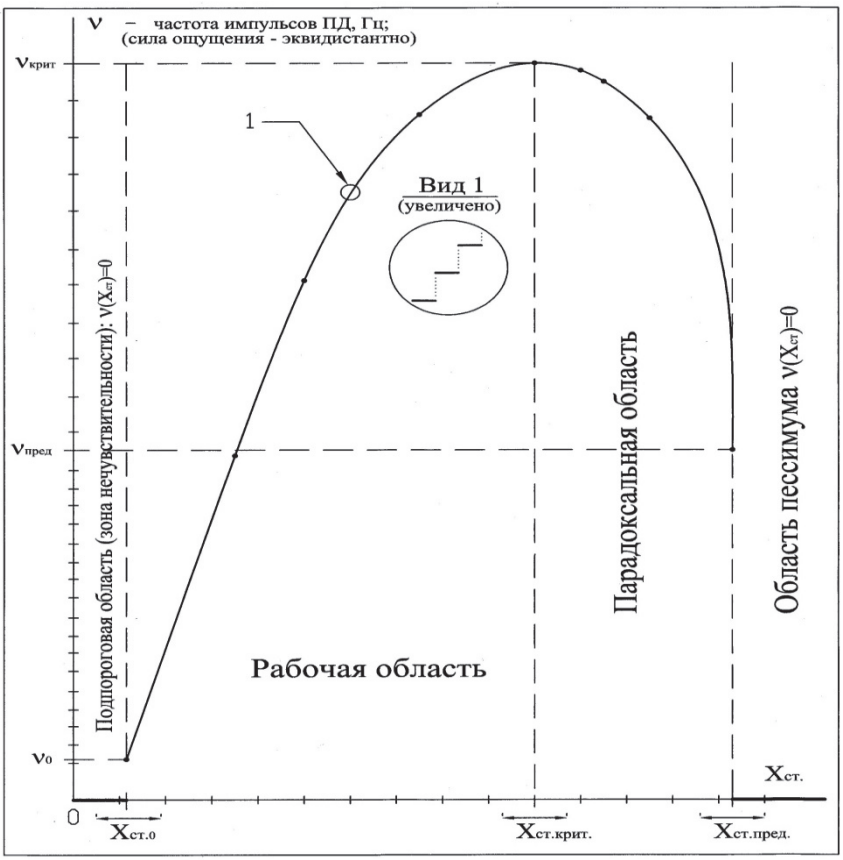

Рис. 3. Расчётный график зависимости частоты потенциалов действия, $\nu_{ПД}$, от интенсивности переведённого стимула, $X_{ст}$, в условиях психофизического эксперимента.

Множители перед логарифмами во всех трёх формулах монотонно убывают с ростом $X_{ст}$, а значения логарифмов ведут себя разнонаправлено. Логарифм на первом промежутке времени (формула (4*)) гиперболически убывает с ростом $X_{ст}$; на втором (формула (5*)) – убывает очень медленно и практически линейно; на третьем (формула (6*)) – круто возрастает ближе к максимальному значению $X_{ст}$. Кроме того, логарифм в формулах (4), (4*) определяет нижнюю пороговую величину мембранного потенциала: при значениях переведённого стимула $X_{ст} < 0.4286 \approx X_{ст}$ ПД

не будут сформированы, так как мембранный потенциал никогда не достигнет своего порогового значения – в нашем тестовом примере это $U_{\text{пор}} = -45\text{mV}$, а значение выражения под знаком логарифма при этом выйдет за область определения - станет отрицательным, что не имеет смысла. В формулах (6), (6*) логарифм определяет верхнюю границу переведённого стимула (в нашем тестовом примере это $X_{\text{ст.пр.}} \approx 2.85$, а $X_{\text{реп.пр.}} \approx 0.2$, соответственно), выше которой также прекратится формирование импульсов ПД, но уже по другой причине: мембранный потенциал никогда не достигнет потенциала закрытия потенциалзависимых калиевых каналов при реполяризации, т.к. значение под знаком логарифма при этом также выйдет за область определения.

Динамика зависимости всех трёх промежутков времени $\Delta t_{\text{деп}}, \Delta t_{\text{пик}}, \Delta t_{\text{реп}}$, составляющих время потенциала действия $\Delta t_{\text{пд}}$, от переведённого стимула $X_{\text{ст}}$ показана на рис. 2.

Так как частота импульсов ПД, $\nu_{\text{пд}}$, обратно пропорциональна их периодам $\Delta t_{\text{пд}}$ (см. формулу (3)), то зависимость $\nu_{\text{пд}}(X_{\text{ст}}(S))$ будет иметь соответствующий максимум. Характерная кривая $\nu_{\text{пд}}(X_{\text{ст}}(S))$, построенная по данным тестового расчёта, представлена на рис. 3.

При обратно пропорциональной зависимости сопротивления стимулуправляемых натриевых каналов от величины стимула, что характерно, например, для механорецепторов [13], кривая $\nu_{\text{пд}}(\text{S})$ будет эквидистантна $\nu_{\text{пд}}(\text{X}_{\text{ст}})$, приведённой на рис. 3 (см. формулы для $\text{X}_{\text{ст}}$).

Выводы

1. Преобразование стимула в потенциалы действия в первичном нейроне рецептора нелинейно и может иметь максимум (рис. 3).
2. Обнаруженный в психофизических экспериментах «эффект насыщения» [5] может формироваться уже на уровне рецепторов.
3. Зафиксированная в психофизических экспериментах [5, 7] разная динамика зависимости «сила ощущения – интенсивность стимула» у лиц со слабой и сильной нервной системой (по Павлову И.П.) определяется различием физиологических параметров первичных нейронов рецепторов испытуемых [9].

Список литературы

1. Fechner G.T. Elemente der Psychophysic. Leipzig. 1860.
2. Stevens S.S. On the psychophysical law // Psychol. Rev. 1957. Vol. 64. № 3.

3. Hodgkin A.L. and Huxley A.F. (1952). A quantitative description of membrane current and its application to conduction and excitation in nerve // J. Physiol. 117. P. 500–544.

4. Willis W.D., Jr. Физиология нервной системы // Уч. «Фундаментальная и клиническая физиология» под ред. Камкина А.Г. и Каменского А.А. М.: Издательский центр «Академия», 2004. С. 347–512.

5. Ратанова Т.А. Психофизическое шкалирование. Сила ощущений, сила нервной системы и чувствительность: Монография / Т.А. Ратанова. 2-е изд., испр. и доп. М.: Изд. МПСИ, 2008. 320 с.

6. Забродин Ю.М., Лебедев А.Н. Психофизиология и психофизика. М.: Наука, 1977. 288 с.

7. Чуприкова Н.И. Время реакций человека: Физиологические механизмы, вербально-смысловая регуляция, связь с интеллектом и свойствами нервной системы. М.: Издательский дом ЯСК, 2019. 432 с.

8. Фокин С.И. Электрохимический механизм реагирования на воздействие живой клеткой и его математическая модель // Деп. в ФГБУ «РГБ» 06.02.2017, № 1178247. 50 с.

9. Фокин С.И. Заложенная на уровне рецептора нелинейность преобразования интенсивности стимула в силу ощущения и его математическое выражение // Вестник психофизиологии. 2019. 3. С. 10–23.

10. Катц Б. Нерв мышца и синапс. / Пер. с англ. Ю.И. Лашкевича. Под ред. и с предисловием д.м.н. В.С. Гурфинкеля. М.: Мир, 1968. 220 с.

11. Детлаф А.А., Яворский Б.М. Курс физики. Уч. 6-е изд., стер. М.: ИЦ «Академия». 2007. 720 с.

12. Suslak T.J., Armstrong J.D. & Jarman A.P. A general mathematical model of transduction events in mechano-sensory stretch receptors, J. Network: Computation in Neural Systems. 2011. Vol. 22. P. 42–133.

13. Ikeda K., Suzuki N. and J. M. Bekkers. Sodium and potassium conductances in principal neurons of the mouse piriform cortex: a quantitative description. J. Physiol. 2018. 596.22. P. 5397–5414.

D.V. TIKHOMIROVA, A.V. SAMSONOVICH
National Research Nuclear University MEPhI, Moscow, Russian Federation
dvsulim@mail.ru

EMPATHY FACILITATES HUMAN RECOGNITION OF ARTIFICIAL INTELLIGENCE AGENTS IN A SOCIAL-EMOTIONAL VIDEOGAME

In this work, we continued our study of the human emotional sphere [1] based on the platform we created earlier – the Teleport video game [2], which allows anonymous social interaction of actors of different nature - both people and automata. It was suggested earlier that the level of empathy is interconnected with the ability to identify artificial intelligence agents in a socio-emotional videogame. The present study was undertaken to verify this idea. The resulting correlation constellation presented in this paper illustrates the relationship between the number of errors associated with misidentification of a person as a bot and a bot as a person, on the one hand, and the level of empathy and empathy channels on the other hand. The outcome supports the hypothesis. In addition, a comparison was made between a person and a bot on 6 personality factors.

Keywords: *human-computer interface, affective computing, artificial emotional intelligence, virtual characters, intelligent agents, semantic correlates, Boyko test, Mehrabian test, empathy.*

1. Introduction

In this paper, we conduct a research on the emotional sphere of a person based on a previously created platform - the video game «Teleport» [2], which provides anonymous social interaction of actors of various natures – both human and automata – with their indistinguishability that helps the subject to behave naturally. At the same time, automata are virtual agents with elements of emotional intelligence [3–7].

The emotional sphere is a multicomponent, complex, structural formation that is closely connected with other spheres of personality – behavior, thinking, and the value-semantic sphere [8–12]. And emotional intelligence is the combination of a person's skills and abilities to recognize emotions, understand the intentions, motivations, and desires of others and their own ones, as well as the ability to manage their own emotions and those of others in order to solve practical problems [13].

Five-component model of emotional intelligence D. Goleman [14] includes the following components: emotional self-awareness, emotional self-regulation, internal motivation, social skills, empathy.

Emotional self-awareness is associated with the ability to accept and understand their own emotional processes and states, relate them to the needs and affection of their emotional expression on others. This component is also associated with such personal traits as self-confidence, realistic self-esteem, and the ability to self-irony. With a sufficiently high level of emotional self-awareness, a person is able to adequately assess and describe their experiences.

Emotional self-regulation refers to the ability to control their emotional expressions and reflect on the consequences of their expressions. It also involves a readiness to change, the ability to experience conflicting, complex feelings and ability to maintain self-control and psychological integrity at the same time.

Intrinsic motivation refers to an intrinsic motivation for an activity that may sometimes go beyond external motivating factors, such as money and status. An internally motivated person has the ability to feel and understand the meaning of their activities and relationships, to experience pleasure from what they like to do, willingness to get new experiences, the ability to experience a state of «flow», being fully immersed in any kind of work, to persevere in achieving goals. Such a person believes in the possibility of achieving goals, even in spite of temporary failures, he has optimism and commitment to the chosen activity.

Empathy is related to the ability to understand the emotions and feelings of other people and build relationships with them, taking into account the characteristics of their emotional response and mental state. A person with developed empathy is able to care for other people and support them.

Social skills are related to the ability to form and maintain relationships, find common points of contact with other people, influence others, show leadership skills, insistence and determination.

From the point of view of N. Hall emotional intelligence is a set of certain personal characteristics. Methods of self-assessment of emotional intelligence created by N. Hall (the Emotional Intelligence Self-Evaluation) [15] include five scales that correspond to the following components of emotional intelligence: emotional awareness, managing your emotions, self-motivation, empathy, and recognizing the emotions of others.

Emotional awareness is the awareness and understanding of own emotions. Managing your emotions is understood as an ability to tame temper easily, flexibility, and the ability to manage your emotions. Self-motivation consists in managing your behavior and actions by knowing your emotions. Empathy is associated with understanding the emotions of another person by facial expres-

sions, gestures, tone of the speech, posture, as well as the ability to empathize with them. Recognition of other people's emotions consists in the ability to influence the emotional state of other people based on understanding their emotional reactions and mood.

As we can see, empathy is one of the most important components of emotional intelligence. And in this paper, we hypothesized that it is related to the ability to recognize artificial intelligence agents in a social-emotional video game.

In this paper, we used a previously created platform – the video game «Teleport»[2] that provides anonymous social interaction of actors of various natures – both human and automata – with their indistinguishability that helps the subject to behave naturally. In addition, 6 factors were selected from Cattell's multi-factor personality questionnaire and respondents were asked to evaluate virtual characters based on these factors.

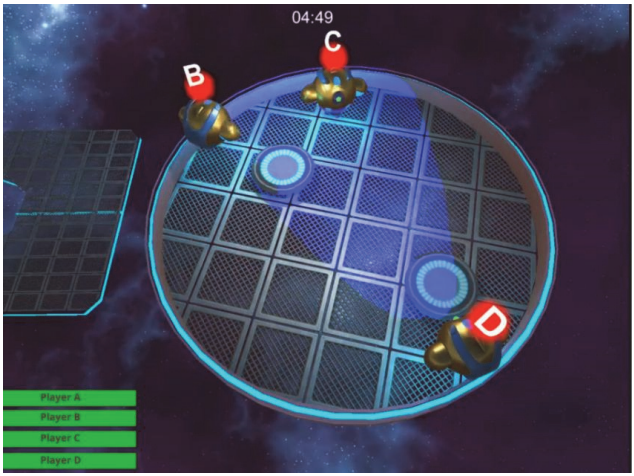

Fig. 1 Screenshot of a session of the videogame «Teleport»

A virtual installation [2] consists of a virtual scene where three avatars are highlighted. It includes the rescue zone «tower» (the left component in fig. 1) and the action zone «platform» (the right component in fig. 1). Each avatar can be controlled by a human player or a virtual actor. The platform has two terminals (circles on the platform, Fig. 1). Actors can be moved from the platform to the tower using teleportation, as described below. A game session consists of a

sequence of logically identical rounds. Each round has a fixed limited duration and can end earlier if certain conditions are met, as described below. Once completed, a new round starts automatically until the 10-minute session time limit expires. Initially, all actors are placed on the platform in random places.

Each actor located on the platform has the following available behavior patterns: greet, ask for help or thank another actor, hit another actor, activate or deactivate the opposite teleport, and perform their own teleportation accessible only from the active teleport. The actor can move from the platform to the tower. Being on the tower, the actor can perform the following two actions, each of which leads to the end of the round: save the selected actor who is on the platform, or escape alone. The round also automatically ends when two actors reach the tower or the 2-minute time limit expires. At the end, all the actors on the tower win and all the rest lose. The virtual environment also includes a clock, a score counter, and checkboxes that allow participants to indicate who their partner is currently.

2. Materials and methods

This study involves 30 students of National Research Nuclear University «MEPhI» aged from 20 to 22 years.

We carried out methodologies of research of the emotional sphere – a test for identifying empathic abilities of Viktor Boyko [16] and a questionnaire for emotional empathy of Mehrabian [17].

The empathic abilities test allowed us to determine the degree of expression of empathic abilities and the significance of each of the six parameters in the structure of empathy: rational channel, emotional channel, intuitive channel, attitudes, penetrating ability, identification. The rational channel of empathy characterizes the focus of attention, perception and thinking of the empathizer on the nature of any other person – on his states, problems, behavior. This is a spontaneous interest in another, person opening the way to emotional and intuitive reflection of the partner. With the help of the emotional channel of empathy, we can record the ability of the empathizer to enter into an emotional resonance with others, that is to empathize and to participate. Emotional responsiveness in this case becomes a means of "entering" the partner's energy field. Participation and empathy serve as a link, a guide from the empathizer to the empathized and vice versa. The intuitive channel of empathy indicates the ability of the respondent to see the behavior of partners, to act in conditions of a lack of initial information about them, based on the experience stored in the subconscious. At the level of intuition, various information about partners gets fixed and generalized. Intuition is less dependent on evaluation stereotypes than

a reasonable perception of partners. Intensions that help or prevent empathy, respectively, facilitate or hinder the operation of all empathic channels. The effectiveness of empathy is reduced if a person tries to avoid personal contacts, considers it inappropriate to be curious about another person, and persuades himself to calmly treat the experiences and problems of others. Various channels of empathy are more active and reliable if there are no obstacles from the person's attitudes. Penetrating ability in empathy is regarded as an important communicative property of a person, which allows creating an atmosphere of openness and trust. Each of us contributes to or hinders information and energy exchange by our behavior and attitude to our partners. Relaxation of the partner promotes empathy, and the atmosphere of tension, unnatural behaviour, suspiciousness prevents disclosure and empathic comprehension. Identification is another essential condition for successful empathy. This is the ability to understand the other based on empathy, putting yourself in the place of a partner. At a fundamental level of identification is the ease, mobility and flexibility of emotions, the ability to imitate.

The Emotional Empathic Tendency Scale (EETS) questionnaire [17] is designed to determine the level of empathic tendencies, the ability to empathy as a personal trait.

After passing the tests, the experiment participants viewed 8 clips of the video game «Teleport» in random order and determined whether the actors were bots or people. We also evaluated virtual characters based on 6 personal factors. In two clips all three players were men, in another two clips they were bots, in another two – two players were bots and one was human, in the rest two clips – two players were human and one was bot.

After that we performed a correlation analysis in order to find the relationship between the level of empathy and the ability to recognize bots in the socio-emotional video game «Teleport», then we conducted the evaluation of virtual characters by 6 personality factors [18], followed by a comparison of the bot and the person according to these factors.

3. Results and Analysis

With a help of the correlation analysis, were revealed the relationships presented in the correlation pleiad (Fig. 2).

The number of bots mistakenly identified as human by the participants in the experiment has a negative correlation with the intuitive channel ($r = –0.515$, $p < 0.05$) and the penetrating ability of empathy according to Boyko ($r = –0.516$, $p < 0.05$). The number of people who mistakenly identified as bots by the participants in the experiment has a negative correlation with the level of

empathy according to Mehrabian ($r = –0.581$, $p < 0.05$) and the integral indicator of empathy obtained based on the level of empathy according to Mehrabian and the level of empathy according to Boyko ($r = –0.543$, $p < 0.05$).

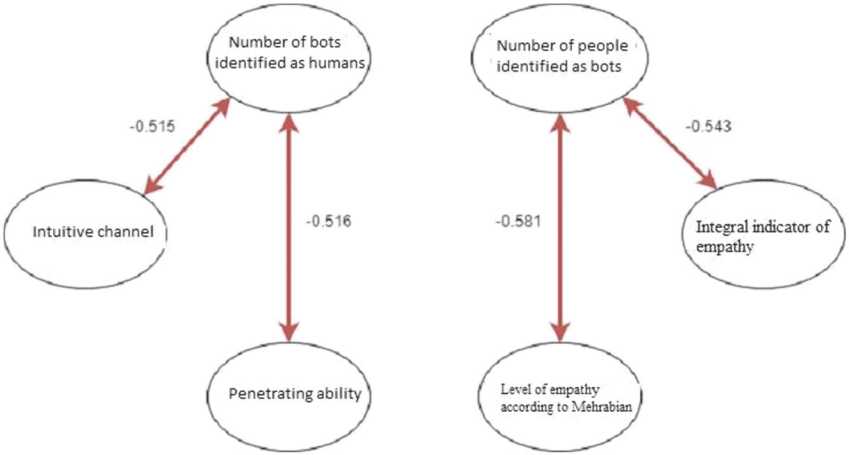

Fig. 2. Correlation pleiad of indicators of Boyko and Mehrabian empathy tests and player ratings (human/bot) of the Teleport video game ($p < 0.05$)

Table 1

Evaluation of virtual characters by 6 personal factors

	Bot		Person			
Factor	Mean	St. Dev.	Mean	St. Dev.	t-criteria	p
Courage	4.9	0.7	5.2	0.8	-1.023	0.317
Sociability	4.9	0.5	5.0	0.6	-0.214	0.833
Suspiciousness	4.4	0.5	4.4	0.4	-0.210	0.836
Dominance	4.9	0.7	5.1	0.9	-0.560	0.581
Emotional stability	5.0	0.6	5.4	0.5	-1.750	0.094
Sensitivity	4.6	0.4	4.9	0.4	-2.320	0.030

The results of evaluating virtual characters by 6 personality factors are presented in Table 1.

The student's test showed the statistical significance of differences between the values of the human and bot sensitivity factors ($p <= 0.05$). The difference is not statistically significant on other factors.

4. Discussion and conclusions

In this paper, we continued our research of the human emotional sphere [1] based on the previously created platform – the video game «Teleport» [2], which allows anonymous social interaction of actors of various natures – both humans and automata, and we suggested that the level of empathy is related to the ability to recognize artificial intelligence agents in a social-emotional video game. The resulting correlation pleiad illustrates this relationship.

When the role of the intuitive channel increases, and as you know, intuition does not depend on evaluation stereotypes, the number of errors associated with human recognition in the bot behaviour decreases. Similarly, the number of such errors decreases with an increase in the penetrating ability of empathy – a communicative ability of a person that allows you to win partner's favour. The number of errors associated with recognition a bot in a human behaviour decreases with an increase in the overall level of empathy.

These results indicate a high role of empathy in human recognition of artificial intelligence agents in a social-emotional video game.

Comparing the personal qualities of a person and a bot showed that their characters in a social and emotional video game are similar in such qualities as courage sociability, suspicion, dominance, and emotional stability. But the student's test showed the statistical significance of differences between the values of the human and bot sensitivity factors ($p <= 0.05$). The person is more sensitive-prone to reflection, thinking about their mistakes and ways to avoid them, more impressionable, prone to empathy, emotionally rich. Cattell defines this personality trait as «programmed emotional sensitivity», emphasizing in this way the prerogative of the genetic origin of this personality trait [18].

Acknowledgements

This research was funded by the Russian Science Foundation Grant No. 18-11-00336. The authors are grateful to all NRNU MEPhI students who participated in the study.

References

1. Tikhomirova D.V., Chubarov A.A, and Samsonovich A.V. Empirical and modeling study of emotional state dynamics in social videogame paradigms Cognitive Systems Research, 2019.

2. Azarnov D. A., Chubarov A. A., Samsonovich A.V. Virtual actor with social-emotional intelligence / / Proceedings Computer Science. 2018. Vol. 123. P. 76–85. DOI: 10.1016/j. procs.2018.01.013.

3. Breazeal, C. (2003). Emotion and sociable humanoid robots. International Journal of Human-Computer Studies, 59 (1–2): 119–155.

4. Chella, A., Lebiere, C.L., Noelle, D.C., and Samsonovich, A.V. (2011). On a roadmap to biologically inspired cognitive agents. Frontiers in Artificial Intelligence and Applications. Vol. 233. P. 453–460. Amsterdam: IOS Press. DOI: 10.3233/978-1-60750-959-2-453.

5. Laird, J.E., Lebiere, C. & Rosenbloom, P.S. (2017). A Standard Model of the Mind: Toward a Common Computational Framework across Artificial Intelligence, Cognitive Science, Neuroscience, and Robotics. AI Magazine, 38. 13–26.

6. Samsonovich A. V. Emotional biologically inspired cognitive architecture // Biologically Inspired Cognitive Architectures. 2013. Vol. 6. P. 109–125.

7. Samsonovich, A.V. (2018). Schema formalism for the common model of cognition. Biologically Inspired Cognitive Architectures, 26: 1–19.

8. Fominykh I. B. Emotions as an apparatus for assessing the behavior of intelligent systems. // Proceedings of the 10th national conference on artificial intelligence KII-2006. M.: Fizmatlit, 2006. Vol. 2.

9. Plutchik, R. (1982). A psychoevolutionary theory of emotions. Social Science Information, 21: 529–553.

10. Simonov P.V. Need-information theory of emotions // Questions of psychology. 1982. N 6. P. 44–56.

11. Gratch J., Marsella S. A domain-independent framework for modeling emotion // Cognitive Systems Research. 2004. Vol. 5. P. 269–306.

12. Ilyin E.P. Emotions and feelings. Ed.: St. Petersburg, 2007. 784 p.

13. Smith M.K. (2002). Howard Gardner and multiple intelligences. The Encyclopedia of Informal Education.

14. Goleman D. Working with emotional intelligence. Bantam, 1998.

15. Hall N. Emotional Intelligence Self-Evaluation // Institute of Health and Human Performance, Saddlebrook Resort, UK, 1995.

16. Boiko V.V. Energy of emotions in communication: a look at yourself and others. Moscow: Filin, 1996.

17. Mehrabian A., Epstein N. A measure of emotional empathy // Journal of personality. 1972.

18. Kapustina A.N. R. Cattell's multi-factor personal technique. Saint Petersburg: Rech, 2004.

А.Н. АЛЕКСЕЕВА, О.А. КРОТКОВА, М.В. ГАЛКИН, М.Ю. КАВЕРИНА, Г.В. ДАНИЛОВ
Институт нейрохирургии им. академика Н.Н. Бурденко РАМН, Москва
aveeskela.an@gmail.com

КАЧЕСТВЕННЫЕ ОЦЕНКИ КАК ОДИН ИЗ ВАРИАНТОВ ПРЕОБРАЗОВАНИЙ МНОГОФАКТОРНОЙ ДИНАМИКИ В КОГНИТИВНОЙ СФЕРЕ*

Качественный анализ предлагается как этап анализа многофакторной динамики в когнитивной сфере у пациентов, получающих лучевое лечение. Введение качественных оценок для динамики когнитивного статуса позволило установить неравномерность функциональных изменений полушарий под влиянием ионизирующего излучения: более раннее начало разнонаправленной динамики при воздействии на правое полушарие и большую инертность изначальных индивидуальных показателей при воздействии на левое полушарие.

Ключевые слова: *когнитивные функции, ионизирующее излучение, факторы воздействия, качественные оценки, асимметрия полушарий.*

Введение

Задача оценки динамики когнитивной сферы является актуальной для многих ситуаций, например, связанных с оценкой спектра действия ноотропных препаратов или отдаленных последствий нейрохирургического лечения пациентов с заболеваниями мозга. Известно, что высшие психические функции человека не унитарны по природе, а включают в свой состав множество подсистем и звеньев, по-разному меняющихся в зависимости от функционального состояния различных отделов мозга [1, 2]. Ситуации сложного воздействия на мозг человека могут сопровождаться положительными изменениями одних характеристик когнитивной сферы и отрицательными – других. При этом значения изолированных от системного исследования тестов не могут рассматриваться в качестве сколько-нибудь исчерпывающих характеристик динамики когнитивной сферы [3, 4]. Мы предполагаем, что в ряде случаев интегративный анализ мно-

* Данная работа выполнена при финансовой поддержке гранта РНФ 17-15-01426.

гофакторной динамики в когнитивной сфере требует введения промежуточных индивидуальных оценок, носящих качественный характер.

Постановка задачи

В настоящей работе стояла задача анализа динамики когнитивной сферы у пациентов, получающих лучевое лечение с преимущественным воздействием на одно из полушарий мозга. Менингиомы хиазмально-селлярной области являются доброкачественными новообразованиями, располагающимися в непосредственной близости от медио-базальных отделов левой или правой височной доли. Они компримируют структуры «своего» полушария, однако не инфильтрируют вещество мозга (не разрушают его). Еще одной существенной характеристикой данных новообразований является низкая скорость роста. Поэтому, сама по себе, эта патология почти не приводит к формированию когнитивных дефицитов [5]. С целью остановки роста опухоли таким больным осуществляется стереотаксическая конформная лучевая терапия: 30 сеансов по 1,8 Гр до суммарной очаговой дозы 54 Гр. При таком лечении воздействию некоторой дозы терапевтической радиации неизбежно подвергаются нормальные структуры на стороне расположения опухоли. У большинства пациентов после лечения отмечается остановка роста опухоли. Однако динамика когнитивной сферы у таких пациентов изучена недостаточно. Успешное решение этой задачи, помимо прочего, позволяет проследить особенности изменения функционального состояния левого и правого полушарий в ответ на воздействие ионизирующего излучения.

И, наконец, ещё одним аспектом решаемых задач является прицельное выделение изменений в работе гиппокампальных отделов мозга. Патологические новообразования в группе исследования непосредственно прилегали к гиппокампу так, что гиппокамп вынужденно получал дозовую нагрузку, сопоставимую с нагрузкой на опухоль. Гиппокамп является структурой, функции которой тесно связаны с переработкой информации и следовыми процессами [6]. В то же время, согласно литературным данным нельзя исключить нейрогенную функцию гиппокампа взрослого человека – продукцию новых нейронов из прогениторных клеток [7]. Ионизирующее облучение оказывает сильнейшее подавляющее воздействие на этот процесс. Предполагается, что угнетение взрослого нейрогенеза является одной из причин формирования когнитивных изменений после лучевой терапии [7].

Методика исследования

Набор экспериментальных заданий и тестов для оценки когнитивной сферы был основан на современных представлениях о мозговом обеспечении высших психических функций человека. Условно все проводившиеся психологические пробы можно было сгруппировать в следующие блоки: управляющие функции и внимание; движения и праксис; зрительный и слуховой гнозис; речь, чтение, письмо; основные модальности и формы памяти; оптико-конструктивная деятельность; мышление и счет. На основании принципов нейропсихологического анализа [1, 2] по результатам выполнения данного набора можно было составить суждение о функциональном состоянии всех корковых и подкорковых отделов мозга, реализующих когнитивные процессы. Отдельный блок составляли опросники и задания, оценивающие межполушарное взаимодействие (методика дихотического прослушивания, позные пробы на выявление доминантного полушария, опросник Аннет). Ещё один самостоятельный блок составляли оригинальные экспериментальные задания, направленные на изучение тонкой дифференциации паттернов информации – выделение в похожих изображениях признаков, позволяющих расценивать их как похожие, но не идентичные ранее увиденным изображениям. Функцию разделения паттернов (pattern separation) в современных исследованиях связывают со нейрогенезом взрослого человека. Как предполагается, она опосредуется процессом формирования в мозге различных репрезентаций для схожих следов памяти [8, 9]. В нашем исследовании использовалась оригинальная методика, позволяющая оценить точность запоминания и узнавания стимулов в сочетании с регистрацией движений глаз испытуемых. Функция разделения паттернов (специфические ошибки узнавания) оценивалась количественно для стимулов в левом и правом полях зрения [10].

Выполнение всего экспериментального набора осуществлялось пациентом в течение трех сеансов продолжительностью 45–60 минут каждый. Между сеансами были промежутки для отдыха. Как правило, сеансы проводились в течение одного экспериментального дня. В исследование были включены 28 пациентов с менингиомами хиазмально-селлярной области. 15 – с левосторонним расположением опухоли и 13 – с правосторонним. На момент начала лечения эти две подгруппы по демографическим признакам и клиническим особенностям заболевания не различались. Для удобства изложения день исследования обозначался как некоторая временная точка. Первая точка соответствовала исследованию, проводившемуся перед началом лучевой терапии. Вторая точка – сразу после окончания лечения (30 сеансов лучевой терапии, проводившиеся по рабочим

дням, как правило, занимали период около 45 календарных дней). Третья точка – через 6 месяцев после лучевой терапии.

Результаты

В первой временной точке результаты в подгруппах по тестам, характеризующим функциональное состояние корковых и подкорковых отделов мозга, в целом не выявляли значимых различий, ещё раз подтверждая полученные ранее данные об отсутствии очаговой нейропсихологической симптоматики у больных с внемозговыми доброкачественными новообразованиями данной локализации [5]. В интервалах от первой ко второй точке и от второй к третьей точке показатели проводимых тестов демонстрировали тенденции, не позволяющие провести усреднение показателей для осуществления синдромного анализа регистрируемых изменений. Такая ситуация характерна для условий, когда динамика когнитивной сферы обусловлена действием ряда сопряженных факторов. Для описания тенденций динамики были введены качественные оценки, выставлявшиеся каждому больному в каждом интервале наблюдения.

Качественная оценка «Отсутствие изменений» выставлялась больному в том случае, если по большинству экспериментальных заданий в данном интервале отсутствовали статистически значимые изменения как в положительную, так и в отрицательную сторону. Качественная оценка «Разнонаправленная динамика» выставлялась больному в том случае, когда по большинству тестов регистрировались статистически значимые изменения, при относительно одинаковом соотношении тестов с положительными и отрицательными изменениями показателей без отчетливого преобладания положительных или отрицательных тенденций в сумме по всем тестам. Качественная оценка «Ухудшение показателей тестирования» выставлялась больному, если по большинству тестов результаты в данном интервале значимо ухудшались. Качественная оценка «Улучшение показателей тестирования» выставлялась больному, если по большинству тестов результаты в данном интервале значимо улучшались.

На рис.1 представлено процентное соотношение указанных оценок в каждой из подгрупп. Видно, что в первом интервале наблюдения (от первой ко второй точке исследования) у больных с левосторонним расположением опухоли преобладала тенденция к отсутствию изменения экспериментальных показателей. Она наблюдалась у 40% пациентов, тогда как разнонаправленные тенденции в тестах регистрировались лишь у 13% больных. В том же интервале у пациентов с правосторонним расположением опухоли, наоборот, у 46 % больных преобладали разнонаправленные

тенденции в тестах и лишь у 23 % эти показатели оставались неизменными.

Во втором интервале наблюдения доля пациентов с разнонаправленными тенденциями по тестам в группе больных с левосторонним расположением опухоли приблизилась к доле больных с аналогичными оценками в группе с правосторонним расположением опухоли. А в группе с правосторонним расположением опухоли удельный вес таких качественных оценок остался в первом и во втором интервале неизменным (43 %, 46 % и 46 % соответственно).

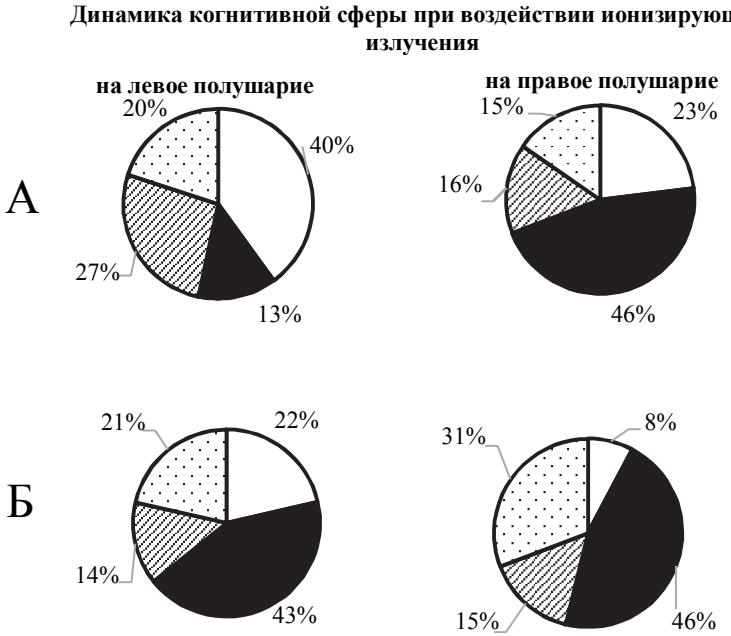

Рис. 1. Динамика когнитивной сферы при воздействии ионизирующего излучения на левое полушарие (левый столбец) и правое полушарие (правый столбец). А – динамика от первой ко второй точке исследования, Б – динамика от второй к третьей точке исследования

Во втором интервале наблюдения доля пациентов с отсутствием изменений в экспериментальных показателях сократилась в обеих подгруппах, однако в группе больных с левосторонним расположением опухоли она продолжала оставаться выше, чем в группе больных с правосторонним расположением патологического новообразования (22 % и 8 %, соответственно).

Больные, демонстрировавшие выраженное ухудшение параметров тестирования (нарастание нейропсихологической симптоматики), в первом интервале наблюдения преобладали в подгруппе с левосторонним расположением опухоли. Во втором интервале наблюдения доля таких пациентов в обеих подгруппах стала одинаковой.

Доля больных с отчетливой положительной динамикой по результатам тестирования у больных с левосторонним расположением опухоли была устойчиво постоянной. При этом она практически не отличалась от таковой у больных с правосторонним расположением опухоли в первом интервале наблюдения. Но во втором интервале наблюдения в группе больных с правосторонним расположением опухоли удельный вес качественных оценок «улучшение показателей тестирования» вырос до 31 % (15 % в первом интервале наблюдения).

Отдельно была проанализирована динамика для теста разделения паттернов. Она прошла средне групповую статистическую обработку, выявив аналогичные тенденции уже на уровне всей группы. В первом интервале наблюдения показатели памяти и внимания больных с левосторонним расположением опухоли либо оставались неизменными, либо демонстрировали ухудшение способности к дифференциации паттернов. Во втором интервале наблюдения у них регистрировалась разнонаправленная динамика для разных параметров теста. У больных с правосторонним расположением опухоли разнонаправленные тенденции регистрировались и в первом, и во втором интервалах наблюдения. Например, в первом интервале в этой подгруппе число ошибок узнавания в левом поле зрения резко возросло, а число ошибок узнавания в правом поле зрения, наоборот, статистически значимо сократилось [11].

Анализ результатов

Терапевтическое облучение является одним из основных методов лечения первичных и метастатических опухолей головного мозга. Несмотря на эффективность такого лечения, ионизирующее излучение обладает нейротоксическими эффектами, среди которых выделяют острые, ранние и отстроченные (через несколько месяцев и лет) эффекты радиотерапии. В

их основе может лежать целый комплекс вызываемых радиацией патологических механизмов – гиалинизация соединительной ткани, демиелинизация и некроз белого вещества, морфофункциональные изменения сосудов. Напротив, факторами положительного влияния лучевой терапии являются остановка роста, а, в ряде случаев, – уменьшение объёма патологического новообразования. Ещё одной группой факторов при распространении ионизирующего излучения на гиппокампальные области является изменение взрослого нейрогенеза [7]. Динамика когнитивной сферы пациентов испытывает мощное воздействие всех перечисленных факторов, демонстрируя положительные и отрицательные тенденции в общей картине изменений. К сожалению, уровень наших знаний не позволяет однозначно установить причинно-следственные отношения с действием того или иного фактора. Как некоторый промежуточный вариант анализа при этом может рассматриваться введение системы качественных оценок, позволяющих интегрально описать состояние когнитивной сферы пациента в том или ином интервале наблюдения.

В нашей работе такой анализ позволил установить неравнозначность функциональных изменений левого и правого полушарий при воздействии радиации. В первом интервале наблюдения функциональные изменения со стороны правого полушария более выражены. Они характеризуются как положительными, так и отрицательными тенденциями, свидетельствуя о значительной чувствительности когнитивных процессов, реализуемых за счет функционального вклада правого полушария, к воздействию ионизирующего излучения. Нейропсихологическая симптоматика от левого полушария при этом выглядит более стабильной.

Во втором интервале наблюдения (в течение 6 месяцев после осуществления лучевого лечения) уровень вариативности когнитивных последствий лучевого воздействия на левое и правое полушарие становится примерно одинаковым, однако факторы положительного влияния лечения на когнитивную сферу более выраженно реализуются правой гемисферой.

Ранее гипотеза неравномерности функциональных изменений мозга под воздействием радиации (опережающее появление и нарастание правополушарных симптомов) высказывалась коллективом ученых, изучавших последствия аварии на Чернобыльской АЭС [12]. Одним из механизмов такой неравномерности, как представляется, может являться разная система опосредования когнитивных явлений. В большей степени сопряженная со структурными связями в левом полушарии мозга и в большей степени зависящая от нейрогуморальных перестроек в правом полушарии [13, 14]. Актуальность проведённого изучения последствий воздействия радиации на когнитивные процессы человека продиктована как наличием

этого фактора при крупных техногенных катастрофах, так и всё возрастающим значением лучевой терапии в лечении патологических новообразований.

Выводы

1. Качественные оценки могут рассматриваться как один из вариантов преобразований многофакторных изменений в когнитивной сфере при отсутствии однозначных причинно-следственных отношений для каждого элемента всей совокупности изменений.

2. В настоящей работе введение качественных оценок для динамики когнитивного статуса у каждого из обследованных пациентов позволило установить неравномерность функциональных изменений полушарий под влиянием ионизирующего излучения: более раннее начало разнонаправленной динамики при воздействии на правое полушарие и большую инертность изначальных индивидуальных показателей при воздействии на левое полушарие.

Список литературы

1. Лурия А.Р. Высшие корковые функции человека (дополненное издание). СПб.: Питер, 2008.

2. Хомская Е.Д. Основы нейропсихологии. СПб.: Питер, 2005.

3. Кроткова О.А., Найдин В.Л. Перспективы использования нейропсихологического метода АР Лурии в изучении биохимического обеспечения высших психических функций // Вестн. Моск. ун-та. Сер. 1992. Т. 14. С. 62–66.

4. Arciniegas D.B., Silver J.M. Pharmacotherapy of posttraumatic cognitive impairments // Behavioural neurology. 2006. Т. 17. № 1. С. 25–42.

5. Alekseeva A. et al. Dynamics of cognitive functions in patients with parasellar meningiomas undergoing radiotherapy // KnE Life Sciences. 2018. С. 42–48.

6. Буклина С.Б. Нарушения высших психических функций при поражении глубинных и стволовых структур мозга. М.: МЕДпресс-информ. 2016. С. 46–47.

7. Encinas J.M. et al. Division-coupled astrocytic differentiation and age-related depletion of neural stem cells in the adult hippocampus // Cell stem cell. 2011. Т. 8. № 5. С. 566–579.

8. Clelland C.D. et al. A functional role for adult hippocampal neurogenesis in spatial pattern separation // Science. 2009. Т. 325. № 5937. С. 210–213.

9. Stark S.M. et al. A task to assess behavioral pattern separation (BPS) in humans: Data from healthy aging and mild cognitive impairment // Neuropsychologia. 2013. Т. 51. № 12. С. 2442–2449.

10. Кроткова О.А., Каверина М.Ю., Данилов Г.В. Мозговые механизмы распределения зрительного внимания и возможность коррекции возникающих при поражении мозга нарушений с помощью технологии айтрекинга// Пятая Между-

народная конференция Фундаментальные и прикладные аспекты восстановления сознания после травмы мозга: междисциплинарный подход. Материалы конференции. 2016. С. 56–58.

11. Данилов Г.В., Кроткова О.А., Алексеева А.Н., Кулёва А.Ю., Каверина М.Ю., Галкин М.В., Ениколопова Е.В. Динамика распределения внимания при одностороннем лучевом воздействии // Актуальная психология. Научный вестник. 2019. № 2 (4). С. 120–127.

12. Горина И.С., Ениколопова Е.В. Сравнительный анализ нейропсихологических синдромов у участников ликвидации последствий аварии на Чернобыльской АЭС и лиц с невротическими расстройствами // ктуальные проблемы психологии. Сборник научных трудов Института психологии им. Г.С. Костюка АПН Украины. К.: Милениум, 2005. Т. 7. Вып. 5. С. 115–125.

13. Дьяконова В., Сахаров Д. Пострефлекторная нейробиология поведения. Litres, 2019.

14. Кроткова О. А. Психофизическая проблема и асимметрия полушарий мозга // Вестник Московского университета. Серия 14. Психология. 2014. № 3. С. 47–62.

С.А. ПЛОТНИКОВ[1], Ю.Д. КРОПОТОВ[2], М. ЛИПКОВИЧ[1], Д.М. СЕМЕНОВ[1], А.Л. ФРАДКОВ[1]

[1]Институт проблем машиноведения РАН, Санкт-Петербург
[2]Институт мозга человека им. Н.П. Бехтеревой РАН, Санкт-Петербург
waterwalf@gmail.com, yurykropotov@yahoo.com

АЛГОРИТМ НЕЙРООБРАТНОЙ СВЯЗИ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА*

Предложен новый подход к проектированию систем нейрообратной связи, основанный на использовании инструментов искусственного интеллекта. Описаны концепция управления подвижными объектами на основе нейрообратной связи и нейросетевой стенд, включающий оборудование и программные средства, разработанные в ИПМаш РАН для реализации предложенной концепции.

Ключевые слова: *нейрообратная связь, нейрокомпьютерный интерфейс, электроэнцефалография, управление, искусственный интеллект, нейронные сети.*

* Данная работа выполнена при частичной поддержке РФФИ, проект № 19-08-00865.

Введение

В последние годы наблюдается быстрый рост применения методов и средств искусственного интеллекта (ИИ). Для ряда задач результаты, полученные в парадигме ИИ, сравнимы или даже превосходят результаты, полученные людьми [1]. Задачи изучения возможностей и повышения эффективности взаимодействия естественного и искусственного интеллекта находятся на повестке дня. Первые шаги в этом направлении были сделаны задолго до недавнего бума искусственного интеллекта. Они породили концепции биологической обратной связи и, в частности, нейрообратной связи [2, 3]. В системах с биологической обратной связью информация о состоянии организма (информация о состоянии нервной системы, в частности, коры головного мозга) передается на компьютер с помощью специальных инструментов для дальнейшей обработки и классификации. Результаты классификации показываются человеку таким образом, что он может оценить близость своего состояния к определенной области, которая соответствует желательным или, наоборот, нежелательным состояниям. В качестве средства записи информации обычно используются неинвазивные методы: ЭЭГ, МЭГ, МРТ и т.д.

Существует множество публикаций, в которых сообщается о практическом применении этого подхода. В работе [4] авторы предложили сформировать сигнал нейрообратной связи на основе адаптивной модели ритмов мозга, скорректированной по сигналам ЭЭГ с использованием методов, разработанных в кибернетике. Адаптивное формирование сигналов нейрообратной связи позволяет не только учитывать изменения в состоянии субъекта, но и корректировать рекомендации системы, когда состояние субъекта приближается или удаляется от целевых областей. Адаптивная рабочая модель, используемая в [4], как и другие адаптивные модели, используемые для описания динамики и управления в моделях нейронных сетей [5, 6], сильно агрегирована и содержит относительно небольшое количество параметров. Способности таких моделей описывать или предсказывать сложные сигналы относительно невелики. В то же время для повышения информативности данных ЭЭГ необходимо увеличить количество отведений и продолжительность проб.

Интерес представляет использование более сложных моделей адаптивных сигналов на основе глубоких нейронных сетей и других моделей и методов современного искусственного интеллекта. До настоящего времени исследования по построению систем нейрообратной связи на основе ИИ в мире практически отсутствуют. Использование нейрообратной связи на основе методов и инструментов ИИ может дать возможность значи-

тельно повысить эффективность взаимодействия естественного и искусственного интеллекта. Кроме того, это предоставит новые возможности для улучшения нейрокомпьютерных интерфейсов (НКИ).

В данной статье описан новый подход к построению систем нейрообратной связи на основе ИИ. В следующих разделах описана концепция моделей управления биологическими нейронными сетями, разработанная в ИПМаш РАН, набор оборудования и набор программных средств, созданных для реализации предложенной концепции, а также методы и программы ИИ, предлагаемые для использования.

Нейрообратная связь

Целью клинической и поведенческой неврологии является наблюдение и понимание механизмов нервной системы для контроля поведенческих нервных процессов и восстановления этих функций, если они нарушены. Чтобы решить эту проблему, можно использовать подход нейрообратной связи, то есть психофизиологическую процедуру, при которой субъектам предоставляются модели нейронной активности с целью их регулирования в режиме онлайн [3].

Лучший способ зарегистрировать активность нейронов – использовать инвазивные методы. В зависимости от размера и сопротивления электродов можно зарегистрировать активность нейронных групп или даже отдельных нейронов. Эти методы позволяют людям с ограниченными возможностями (эпилепсия, болезнь Паркинсона, эссенциальный тремор) управлять экзоскелетом [7] или печатать текст [8]. Однако у этих методов есть несколько проблем. Первая проблема – дорогая стоимость этой процедуры. Во-вторых, имплантация электрода в кору головного мозга представляет собой сложную нейрохирургическую операцию, приводящую к повреждению нервных тканей вокруг имплантата. В-третьих, имплантат зарастает глией с течением времени, что приводит к проблемам с записью сигнала.

Другой способ регистрации активности мозга – использование неинвазивных методов. Наиболее распространенным методом является электроэнцефалография (ЭЭГ), то есть регистрация мозговой активности с использованием электродов, которые располагаются на поверхности головы. Это самый распространенный и дешевый метод, имеющий наибольшее временное разрешение из неинвазивных методов. К недостаткам этого метода можно отнести низкое пространственное разрешение и зашумленный сигнал. ЭЭГ измеряет колебания напряжения, возникающие в результате активности ионного тока в нейронах мозга [9]. Различные образцы электрической активности, известные как мозговые волны, можно узнать

по их амплитудам и частотам. Частота показывает, как быстро колеблются волны, что измеряется количеством волн в секунду (Гц), а амплитуда представляет мощность этих волн, измеряемую в микровольтах [10].

Частотные компоненты спектра делятся на дельта- (менее 4 Гц), тета- (4–8 Гц), альфа- (8–13 Гц), бета- (13–30 Гц) и гамма- (30–100 Гц) ритмы, где каждый представляет определенную физиологическую функцию.

Дельта- и тета-ритмы связаны с состоянием сна человека. Альфа-ритм представлен преимущественно в затылочных областях. Его амплитуда значительно увеличивается, когда глаза закрыты; он также подавляется при стрессе и усиливается при расслаблении. Бета- и гамма-ритмы увеличиваются при умственной активности и тревоги и имеют более низкую амплитуду по сравнению с альфа-ритмом.

Наша цель – разработать комплекс, который позволит человеку управлять подвижными объектами, используя парадигму нейрообратной связи, то есть управлять ими, изменяя активность мозга. Дельта- и тета-ритмы не подходят для решения этой проблемы, потому что они наблюдаются преимущественно, когда человек спит. Гамма ритм имеет низкую амплитуду по сравнению с шумом, поэтому его сложно использовать для управления. Наиболее подходящим ритмом для решения поставленной проблемы является альфа-ритм. Однако человек не может управлять транспортным средством, когда его глаза закрыты. Для этой цели можно использовать так называемый сенсомоторный ритм (мю-ритм), который представляет собой ритм ЭЭГ в диапазоне альфа-ритма, наблюдаемый в центральной и центротальпоральной областях коры головного мозга в расслабленном состоянии, или бета-ритм, который также связан с двигательной активностью. Мю-ритм блокируется движением, наблюдением за движением, кинестетическим или визуальным представлением движения [11].

Экспериментальная установка

Разработка экспериментальной установки является ключевым этапом проектирования нейрокомпьютерного интерфейса (НКИ). ИМПаш РАН располагает специальным нейросетевым стендом НС-1, позволяющим проводить эксперименты с использованием электроэнцефалографа. Экспериментальный комплекс НС-1 имеет в своем составе 2 энцефалографа. Первый – мобильный энцефалограф Мицар-ЭЭГ-SmartBCI на 32 канала с системой позиционирования электродов Electro-Cap USA с акусессуарами [12]. Второй – стационарный энцефалограф Нейровизор 136 на 136 каналов [13]. Также имеются мобильные роботы, собранные из конструкторов ТРИК [14] и LEGO Mindstorms NXT [15], зарядные устройства и вспомо-

гательное оборудование. Подробное описание стенда можно найти на сайте ИПМаш РАН в разделе «Структура института-объекты инфраструктуры» [16].

Для проведения экспериментов с использованием стенда НС-1 в определенных местах на голове субъекта размещаются небольшие электроды с помощью шапочки. Для обеспечения качественного контакта электродов с кожей головы используется электропроводящий гель (УНИМАКС). Голова должна быть очищена перед экспериментом, что обеспечивает хороший контакт электродов с кожей головы для получения высококачественной записи энцефалограммы. Энцефалографы подключаются к компьютеру через USB-кабель или Bluetooth, соответственно. Для получения данных из энцефалографа используется специальное программное обеспечение, которое преобразует сигналы в поток LSL (Lab Streaming Layer). Для энцефалографа Mitsar-EEG-SmartBCI используется программное обеспечение LSLSmartBCI, а для энцефалографа Нейровизор-136 - программное обеспечение NeoRec. Далее можно использовать программное обеспечение, разработанное в ИПМаш РАН [17, 18], для управления роботом с использованием преобразованного сигнала от ЭЭГ.

Структура программного обеспечения

Представленное программное обеспечение было разработано в среде MATLAB [19] и состоит из пяти основных блоков: получение сигнала ЭЭГ, частотная фильтрация, пространственная фильтрация, адаптивная оценка параметров модели и управление роботом (рис. 1).

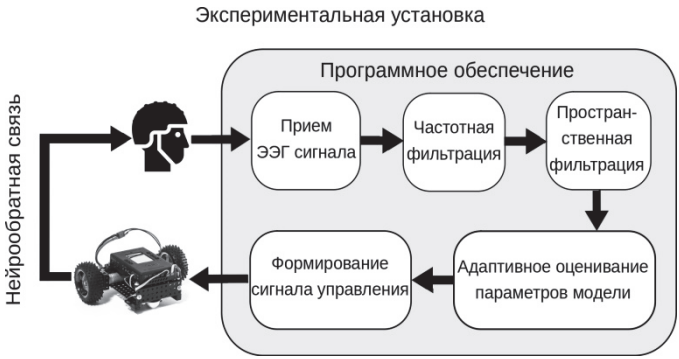

Рис. 1. Схема экспериментальной установки и программного обеспечения на основе фильтрации CSP и адаптивной модели

Блок приема сигнала ЭЭГ используется для передачи электрических потенциалов от электродов энцефалографа к ПК, который является программным обеспечением сторонних производителей, описанным выше.

Принятый сигнал ЭЭГ передается на блок частотной фильтрации. Целью этого блока является определение сигнала в соответствующей полосе частот 8–30 Гц, что соответствует альфа и бета ритмам. Для этого используется фильтр Баттерворта четвертого порядка.

Модуль пространственной фильтрации основан на алгоритме Common Spatial Pattern (CSP), который позволяет локализовать источник сигнала. Алгоритм основан на решении обобщенной задачи на собственные значения [20], образованной парой автокорреляционных матриц для двух различных сопоставимых условий.

Следующий блок называется адаптивным оцениванием параметров модели. Разработка методов расчета сигналов адаптивной обратной связи, которые корректируют параметры правил применительно к конкретному предмету, является актуальной проблемой. Правила для расчета количественных параметров ЭЭГ, используемых далее для формирования сигнала нейрообратной связи, зависят от большого числа параметров, таких как, например, длина временного окна обработки данных или величина задержки при предъявлении управляющего воздействия. Индивидуальный подбор значений этих параметров также может повысить эффективность тренинга [4]. После этого управляющий сигнал генерируется путем сравнения модели и результатов алгоритма CSP в блоке генерации управления.

Полученный управляющий сигнал передается роботу, который, в свою очередь, начинает двигаться в соответствующем направлении. Перемещение правой руки приводит к подавлению мю-ритма в левом полушарии, что приводит к увеличению мощности левого колеса робота, то есть он поворачивает вправо. То же самое относится и к движению левой руки. Таким образом, субъект может управлять роботом.

Обсуждение результатов

Эксперимент по распознаванию сенсомоторного ритма проводили на испытуемом (мужчина, 28 лет). Пространственный фильтр обучался посредством вращения запястья левой или правой руки по очереди, распознавание – через вращение и воображение вращения. Результаты согласуются с наблюдениями работы [11], а именно движение лучше распознается, чем его воображение. В нашем случае:

1) вращение правой кистью: распознавание 61 %;
2) воображение вращения правой кисти: распознавание 52 %;

3) вращение левой кистью: распознавание 82 %;
4) воображение вращения левой кисти: распознавание 68 %.

Точность распознавания движения недостаточна для решения поставленной задачи управления роботом. Точность в значительной степени зависит от субъекта, независимо от того, обучен ли он контролировать активность мозга или нет. Другая проблема заключается в том, что движение глаз и мышц лица влияют на записанный сигнал. В результате появляется реальная возможность научиться управлять транспортным средством, используя мышцы и глаза, а не мозг. Чтобы преодолеть эти трудности, мы предлагаем использовать современные методы распознавания образов, основанные на искусственном интеллекте, а именно, мы предлагаем изменить блок пространственной фильтрации и адаптивной оценки на блок классификации на основе искусственного интеллекта.

Искусственный интеллект

В последние годы быстро развиваются технологии искусственного интеллекта и машинного обучения. Традиционный подход к машинному обучению включает в себя два этапа: выделение признаков («фичей») и непосредственно обучение модели. Выделение признаков – это процесс выбора и преобразования ключевых характеристик, содержащихся в необработанных данных. Полученные характеристики служат входом для модели машинного обучения. Модель состоит из нескольких параметров, которые настраиваются («обучаются»), как правило, с использованием некоторого итеративного процесса для достижения поставленной цели. Например, можно рассмотреть возможность обучения модели, которая отображает входные функции на фиксированный набор меток («лейблов»). Такая задача называется классификацией. Для нашей задачи в качестве меток могут выступать «правое вращение» и «левое вращение».

Разработка признаков требует глубоких знаний предметной области и высококачественных необработанных данных. Данные ЭЭГ имеют низкое SNR (отношение сигнал/шум), что затрудняет извлечение разумных признаков. Хотя было разработано несколько методов предварительной обработки для снижения уровня шума, эти методы занимают много времени и не подходят для формирования сигналов управления в реальном времени и могут привести к потере полезной информации. Кроме того, на сигналы ЭЭГ влияют движения глаз и мимические мышцы, что может быть отражено в извлеченных признаках. В последнее время набирает популярность альтернативный подход к машинному обучению. Этот подход, который называется глубоким обучением, вместо того чтобы раз-

делять обучение на две отдельные стадии выделения признаков и подбора параметров, выполняет их одновременно в процессе обучения. Другими словами, модель глубокого обучения сама извлекает подходящие признаки из необработанных данных. Ключевым моментом нашего предложения является замена пространственной фильтрации и адаптивной оценки параметров в схеме на рис. 1 на модель ИИ и алгоритмы классификации машинного обучения (рис. 2). Парадигма глубокого обучения кажется наиболее многообещающей для этой задачи классификации из-за проблем разработки признаков, которые обсуждались выше.

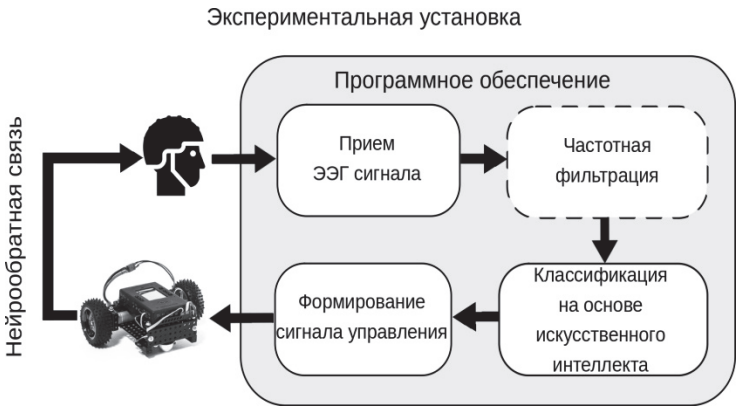

Рис. 2. Схема экспериментальной установки и программного обеспечения на основе ИИ

Одной из проблем с подходом глубокого обучения является необходимость больших объемов необработанных данных. Для решения этой проблемы мы предлагаем использовать данные из открытых источников [21, 22] для предобучения нашей модели [23]. Эта модель послужит основой для классификационных моделей, которые будут обучаться на наших помеченных данных. Мы могли бы начать с бинарной классификации («правое вращение», «левое вращение») и добавить новые классы, как только мы соберем больше данных без необходимости переобучать базовую модель. Существует много архитектур моделей глубокого обучения. Так называемые сверточные нейронные сети (CNN) позволяют захватывать пространственную структуру данных, в то время как рекуррентные нейронные сети (RNN) хорошо подходят для захвата временной структуры. Поскольку сигналы ЭЭГ имеют как пространственные, так и временные компоненты, можно рассмотреть возможность использования ги-

бридных моделей, состоящих из уровней CNN и RNN. Хотя модели глубокого обучения извлекают признаки сами по себе и могут применяться непосредственно к необработанным данным [24, 25], в качестве входных данных для модели все же можно использовать предварительно обработанный сигнал [26, 27] Модели глубокого обучения также часто используются в качестве экстракторов признаков [28, 29].

Заключение

Современная технология на основе искусственного интеллекта кажется подходящей для обработки больших наборов данных ЭЭГ. Мы предлагаем использовать ее в парадигме нейрообратной связи. Это открывает путь для улучшения взаимодействия между человеком и машиной и для расширения области применения нейрообратной связи. Следующим этапом исследований станет экспериментальное изучение предложенного подхода.

Список литературы

1. Silver D., Schrittwieser J., Simonyan K., Antonoglou I., Huang A., Guez A., Hubert T., Baker L., Lai M., Bolton A., Chen Y., Lillicrap T., Hui F., Sifre L., van den Driessche G., Graepel T., Hassabis D. Mastering the game of Go without human knowledge // Nature. 2017. V. 550. P. 354–359.

2. Kropotov Yu.D. Quantitative EEG, Event-Related Potentials and Neurotherapy. Berlin: Elsevier. 2008.

3. Sitaram R., Ros T., Stoeckel L., Haller S., Scharnowski F., Lewis-Peacock J., Weiskopf N., Blefari M.L., Rana M., Oblak E., Birbaumer N., Sulzer J. Closed-loop brain training: the science of neurofeedback // Nat. Rev. Neurosci. 2017. V. 18. No 2. P. 86–100.

4. Овод И.В., Осадчий А.Е., Пупышев А.А., Фрадков А.Л. Формирование нейрообратной связи на основе адаптивной модели активности головного мозга // Нейрокомпьютеры: разработка, применение. 2012. № 2. С. 36–41.

5. Gorshkov A.A., Plotnikov S.A., Fradkov A.L. Bifurcation and synchronization analysis of neural mass model subpopulations // IFAC-PapersOnLine. 2017. Vol. 50. No 1. P. 14741–14745.

6. Plotnikov S.A., Lehnert J., Fradkov A.L., Schoell, E. Adaptive control of synchronization in delay-coupled heterogeneous networks of FitzHugh-Nagumo nodes // Int. J. Bifur. Chaos. 2016. V. 26. No 4. P. 1650058.

7. Takasaki K., Liu F., Ogura M., Okuyama K., Kawakami M., Mizuno K., Kasuga S., Noda T., Morimoto J., Liu M., Ushiba J. EEG-based neurofeedback training with shoulder exoskeleton robot assistance triggered by the contralesional primary motor cortex activity in poststroke patients with severe chronic hemiplegia // Ann. Phys. Rehab. Med. 2018. V. 61. P. e94–e95.

8. Arvaneh M., Robertson I.H., and Ward T. P300-based brain-computer interface for improving attention // Front. Hum. Neurosci. 2018. V. 12. P. 524.

9. Niedermeyer E. and Lopes da Silva F.H. Electroencephalography: basic principles, clinical applications, and related fields. Philadelphia: Lippincott Williams & Wilkins. 2005.

10. Marzbani H., Marateb H.R., Mansourian M. Neurofeedback: a comprehensive review on system design, methodology and clinical applications // Basic Clin. Neurosci. 2016. V. 7. No 2. P. 143–158.

11. Neuper C., Scherer R., Reiner M., and Pfurtscheller G. Imagery of motor actions: differential effects of kinesthetic and visual-motor mode of imagery in single-trial EEG // Cogn. Brain Research. 2005. V. 25. No 3. P. 668–677.

12. https://mitsar-eeg.com

13. https://mks.ru/index

14. https://trikset.com

15. https://www.lego.com/en-us

16. http://www.ipme.ru/ipme/ru/indexr.html

17. Осадчий А.Е., Сметанин Н.М., Плотников С.А. Среда для проведения тренинга в парадигме нейрообратной связи // Свидетельство о государственной регистрации ПрЭВМ, рег. №2018611760 от 06.02.2018. Москва: Роспатент. 2018.

18. Степаненко Д.А., Семенов Д.М., Плотников С.А., Фрадков А.Л. Программный комплекс для реализации нейрообратной связи: модуль обработки сигнала ЭЭГ // Свидетельство о государственной регистрации ПрЭВМ, рег. № 2019610034 от 09.01.2019. М.: Роспатент, 2019.

19. https://www.mathworks.com

20. Koles Z.J., Lazaret M.S., Zhou S.Z. Spatial patterns underlying population differences in the background EEG // Brain Topogr. 1990. Vol. 2. P. 275–284.

21. https://github.com/meagmohit

22. https://sccn.ucsd.edu/~arno/fam2data

23. Erhan D., Bengio Y., Courville A., Manzagol P.-A., Vincent P., Bengio, S. Why does unsupervised pre-training help deep learning? // JMLR. 2010. V. 11. P. 625–660.

24. Sors A., Bonnet S., Mirek S., Vercueil L., Payen J.F. A convolutional neural network for sleep stage scoring from raw single-channel EEG // Biomed. Signal Process. Control. 2018. V. 42. P. 107–114.

25. Tang Z., Li C., Sun S. Single-trial EEG classification of motor imagery using deep convolutional neural networks // Optik. 2017. V. 130. P. 11–18.

26. Johansen A.R., Jin J., Maszczyk T., Dauwels J., Cash S.S., Westover M.B. Epileptiform spike detection via convolutional neural networks // 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2016. P. 754–758.

27. Tsiouris K.M., Pezoulas V.C., Zervakis M., Konitsiotis S., Koutsouris D.D., Fotiadis D.I. A Long Short-Term Memory deep learning network for the prediction of epileptic seizures using EEG signals // Comput. Biol. Med. 2018. V. 99. No 1. P. 24–37.

28. Ansari A.H., Cherian P.J., Caicedo A., Naulaers G., De Vos M., Van Huffel S. Neonatal seizure detection using deep convolutional neural networks // Int. J. Neural Syst. 2018. V. 29. No 4. P. 1850011.

29. Wang Q., Hu Y., Chen H. Multi-channel EEG classification based on fast convolutional feature extraction // International Symposium on Neural Networks. 2017. P. 533–540.

А.А. ТЕЛЬНЫХ[1,2], И.В. НУЙДЕЛЬ[1,2], О.В. ШЕМАГИНА[1,2]
[1]Федеральный исследовательский центр Институт прикладной физики Российской академии наук, Нижний Новгород
[2]Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского
nuidel@appl.sci-nnov.ru

БИОМОРФНАЯ СТРУКТУРНО-ФУНКЦИОНАЛЬНАЯ МОДЕЛЬ ОБРАБОТКИ ЗРИТЕЛЬНЫХ СИГНАЛОВ В ЖИВЫХ СИСТЕМАХ*

Разработка системы интеллектуальной видеоаналитики, имеющей модули для обнаружения, распознавания и трекинга объектов, привела к осмыслению процесса формирования детекторов объектов различных типов в терминах распознавания информации живыми системами. Система семантического анализа изображений с использованием каскадов сильных классификаторов на основе нелокальных бинарных шаблонов представлена как биоморфная модель структурно-функциональных модулей, например, колонок коры, для обработки информации в живых системах. Предложенную архитектуру многослойной нейронной сети можно отнести к классу «растущих нейронных сетей».

Ключевые слова: *биоморфное моделирование, интеллектуальные системы распознавания, семантический анализ изображений, адаптивный бустинг.*

Введение

В процессе выполнения технической задачи разработки искусственной когнитивной системы семантического анализа изображений создана структурно-функциональная модель нейрональных модулей для обработки информации в живых системах. Детекторы различных объектов строятся на основе растущей многослойной нейронной сети, и визуализирован процесс построения сети – детектора объектов заданного типа.

Цель настоящей работы – представить искусственную когнитивную систему как биоморфную модель структурно-функциональных модулей обработки информации в живых системах. В работе приведено описание

* Данная работа выполнена при поддержке Министерства образования и науки РФ, проект №14.Y26.31.0022.

разработанной системы семантического анализа изображений, и показано, что она устроена по «законам» обработки информации в живых системах.

Система семантического анализа изображений

В настоящее время активно разрабатываются системы интеллектуальной видеоаналитики [1]. Оптическое распознавание любых образов – это обнаружение и идентификация объекта, классификация, определение каких-либо его свойств по поступающему изображению [1, 2]. Среди различных видов классификаций по уровням значимости и сложности выделяется задача семантической классификации зрительных образов [3–6]. Для решения данной задачи используются нейросетевые модели глубокого обучения. Это своеобразные модели рецептивных полей нейронов, на которых строится иерархическая обработка, но параметры сети задаются изначально, и процесс построения детекторов фактически скрыт, реализуется лишь распознавание объектов с определенной точностью [7].

Разработанная система семантического анализа изображений устроена следующим образом. К каждому понятию из словаря в соответствии поставлен каскадный детектор [8], выполненный на основе сильных классификаторов, построенных на базе нелокальных бинарных шаблонов [9]. А свойства объекта определяет детектор атрибутов, также построенный на основе нелокальных бинарных шаблонов (рис. 1) [10, 11].

Признаки, которые используются, определяются как ядро, размером 3x3 элемента, отражающее пространственную структуру изображения. Внутри ядра применятся бинарное кодирование информации {0, 1} и результирующие бинарные шаблоны могут представлять собой границы, отрезки, размером 3x3 элемента. Существуют $2^9 = 512$ подобных ядер (рис. 1). Для кодирования графической информации (рис. 2, а, б) применяются прямоугольные ядра различных размеров.

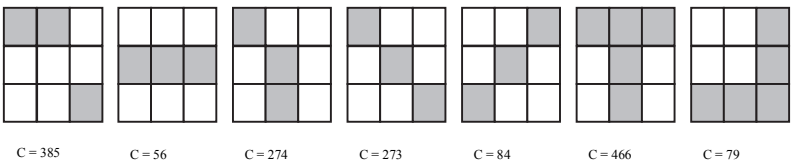

Рис. 1. Примеры бинарных шаблонов (в нейрофизиологических терминах – рецептивных полей), которые используются для кодирования информации на изображении

Обнаружение объектов на изображении осуществляется с использованием техники многокаскадного детектирования. Каждый детектор представляет собой каскад сильных классификаторов, соединённых последовательно (рис. 2, в).

Для обнаружения и распознавания заданных объектов на изображении взят подход, предложенный в работе Виолы и Джонса [8]. При этом для кодирования графической информации применены прямоугольные ядра различных размеров – модифицированное преобразование Цензуса [9].

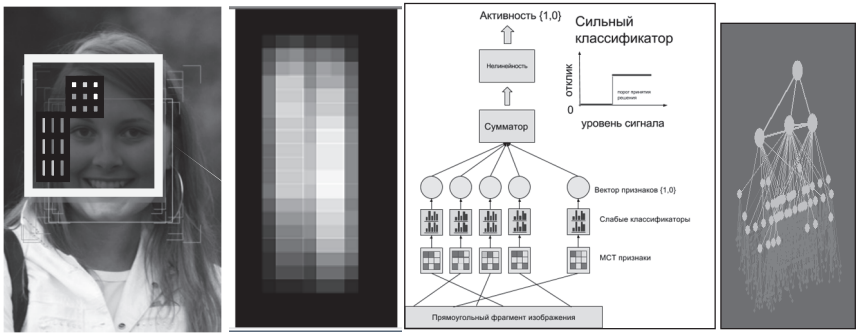

а *б* *в* *г*

Рис. 2. *а* – формирование кодового описания прямоугольной области изображения в белой рамке; *б* – пример наложения прямоугольных решеток 3x3 внутри области апертуры; *в* – схема сильного классификатора; *г* – 3D изображение сформированной в результате обучения сети

Формирование кодового описания изображения поясняется на рис. 2. Область формирования кодового описания разбивается на 9 равных частей, и анализируется средняя яркость $< I_f >$ каждой части по сравнению со средней яркостью всей области формирования кодового описания для глобального бинарного шаблона, который связан со слабым классификатором. Таким образом, любой прямоугольный фрагмент изображения описывается целым числом C, имеющим разрядность 9 бит, т.е. в десятичной системе счисления $0 \le C < 512$. На основе каждого признака, представляющего собой нелокальный бинарный шаблон, создается ***слабый классификатор***, который представляет собой бинарную функцию, принимающую значения {0;1}. Ноль в случае отсутствия искомого объекта в заданной прямоугольной области изображения, 1 – в противном случае.

Для формирования функции активации применяется правило принятия решения на основе «критерия максимального правдоподобия» с использо-

ванием его оценки плотности вероятности значения входного сигнала, полученной при анализе обучающей выборки, при условии, что обучающая выборка представляет собой образцы «полезного сигнала».

Поскольку код имеет целочисленную природу, то оценка плотности вероятности его распределения соответствует гистограмме распределения кодов, полученных в результате анализа обучающей выборки.

С использованием алгоритма обучения AdaBoost [8–11], набора признаков и слабых классификаторов, формируется так называемый ***«сильный классификатор»*** (рис. 2, в), который представляет собой бинарную функцию {0; 1}, включающую в себя порог принятия решения, который определяется в процессе обучения. Процесс обучения выполняет минимизацию ошибки распознавания на обучающей базе данных (1).

$$H_i = \begin{cases} 1, \sum_{k=1}^{n} w_k h_k > \Theta \\ 0, \sum_{k=1}^{n} w_k h_k \le \Theta \end{cases} \quad (1)$$

где h_k – слабый классификатор, w_k – вес слабого классификатора, полученный в процессе обучения с использованием процедуры AdaBoost, n – число слабых классификаторов, Θ – порог принятия решения.

Ключевым элементом системы поиска и распознавания является ***детектор объектов заданного типа.*** Обнаружение объектов на изображении осуществляется с использованием техники каскадного детектирования. Детектор представляет собой каскад сильных классификаторов (рис. 2, в), соединённых последовательно. Одной из задач совершенствования системы распознавания является поиск эффективных детекторов, и этой задачей мы занимаемся [9].

Так как в ходе построения детектора формируется многослойная сеть, мы можем посмотреть на систему семантического анализа как на биологоправдоподобную модель обработки информации в структурно-функциональных модулях коры головного мозга (например, в кортикальных колонках), настроенных на выделение признаков исходного сенсорного сигнала. На модели можно проследить процесс формирования (или активации) восходящих топических связей в модуле и получить результат распознавания – ответ на предъявленный стимул в виде изображения. Послойное построение распознающего модуля визуализируется (рис. 2, г).

Семантический анализ изображений, а именно, обнаружение (детектирование) различных типов изображений в разработанной системе, воспроизводит «срабатывание» кортикальной колонки – детектора, в котором формируются связи в процессе обучения. Распознавание – это реакция на активацию заданным сигналом рецептивного поля колонки. Так как про-

цесс обучения детектора визуализирован, можно наглядно представить формирование колонки – детектора конкретных стимулов: лицо, цифра, число и т.п.

Таким образом, в процессе естественного подхода разработки иерархической системы распознавания на основе многокаскадного детектирования произошла метаморфоза: систему можно интерпретировать как биоморфную модель структурно-функциональных модулей обработки информации в живых системах.

Структурно-функциональная организация процессов обработки информации в мозге

Нейроны представляют собой элементарные обрабатывающие единицы в центральной нервной системе, которые связаны друг с другом. Lorento de No [12], Hubel и Wiesel [13], Mountcastle [14, 15] получили прямые доказательства того, что основной структурно-функциональной единицей в слуховой, зрительной, соматосенсорной областях являются вертикально ориентированная колонки, идущие через все клеточные слои.

Так устроены макроколонки мозга, состоящие из сети нейронов с рецептивными полями, реагирующими на сходные признаки [16, 17]. Диаметр микроколонки $d = 30 \cdot 10^{-6} м$, это 80-100 нейронов, расположенных на пяти клеточных уровнях. Микроколонки объединены в макромодули (макроколонки) $D = 500 - 100 \cdot 10^{-6} м$, содержащие ~ 100 микроколонок. Все клетки в пределах одной микроколонки связаны с одним и тем же рецептивным полем; смежные микроколонки могут быть связаны с разными рецептивными полями. Выходящий из таламуса аксон подходит к 100–300 микроколонкам. Схема на рис. 3.

В статьях [15–18] используется термин «колонка», хотя он для обозначения структурно-функциональной единицы обработки информации вызывает споры [19]. Колонка – это «локальная нервная сеть», представляющая собой интегрированное нейронное объединение, деятельность нейронов которого функционально сопряжена между собой и направлена на решение определенной задачи (достижение определенной функции) [19]. Формирование колонок нейронов в коре головного мозга осуществляется не только за счет нейрогенеза, но за счет поступающей афферентации. Колонка имеет общее сенсорное (рецептивного) пространство и способность кодировать и запоминать информацию [19].

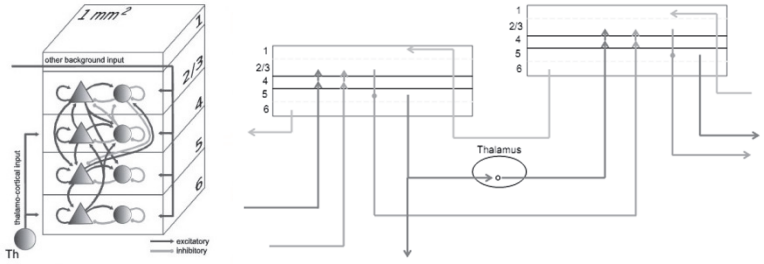

а *б*

Рис.3. *а* – схема связей в одной колонке между слоями коры на шести уровнях. Треугольники – пирамидные клетки. Чёрным цветом показаны возбуждающие связи, серым цветом показаны интернейроны соответствующих уровней коры и тормозные связи. Th – таламус, от которого идут стрелки таламо-кортикальных входов сенсорных сигналов [16]; *б* – две области неокортекса и основные связи между ними, линии обозначают выходные сигналы нейронов различных слоев, то есть пучки их аксонов, многие аксоны почти сразу разделяются на две ветви: одна из них идет горизонтально внутри своей области, и обычно внутри своего слоя в нем горизонтальные связи внутри слоев не показаны на рисунке [18, 26]

Актуальная задача – разработка теории мозга

Сейчас одним из определяющих моментов исследований мозга является стремление понять фундаментальные принципы обработки информации в мозге для создания новых информационных технологий, систем и устройств, использующих принципы работы систем мозга в задачах обработки данных, управления и навигации робототехнических систем.

Развернуто множество глобальных проектов по исследованию мозга в Европе, США, Японии, Китае [21]. Методы исследований мозга развиваются стремительными темпами, число данных и публикаций в области Neuroscience растет. Но пока нет логики для превращения большого количества фактов нейронной активности в теорию [21].

Россия также вступает в программу по исследованию мозга. На повестке создание теории мозга. Необходимо понять структуру мозга как синтез связанных и взаимодействующих между собой функциональных систем [20], которые являются распределенными по огромному количеству нервных клеток в мозге. Для обозначения сети из сетей нейронов, каждая из которых – это функциональная система КОГ (COG) (или когнитивная группа, несущая эволюционные видовые знания или индивидуальные неповторимые знания), К.В. Анохиным введено понятие когнитом

[21–23]. В нейросетевой терминологии, разум – это нейронная гиперсеть, высокопорядковая структура мозга [21–23]. В пользу этого положения говорят, например, результаты нейрофизиологических экспериментов 2019 г.: стимуляция всего нескольких нейронов из когнитивной группы без внешнего стимула способна вызвать избирательное поведение животного [24].

В лекции «Мозг: итоги 2019 года» К.В. Анохин [21] отмечает, что сейчас получаются все новые и новые факты о работе мозга, но понимания и ответа на вопрос, как работа нервных клеток создает мысли, чувства, эмоции, субъективный опыт, пока нет. Нужна теория мозга. В свете перспективной цели создания теории мозга актуальной является задача визуализации работы искусственных нейронных сетей. Например, в Институте перспективных исследований мозга МГУ планируется проект «Прозрачный мозг» [21]. Пройдет еще немного времени – и сети глубокого обучения перестанут быть черным ящиком!

И наша работа формирования биоморфной колонки обнаружения и семантического анализа изображений находится в mainstream этих исследований.

Некоторые биоморфные модели нейронных сетей

В искусственных когнитивных системах моделируются нейроморфные корковые вычисления. Активно развиваются структурные модели нейронных сетей, например, морфогенетические модульные нейронные сети [25]. Устройство кортикальной колонки [14, 15] вдохновляет ученых на разработку различных архитектур технических систем. В работах Hawkins J [26] с помощью разработанной технологии машинного обучения – иерархической темпоральной памяти (Hierarchical Temporal Memory – HTM), которая нацелена на повторение структурных и алгоритмических свойств коры головного мозга, строится система непрерывного обучения и распознавания любых сигналов. HTM – это структурная модель взаимодействующих микроколонок неокортекса (рис. 3б). Для обучения на HTM можно подавать непрерывный потоки данных (аудио, видео сигналы), система будет обучаться, дообучаться, строить модель распознавания данных. Инициализация модели требует задания таких параметров, как количество колоконок, количество синапсов в колонке, пороговое значение срабатывания синапса, параметр перекрытия колонок. Таким образом, модель колонки задается заранее и процесс ее формирования в зависимости от внешнего сигналя (афферентации) скрыт.

Разработанная техническая система семантического анализа изображений [9–11], в основе которой лежат иерархические принципы построения детекторов на основе слабых и сильных классификаторов, является наглядной биоморфной структурно-функциональной моделью процессов передачи и обработки информации в формирующихся колонках коры мозга человека и животных.

Система семантического анализа изображений – биоморфная структурно-функциональная модель кортикальной колонки

Как известно, типичным для неокортекса является наличие шести слоев, которые различаются между собой формой входящих в них клеток и их функциональным назначением, которые сгруппированы во множество колонок (рис. 3) [16]. Предложенную систему семантического анализа изображений можно рассматривать как многослойную нейронную сеть, содержащую входной слой (интегральное изображение), полиморфный слой (кодирование яркости, градиентов, текстуры и цвета), слой слабых классификаторов, слой сильных классификаторов, скрытый слой (обеспечивает пространственную связь решений каскадов сильных классификаторов) и выходной слой (содержит местоположения найденных объектов, их свойства и результаты попиксельной сегментации).

Такое построение системы позволит сравнить ее с модулем обработки информации в живых системах.

Показано, что такая модель из одинаковых элементов, сгруппированных послойно, демонстрирует способность распознавать объекты заданных типов и их свойства (селективность и семантическая классификация изображений), см. рис. 4.

Рис. 4. Отклик двух кортикальных колонок на объекты реального мира различных типов: автомобили и лица людей анфас и в профиль

Визуализация искусственной кортикальной колонки

На рис. 5 приведен один из режимов визуализации работы колонки.

Рис. 5. Визуализация работы искусственной кортикальной колонки. Активные элементы внутреннего слоя отображаются – черные точки среди множества неактивных (серых) элементов; активные элементы пирамидного слоя отображаются черными кружками в верхнем слое

Визуализация работы искусственной кортикальной колонки представляет собой динамический процесс анализа заданного фрагмента изображения, при котором система визуализации отображает активные состояния элементов искусственной кортикальной колонки в текущий момент времени, одновременно с отображением результата ее работы на исходном изображении.

Заключение

Подход к созданию биоморфной модели обработки информации человеком и животными в настоящей работе естественным образом вырос из решения конкретной технической задачи построения системы семантического анализа изображений. Организация системы формирования детекторов различных типов на основе растущей многослойной нейросети с иерархической системой построения сильных классификаторов из слабых классификаторов на основе адаптивного бустинга есть структурно-функциональная модель кортикальной колонки для обработки информации в живых системах. В работе решена задача построения различных детекторов, то есть колонок для выделения различных сигналов, и, что очень важно, визуализирован процесс построения сети – детектора объектов заданного типа.

Создан программный комплекс, который позволяет визуализировать составные части колонки в двумерном и трехмерном представлении. В настоящее время он выполнен в виде приложения под операционную систему Windows10, оснащенного пользовательским интерфейсом и развитой системой визуализации различных элементов искусственной кортикальной колонки. В дальнейшем эту систему предполагается адаптировать к клиент-серверной архитектуре, реализовав вычислительное ядро системы на сервере, а пользовательский интерфейс сделать в виде Web-приложения.

Коллектив авторов благодарит Яхно В.Г. за содержательное обсуждение работы.

Список литературы

1. Торстен А., Иво К., Харальд Л. Видеоаналитика: Мифы и реальность // Security Focus. 2012. 176 с.
2. Ту Д., Гонсалес Р. Принципы распознавания образов. М.: Техносфера, 2012. ISBN: 978-5-94836-331-8 Tu, D., Gonzalez R. Principles of pattern recognition. M .: Tekhnosfera, 2012, ISBN: 978-5-94836-331-8. In Rusian.
3. Smith J.R., S.F.Chang Visualseek: A fully automated content based image query system. In Proc. ACM Multimedia, Boston, MA, Nov, 1996.
4. Milind R.N., T.S.Huang Extracting Semantics from Audiovisual Content: The Final Frontier in Multimedia Retrieval.
5. Дорогов А.Ю., Курбанов Р.Г., Разин В.В. Быстродействующий алгоритм семантической классификации JPEG-изображений //Санкт-Петербургский государственный электротехнический университет (СПбГЭТУ) «ЛЭТИ», 2006.
6. Ritika Hirwane et al. Fundamental of Content Based Image Retrieval / (IJCSIT) International Journal of Computer Science and Information Technologies. 2012. Vol. 3 (1). 3260–3263.
7. http://caffe.berkeleyvision.org
8. Paul A. Viola, Michael J. Jones Rapid Object Detection using a Boosted Cascade of Simple Features// CVPR (1) 2001: P. 511–518.
9. Alexander Telnykh, Irina Nuidel,Yulia Samorodova Construction of efficient detectors for character information recognition // Procedia Computer Science. 2020. Vol. 169. P. 744–754; https://doi.org/10.1016/j.procs.2020.02.170.
10. Bellustin N., Kalafati Y., Kovalchuck A., Telnykh A., Shemagina O., Sharma P., Vaish A.,Verma S. and Yakhno V. «Instant Human Face Attributes Recognition System». International Journal of Advanced Computer Science and Applications (IJACSA), Special Issue on Artificial Intelligence. 20111. P. 112–120.
11. Nikolai Bellustin, Konstantin Moiseev, Olga Shemagina, Sergey Starkov and Aleksandr Telnykh “One Approach to intellectual image analysis”, ITM Web Conf. 2016. 8. 01010.
12. Lorento de No R. Analysis of the activity of the chains of internuncial neurons. // J.Neurophysiol. 1939. V.1. P. 208–217.

13. Hubel D.H., Wiesel T.N. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex // J. Physiol. (Gr. Brit.). 1962. V. 160. N 1. P. 106–154.

14. Mountcastle V.B. Modality and topographic properties of single neurons of cat 's somaticsensory cortex // J. Neurophysiol. 1957. V. 20. N4. P. 408–434.

15. Mountcastle V.B. The columnar organization of the neocortex // Brain. 1997. Vol. 20. № 4. P. 701–722; Jones E.G. Microcolumns in the cerebral cortex // Proc. Natl. Acad. Sci. U. S. A. UNITED STATES. 2000. Vol. 97. № 10. P. 5019–5021.

16. Tobias C. Potjans and Markus Diesmann. The Cell-Type Specific Cortical Microcircuit: Relating Structure and Activity in a Full-Scale Spiking Network Model // Cerebral Cortex. March 2014.24. P.785–806. doi:10.1093/cercor/bhs358.

17. Alex M. Thomson and Christophe Lamy. Functional maps of neocortical local circuitry // Frontiers in Neuroscience. 2007. V. 1, iss. 1. P. 19–42. doi: 10.3389/neuro.01.1.1.002.2007.

18. HIERARCHICAL TEMPORAL MEMORY including HTM Cortical Learning Algorithms VERSION 0.2.1, SEPTEMBER 12, 2011 ©Numenta, Inc. 2011.

19. Комиссаров В.И. Концепция функциональной организации нейронных сетей мозга // Курский научно-практический вестник «Человек и его здоровье». 2005. № 2. С. 30–38.

20. Анохин П.К. Системные механизмы высшей нервной деятельности. М.: Наука, 1979. 453 с.

21. Анохин К. Мозг: итоги года2019 . Лекция от 15.02.2020 // https://www.youtube.com/watch?v=kTVdM-FOPdY

22. Анохин К.В. Коннектом и когнитом: заполнение разрыва между мозгом и разумом // Седьмая международная конференция по когнитивной науке. Тезисы докладов / Ответственные редакторы: Ю. И. Александров, К.В. Анохин. 2016. С. 18–19.

23. Анохин К.В. Когнитом – гиперсетевая модель мозга // http://spkurdyumov.ru/uploads/2018/05/kognitom-gipersetevaya-model-mozga.pdf, опубликовано 16.05.2018

24. LuisCarrillo-Reid, ShutingHan, WeijianYang, AlejandroAkrouh, Controlling Visually Guided Behavior by Holographic Recalling of Cortical Ensembles // Cell, Vol. 178, Issue 2, 11 July 2019, P. 447–457.e5.

25. Дорогов А.Ю. Теория и проектирование быстрых перестраиваемых преобразований и слабосвязанных нейронных сетей. М.: Политехника, 2014. 327 с., ISBN 978-5-7325-1036-2.

26. Hawkins J, Ahmad S and Cui Y (2017), A Theory of How Columns in the Neocortex Enable Learning the Structure of the World.// Front. Neural Circuits 11:81.doi: 10.3389/fncir.2017.00081.

А.А. БОГАТЫРЕВ[1], А.А. БРАНИЦКИЙ[2], Н.П. ВАНЧАКОВА[3], Е.В. ДОЙНИКОВА[2], И.В. КОТЕНКО[2], Н.В. КРАСИЛЬНИКОВА[3], Д.С. ЛЕВШУН[2], А.В. ТИШКОВ[3]

[1]Московский педагогический государственный университет
[2]Федеральный исследовательский центр Санкт-Петербургский институт информатики и автоматизации Российской академии наук
[3]Первый Санкт-Петербургский государственный медицинский университет им. И.П. Павлова
ivkote@comsec.spb.ru

МЕТОДИКИ ВЫЯВЛЕНИЯ И ПРОФИЛАКТИКИ ДЕСТРУКТИВНЫХ ФОРМАТОВ КОММУНИКАТИВНОГО ПОВЕДЕНИЯ МОЛОДЕЖИ В СОЦИАЛЬНЫХ СЕТЯХ*

Исследуется проблема выявления признаков перехода молодежи к деструктивным форматам коммуникативного поведения в социальных сетях и их профилактики. Проблема обнаружения и профилактики деструктивного поведения может быть решена путем выявления его признаков. Предлагается комплексный подход с использованием нейросетей, включающий три основных методики: (1) выявления признаков деструктивных форматов коммуникативного поведения на страницах профилей пользователей социальной сети и вероятностного прогнозирования корреляций профилей с результатами теста Аммона, (2) выявления перехода к деструктивным форматам коммуникативного поведения за счет введения оригинальной семиуровневой шкалы оценивания, а также (3) профилактики деструктивных форматов коммуникативного поведения с использованием психологических и образовательных инструментов. В статье детально рассматривается первая методика. В рамках первой задачи разработан алгоритм вероятностного прогнозирования результатов теста Аммона на основе многослойной нейронной сети. Представлены результаты его работы.

Ключевые слова: *нейронные сети, социальные сети, деструктивные форматы коммуникативного поведения, тест Аммона, вероятностное прогнозирование, молодежь, психолого-педагогическая профилактика, веб-квест, перевернутый класс.*

* Данная работа выполнена при поддержке РФФИ, проект № 18-29-22034 мк.

Введение

В работе рассматривается задача выявления признаков перехода молодежи к деструктивному поведению в социальных сетях и профилактики деструктивного поведения на основе использования нейронной сети. Данное исследование основано на предположении, что некоторые особенности личности могут выражаться в поведении. В качестве объекта исследования выступают деструктивные форматы коммуникативного поведения молодежи в социальных сетях. В качестве материала исследования рассматриваются социальные сети, выступающие как популярное средство общения молодежи. При этом под поведением в социальной сети понимается предоставляемая пользователем информация как в форме сообщения данных о себе, так и при осуществляемом социальном (межличностном) взаимодействии вида «один к одному» (ответ на конкретный комментарий) или «один ко многим» («посты» на стене пользователя в социальной сети). Молодежь рассматривается как социальная группа наиболее уязвимая к деструктивным воздействиям и наиболее подверженная к изменениям в структуре личности, которые необходимо своевременно выявить и предотвратить их дальнейшее развитие. Актуальность комплексного подхода к решению задачи выявления и профилактики деструктивного коммуникативного поведения определяется стремлением государства сформировать психологически здоровое общество – такое, в котором удовлетворены не только основные базовые потребности человека по пирамиде Маслоу, но также и такие группы потребностей, реализуемые через гуманистическую призму, как потребность в принадлежности к социальной группе и коммуникативные потребности, включая разновидности их реализации в цифровой реальности. Это особенно актуально для такой группы молодежи, как будущие врачи, которые должны выстраивать свою деятельность на основании принципов сотрудничества [1], вежливости [2], глубинных гуманистических ценностей и уважения личности и достоинства другого индивида [3, 4, 5], что должно проявляться в коммуникативном поведении личности врача [6].

Для решения поставленной задачи предлагается и разрабатывается комплексный подход, объединяющий следующие методики: (1) вероятностного прогнозирования результатов теста Аммона на основе выявления взаимосвязей между ними и коммуникативным поведением в сети; (2) выявления признаков перехода к деструктивному поведению за счет введения оригинальной семиуровневой шкалы; (3) психолого-педагогическую методику профилактики перехода к деструктивному поведению.

Основная цель проводимого исследования состоит в противодействии деструктивным воздействиям на молодежь в социальных сетях. В то же время, определение полного комплекса воздействий, оказываемых на отдельного пользователя, практически недостижимо. Поэтому предлагаемый подход основан на выявлении наличия деструктивных воздействий на пользователя, которые могут быть ассоциированы с изменением его поведения в социальной сети. Поиск диагностических методик, которые могли бы быть использованы с этой целью, представляется достаточно сложным. Поскольку не создано специализированного адекватного инструментария для понимания изучаемого явления, были апробированы различные виды тестов, чтобы понять, какая из методик может приблизить авторов к изучаемому явлению, однако, не претендуя на исчерпывающее и всеобъемлющее решение задачи по его описанию. В частности, одним из вариантов является Я-структурный тест (предложенный Г. Аммоном) [7]. Методика Аммона показывает совокупность отношений различных психических процессов личности. Следовательно, прямолинейно соотнести результаты, получаемые по опроснику Аммона, и коммуникативное поведение в сетях представляется достаточно сложным и возможно, преждевременным. В данном случае авторами была предпринята попытка. Таким образом, текущее исследование основано на предварительном подходе к оценке коммуникативных проявлений деструктивного характера и манере поведения пользователей в социальных сетях. Выявление изменений в поведении пользователей осуществляется с использованием семиуровневой шкалы оценки эскалации установки индвида к деструктивному поведению (при опоре на использование метода экспертных оценок). Данная шкала также легла в основу определения конструктивных анти-стимулов, направленных на предотвращение перехода к деструктивным форматам коммуникативного поведения в сети.

В рамках первой методики, ввиду того что невозможно протестировать всех пользователей сети Интернет, предлагается вероятностное прогнозирование результатов прохождения тестов путем их соотнесения с определенными маркерами коммуникативного поведения в социальной сети с использованием многослойной нейронной сети. Крайне важно отметить, что такие данные носят исключительно вероятностный характер, и не претендуют на «предсказание поведения», поскольку, как известно из специализированных исследований, предсказать человеческое поведение принципиально невозможно. При этом представляется крайне значимым оценивать вероятностные риски перехода к негативным коммуникативным форматам по той или иной причине, и заниматься их психолого-педагогической профилактикой. В рамках второй методики, ввиду огромного количества про-

филей в социальной сети, также предлагается прогнозирование уровня шкалы перехода к деструктивным форматам коммуникативного поведения в сети, к которому относится профиль пользователя, с использованием нейронных сетей на основе размеченной экспертами выборки.

Данная работа является развитием исследований [8–11].

Постановка задачи и описание подхода

Задача исследования состоит в разработке комплексного подхода, направленного на профилактику перехода молодежи к деструктивному коммуникативному поведению в социальных сетях. Предлагаемый подход предполагает цикл с переходом от диагностических действий и методик к профилактическим. Поскольку сеть Интернет является средством массовой коммуникации, в данном исследовании рассматривается именно коммуникативное поведение пользователя и его различные форматы (конструктивный, нейтральный и деструктивный).

В качестве входных данных, демонстрирующих коммуникативное поведение пользователя, рассматривается информация, предоставляемая пользователями в рамках их профилей в социальных сетях, в том числе, анкетные данные пользователя (число постов, друзей, фотографий и др.), а также т.н. «посты» – публикации, оставляемые пользователем в его профиле, и комментарии к ним. Поскольку невозможно определить весь спектр деструктивных воздействий на пользователя внутри и за пределами социальной сети, была выдвинута гипотеза, что переход пользователя к деструктивному формату коммуникативного поведения можно выявить по изменениям в предоставляемой им в рамках профиля информации. Определение наличия признаков таких изменений является задачей экспертов психологов. Ввиду того, что социальные сети содержат огромное количество информации, и всю ее обработать вручную за ограниченные сроки невозможно, выборка профилей для выявления признаков перехода к деструктивному формату коммуникативного поведения была ограничена пользователями, прошедшими тест Аммона. Данный тест базируется на психоаналитических взглядах, и, как уже отмечалось выше, может продемонстрировать определенный срез языковой личности пользователя. В психологии существует проблема личности и поведения, при этом, объективного исследовательского аппарата для соотнесения личности и поведения не существует. В то же время, существуют отработанные исследовательские тенденции, которые опираются на различные научные школы. Так, любые личностные особенности, в отличие от психических процессов (таких как память, мышление, речь) могут измеряться ориентиро-

вочными тестами. Любой психоаналитический тест (к которым принадлежит тест Аммона) относится к такого рода группе.

Я-структурный тест Аммона содержит 220 вопросов, в зависимости от ответов на которые он отображает деструктивные, дефицитарные и конструктивные проявления по шести личностным функциям, а именно, агрессии, тревоге, внешнему Я-отграничению, внутреннему Я-отграничению, нарциссизму и сексуальности. Важно при этом помнить, что шкалы в данном тесте не интерпретируются отдельно, для изучения важно их сочетание. В рамках данного исследования была предпринята попытка автоматизированного анализа соотнесенности коммуникативного поведения пользователя сети Интернет с возможными особенностями личностных функций по методике Аммона и вероятностного прогнозирования результатов теста Аммона с использованием многослойных нейронных сетей [12–14]. Предложенная методика включает сбор данных из профилей пользователей социальной сети, прошедших тест Аммона; формирование первичного вектора признаков на основе анализа информации, предоставляемой в профиле; и вероятностное прогнозирование результатов теста Аммона с использованием обученных нейронных сетей.

На следующем этапе специалисты психологи использовали профили для определения признаков наличия деструктивных воздействий, при этом учитывалась динамика результатов теста Аммона, пройденного несколько раз с промежутком между прохождениями не менее месяца, а также для определения соответствия профиля одному из уровней предложенной шкалы перехода к деструктивности. Последний этап подхода включает методику профилактики перехода к деструктивному формату поведения в сети с использованием различных педагогических и психолого-педагогических технологий, таких как веб-квест [15], перевернутый класс [16] и многие другие.

Таким образом, предлагаемый подход включает три методики:

(1) методику вероятностного прогнозирования результата теста Аммона, предназначенную для определения первичных признаков перехода к деструктивному формату поведения в сети и предоставления выборки для определения итоговых признаков; необходимо отметить, что данная методика не позволяет определить причинно-следственной связи между определенными форматами поведения в сети и специфическими результатами по тесту Аммона, а также не позволяет отразить объемную и динамично развивающуюся картину взаимоотношений личности и мира, а лишь выявляет выборочные линейные взаимосвязи;

(2) методику выявления признаков перехода к деструктивным форматам коммуникативного поведения в сети, служащую для выявления усо-

вершенствованного набора признаков, а также определения соответствия профиля одному из уровней оригинальной семиуровневой шкалы перехода к деструктивному формату коммуникативного поведения в сети;

(3) методику профилактики перехода к деструктивному формату коммуникативного поведения в сети, задача которой состоит в разработке конструктивных стимулов для профилактики перехода к деструктивному поведению, выявлении целей применения специальных цифровых педагогических технологий, а также, в перспективе, машинному обучению компьютера психолого-педагогической стратегии взаимодействия с пользователем.

В следующем разделе детально рассматривается применение нейронных сетей для реализации первой методики в рамках предложенного комплексного подхода.

Методика прогнозирования результата Я-структурного теста Аммона

Данная методика включает сбор данных из профилей пользователей социальной сети, прошедших Я-структурный тест (предложенный Г. Аммоном) [7]; формирование первичного вектора признаков на основе анализа видов информации, предоставляемой в профиле; и вероятностное прогнозирование результатов теста Аммона с использованием обученных нейронных сетей. Эксперименты проводились с анализом деструктивных, дефицитарных и конструктивных проявлений личностной функции «агрессия» (без учета других Я-функций и их взаимосвязей).

Для проведения экспериментов использовались результаты онлайн-тестирования Аммона среди студентов-медиков. Набор данных для экспериментов содержал 460 записей, описывающих уникальные профили пользователей социальной сети. Записи были помечены 18 шкалами, представляющими собой комбинации 6 Я-функций и 3 компонентов (конструктивный, деструктивный, дефицитарный). Эксперименты проводились только для шкал «агрессия конструктивная», «агрессия деструктивная» и «агрессия дефицитарная».

При проведении экспериментов в качестве классификаторов использовались три типа нейронных сетей: трехслойный перцептрон (ТП), машина опорных векторов (МОВ) и логистическая регрессия (ЛР).

В качестве признаков использовались 55 параметров, описывающих анкетные данные пользователя, а именно: число постов (скаляр), число друзей (скаляр), число фотографий (скаляр), число подписчиков (скаляр), число групп (скаляр), число подписок (скаляр), число видео записей (скаляр), число репостов (скаляр), пол (м/ж), месяц рождения (скаляр), а также степень схожести наиболее часто используемых слов внутри постов каждого класса

(уровня шкалы агрессии), т.е. результат применения word2vec [17] между пятью наиболее употребительными словами, характерными для постов каждого класса (последовательность слов), и наиболее часто используемых слов внутри постов пользовательского профиля, т.е. результат применения word2vec [17] между тремя наиболее употребительными словами в постах анализируемого профиля (последовательность слов).

Результатом работы классификаторов является велична y , принимающая значения от 0 до 100. Применение к y сигмоидной функции активации позволяет получить прогнозируемое значение результата теста Аммона для психологической шкалы «агрессия» (конструктивная, деструктивная, дефицитарная), где $\varphi(y) < 0.33$ соответствует низкому уровню деструктивности, $0.33 \le \varphi(y) \le 0.66$ – среднему уровню, и $\varphi(y) > 0.66$ – высокому уровню. Таким образом, для каждой шкалы выполнялось прогнозирование ее уровня (низкого, среднего, высокого).

Показатель точности оценивался для трех шкал агрессии (конструктивная, деструктивная, дефицитарная).

Результаты прогнозирования представлены в табл. 1, 2, 3, соответственно.

Использование трехблочной кросс-валидации показало, что для шкал «агрессия конструктивная» и «агрессия деструктивная» наилучшими результатами обладает МОВ, а для шкалы «агрессия дефицитная» – ТП.

Таблица 1

Результаты экспериментов для психологической шкалы «агрессия конструктивная»

Классификатор	Точность на обучающей выборке	Точность на тестовой выборке
ТП	59.41 %	51.67 %
МОВ	62.94 %	52.5 %
ЛР	55.59 %	51.67 %

Таблица 2

Результаты экспериментов для психологической шкалы «агрессия деструктивная»

Классификатор	Точность на обучающей выборке	Точность на тестовой выборке
ТП	68.59 %	68.04 %
МОВ	72.51 %	68.05 %
ЛР	70.33 %	66.3 %

Таблица 3

Результаты экспериментов для психологической шкалы «агрессия дефицитарная»

Классификатор	Точность на обучающей выборке	Точность на тестовой выборке
ТП	57.72 %	54.99 %
МОВ	67.72 %	53.92 %
ЛР	59.35 %	51.96 %

Полученные результаты используются на следующих этапах подхода, как входные данные второй методики, и как триггеры профилактики деструктивных воздействий в социальной сети.

Выводы

В работе предложен и реализован подход к выявлению признаков перехода молодежи к деструктивным формам коммуникативного поведения в социальных сетях с использованием нейронных сетей и разработке программы и средств их профилактики, включающий (1) методику выявления признаков деструктивных форматов коммуникативного поведения на страницах профилей пользователей социальной сети, (2) методику выявления признаков перехода пользователя сети к деструктивным форматам коммуникативного поведения и (3) методику профилактики данного явления. В рамках развития первых двух разработанных методик предложен алгоритм на основе многослойной нейронной сети для вероятностного прогнозирования перехода к деструктивным форматам коммуникативного поведения. В настоящее время алгоритм реализован для первой методики и исследуется для второй. Основная сложность состоит в формировании банка репрезентативных признаков для обучения нейронной сети, а также в формировании размеченного набора данных. Программа дальнейших исследований будет включать работу по совершенствованию методов прогнозирования возможных сценариев перехода пользователя сети к деструктивным форматам коммуникативного поведения. С этой целью планируется расширение и тестирование набора признаков и совершенствование алгоритма с использованием нейросети.

Список литературы

1. Grice H.P. Logic and conversation // in: P. Cole and J.L. Morgan (eds.), Syntax and Semantics Vol. 3: Speech Acts. New York: Academic Press, 1975. P. 41–58.

2. Leech G.N. Principles of pragmatics / Geoffrey N. Leech. London; New York: Longman. 1983. XII. 250 p.

3. Hermann H., Trachsel M. Biller-Andorno N. Physician's personal values in determining medical decision capacity: a survey study Journal of Medical Ethics 2015;41:739–744.

4. Andorno R. The dual role of human dignity in bioethics // Medicine and Healthcare in Philosophy. 2002. Vol. 16, No 4B. DOI: 10.1007/s11019-011-9373-5.

5. Rider E.A., Kurtz S., Slade D., Esterbrook Longmaid H., Ming-Jung Ho, Jack Kwok-hung Pun, Eggins S., Branch W.T. Jr. The International Charter for Human Values in Healthcare: An interprofessional Global Collaboration to enhance values and communication in healthcare // Patient education and counseling. 2014. Vol. 96 (3). P. 273–280.

6. Elsner A.M. Medical Humanities /Perception of the patient as a person: Medical Humanities. Collective Monograph / R. Andorno, A.M. Elsner, N.P. Vanchikova, E.A. Vatskel,N. V. Krasilnikova, A.P. Chernyavskaya. Saint-Petersburg, 2019. 208 p.

7. Очерки динамической психиатрии. Транскультурное исследование / Под ред. М.М. Кабанова, Н.Г. Незнанова. СПб.: Институт им. В.М. Бехтерева, 2003. 438 с.

8. Branitskiy A., Levshun D., Krasilnikova N., Doynikova E., Kotenko I., Tishkov A., Vanchakova N., and Chechulin A. Determination of Young Generation's Sensitivity to the Destructive Stimuli based on the Information in Social Networks // Journal of Internet Services and Information Security (JISIS). V. 9. No 3. 2019. P. 1–20. DOI: 10.22667/JISIS.2019.08.31.001. http://isyou.info/jisis/vol9/no3/jisis-2019-vol9-no3-01.pdf.

9. Браницкий А.А., Дойникова Е.В., Котенко И.В. Использование нейросетей для прогнозирования подверженности пользователей социальных сетей деструктивным воздействиям // Информационно-управляющие системы. 2019. № 6.

10. Богатырёв А.А., Ванчакова Н.П., Красильникова Н.В., Гайфулина Д.А., Котенко И.В., Браницкий А.А. Медийный портрет индивида как основа выявления деструктивного стиля взаимодействия молодежи в социальных сетях // Современные наукоемкие технологии. 2019.

11. Красильникова Н.В., Дойникова Е.В., Ванчакова Н.П. Семиуровневая шкала деструктивных проявлений поведения в социальных сетях для мониторинга деструктивных воздействий нейросетевыми методами // Материалы V межрегиональной научно-практической конференции «Перспективные направления развития отечественных информационных технологий». Севастополь, 2019.

12. Cybenko G. Approximation by superpositions of a sigmoidal function // Mathematics of Control, Signals, and Systems (MCSS). 1989. V. 2. No 4. P. 303–314.

13. Funahashi K.I. On the approximate realization of continuous mappings by neural networks // Neural networks. 1989. V. 2. No 3. P. 183–192.

14. Hornik K., Stinchcombe M., White H. Multilayer feedforward networks are universal approximators // Neural networks. 1989. V. 2. No 5. P. 359–366.

15. Тихомирова А.В. Коммуникативный квест как прообраз современной учебной программы по иностранному языку в неязыковом вузе // Problems of modern pedagogics in the context of international educational standards development. Mate-

rials digest of the XL International Research and Practice Conference and I stage of the Championship in Pedagogical sciences., London, January 31 – February 05, 2013, London, 2013. С. 82–84.

16. Чернявская А.П., Ванчакова Н.П., Вацкель Е.А., Барабошина А.А. Самонаправляемое обучение студентов в «Перевернутом классе» // Ярославский педагогический Вестник. 2019. № 2 (107). С. 60–66.

17. Mikolov T. et al. Efficient estimation of word representations in vector space. arXiv preprint arXiv:1301.3781, 2013.

Н.С. ФИЛАТОВ[1,2,*], О.В. ЛИТВИНОВ[2,*], В.Н. УЛАНОВ[2]

[1]Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики, Санкт-Петербург

[2]Санкт-Петербургский Политехнический Университет Петра Великого

n.filatov@rtc.ru

МОДЕЛИ ПРЕДСТАВЛЕНИЯ ЯЗЫКА КАК КЛЮЧЕВОЙ ЭЛЕМЕНТ ДЛЯ АВТОМАТИЧЕСКОГО РЕФЕРИРОВАНИЯ ТЕКСТА[**]

Реферирование текста – это метод обработки естественного языка (NLP), который используется для извлечения ключевых идей из данного документа. Продвинутые методы реферирования должны уметь понимать высокоуровневую семантику в тексте. В этой статье рассматриваются распространенные языковые модели (LM) и фреймворки для обобщения текста на их основе. Показано, что наилучшие показатели качества достигаются с использованием новейших LM. Кроме того, некоторые из рассмотренных платформ подходят для множества задач NLP и могут обучаться без учителя. Поскольку способность учиться и общаться на естественном языке является важной характеристикой сильного искусственного интеллекта (AGI), эти исследования имеют большое значение для его развития.

Ключевые слова: *автоматическое реферирование текста, языковая модель, обработка естественного языка.*

[*] Авторы внесли равный вклад.

[**] Работа проводилась в рамках выполнения государственного задания Минобрнауки России № 075-01195-20-00 «Разработка и исследование новых архитектур реконфигурируемых растущих нейронных сетей, методов и алгоритмов их обучения».

Введение

Автоматическое реферирование текста является одним из важных методов обработки естественного языка (NLP), который позволяет получить документ, кратко отражающий основную информацию из оригинального документа. В настоящее время информация доступна в изобилии по многим темам в Интернете, поэтому обобщение может быть полезным для многих целей, включая мониторинг СМИ, ответы на вопросы и системы рекомендаций. Тем не менее, методы обобщения текста также, по-видимому, важны для развития сильного искусственного интеллекта (AGI), так как они необходимы для общения на естественном языке и обучения на читаемых человеком ресурсах. Первые подходы к этой задаче использовали статистические языковые модели (LM). С развитием нейросетевых LM большинство достижений было достигнуто. Таким образом, в этой работе показано, что предварительно обученная модель представления языка (LRM) является ключевым элементом для качественного реферирования текста.

Задача реферирования текста, различные подходы

Задача реферирования текста в основном делится на два типа: выборочное реферирование с целью выбора только наиболее важного подмножества предложений из исходного текста и абстрактное реферирование, целью которого является создание более короткого текста с новыми предложениями, описывающими основные идеи исходного документа. Последний подход требует обширного применения методов NLP для получения свободно читаемого текста.

Следовательно, абстрактное реферирование является более сложной задачей, и большинство работ посвящено выборочному реферированию [1].

В некоторых ранних работах по выборочному реферированию использовались такие признаки предложений, как позиция в тексте, наличие положительных или отрицательных ключевых слов центральность предложения, сходство, относительная длина предложения и т. д. [2]. Эти признаки затем используются для построения моделей на основе математической регрессии, генетических алгоритмов или вероятностных нейронных сетей. Также были представлены подходы, основанные на графах, деревьях решений и правилах [3]. Позднее для извлечения независимых текстовых признаков были применены сверточные нейронные сети [4]. Этот подход показал, что извлечение признаков из текста с помощью сверточной нейронной сети ведет к более качественному реферированию в кон-

тексте применения регрессии. Дальнейшее улучшение было достигнуто с использованием архитектуры энкодер-экстрактор с использованием рекуррентных нейронных сетей (RNN). В [5] иерархическая структура документа кодируется кодировщиками на уровне предложения и на уровне текста на основе двунаправленных упорядоченных рекуррентных блоков (GRU). Для извлечения предложений используется комбинация другой сети GRU и многослойного персептрона.

Большинство из этих работ были протестированы на наборе данных DUC 2004, который содержит 500 статей и их кратких рефератов, написанных людьми. Однако DUC 2004 относительно невелик по сравнению с недавно введенным (2015 г.) набором данных CNN / Daily Mail [6], состоящим из 300 000 обучающих пар. Обычно для оценки качества реферирования текста используется метрика ROGUE (Recall-Oriented Un-derstudy for Gisting Evaluation) [7]. Эта метрика сравнивает автоматически созданные рефераты с идеальными, созданными людьми, путем вычисления числа перекрывающихся n-грамм, последовательностей слов и пар слов. Исследовательские работы обычно сравниваются с использованием следующих показателей:

1. ROUGE-1 (R1) – перекрытие униграмм между рефератами;
2. ROUGE-2 (R2) – перекрытие биграмм между рефератами;
3. ROUGE-L (RL) – самая длинная общая последовательность.

Однако вышеупомянутые метрики не учитывают такие аспекты качества, как лингвистическая целостность, и в основном полагаются на лексическое совпадение, которое может помешать правильной оценке абстрактных рефератов. Поэтому исследования проводят другие процедуры оценки в дополнение к метрикам ROUGE.

Достижения в реферировании текста с использованием предварительно обученных языковых моделей

Предварительно обученные LRM полезны во многих задачах NLP, в связи с их недавним развитием, большая часть работ, выполненных на тему реферирования текста основана на LRM. В этой главе рассматриваются распространенные LM и фреймоврки для реферирования текста на их основе. Развиваясь из Word2Vec [8] и GloVe [9], в которых использовалось фиксированное представление для каждого слова, LRM, такие как ELMo [10] обучаются получать контекстуальное представление слов, предварительно обучая LM (двунаправленный LSTM для ELMo) без учителя.

Следуя аналогичной идее ELMo, OpenAI GPT [11] расширяет обучаемую без учителя LM, обучаясь на обширной коллекции корпусов текста. Несмотря на схожесть, GPT имеет два основных отличия от ELMo:

1. Архитектуры моделей различаются: ELMo использует неглубокую конкатенацию независимо обученных слева направо и справа налево многослойных LSTM, а GPT – это многослойный декодер.

2. Использование контекстуальных векторных представлений для практических задач различается. ELMo передает векторные представления в модель, преобразуемую для практических задач, в качестве признаков, в то время как GPT перенастраивает базовую модель для всех видов конкретных задач.

Языковая модель ELMo была двунаправленной, но OpenAI Transformer обучает только однонаправленную LM, эта проблема была решена в BERT [12]. По сравнению с GPT, самое большое отличие и улучшение BERT заключается в том, чтобы сделать обучение двунаправленным. Модель учится предсказывать оба контекста слева и справа. По мнению авторов, двунаправленный характер их модели является единственным наиболее важным новым вкладом.

Для задачи выборочного реферирования представлены следующие работы. В [13] документ передавался в модель BERT для предсказания выходного представления, а затем с помощью метода K-средних представления кластеризовались , чтобы выбрать векторные представления предложений, которые были ближе всего к центроиду, в качестве предложения кандидата для реферирования. Преимущество этого подхода заключается в том, что он может создавать рефераты текста не используя обучение с учителем.

В работе [14] во время предварительного обучения были добавлены адаптации для изучения представлений предложений (в оригинальном BERT представления создаются для токенов вместо предложений). Модель выборочного реферирования строится путем объединения предварительно обученного кодировщика (BERT) с простым классификационным слоем или со слоями RNN и Transformer [15] для лучшего захвата функций на уровне документа (наиболее результативная модель со слоем Transformer была названа BertSumExt). Для абстрактного реферирования используется стандартная структура кодировщик-декодировщик [16] с тем же кодировщиком, декодировщик представляет собой 6-уровневый Transformer, инициализированный случайным образом. Сравнительный по метрике ROGUE график алгоритмов реферирования, рассмотренных в этой работе, показан на рис. 1.

Подходы к абстрактному реферированию на основе нейронных сетей рассматривают задачу как задачу «из последовательности в последовательность», где целевые рефераты содержат слова или фразы, которые необязательно находятся в исходном тексте. В отличие от более ранних работ, многие из рассмотренных методов способны выполнять как абстрактное, так и выборочное реферирование.

Исследование [17] является одним из первых, которое расширило BERT до задачи генерации последовательности. В этой работе BERT используется как в кодировщике, так и в двухступенчатом декодировщике модели «из последовательности в последовательность» для абстрактного реферирования текста. Кодировщик используется для получения представления документа. Декодировщик работает в два этапа: на первом этапе декодировщик на основе Transformer используется для генерации чернового реферата. На втором этапе каждое слово чернового реферата маскируется и подается в BERT, затем путем объединения входной последовательности и чернового представления, генерируемого BERT, используется декодировщик на основе Transformer для прогнозирования уточненного слова для каждой маскированной позиции. Уточняющий декодировщик выполняет задачу на уровне слова, аналогичную задаче в процессе предварительного обучения BERT, поэтому декодировщик может генерировать более связные и естественные последовательности. Дискретная цель, оптимизированная с помощью обучения с подкреплением (RL), была добавлена в модель. Это решило проблему несоответствия ROUGE (метрика оценки) и логарифмической функции правдоподобия (использовалась во время обучения), что повлияло на качество работы модели.

В [18] показано, что LM получают возможность обучаться задачам НЛП (включая реферирование текста) без какого-либо явного контроля, обучаясь на новом наборе данных из миллионов веб-страниц. Чтобы способствовать обучению реферированию, после текста были добавлены «TL; DR» и случайно выбранные токены. Полученные результаты позволяют предположить, что обучение без учителя является дополнительной перспективной областью исследований. Однако, будучи ценным научным результатом, модель GPT-2 по качеству далека от практического применения.

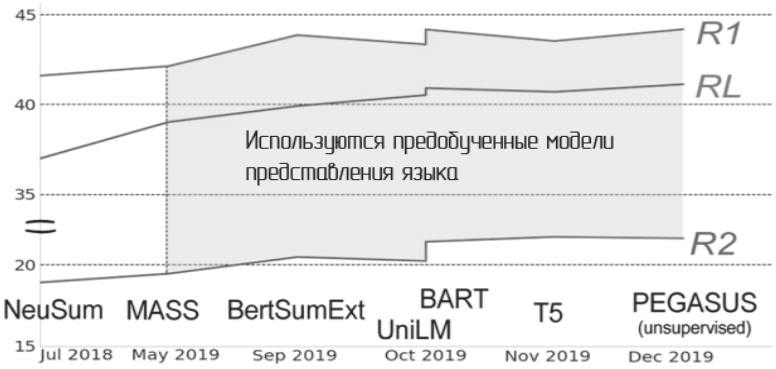

Рис. 1. Метрики ROUGE для последних современных моделей реферирования текста на наборе данных CNN / Daily Mail

В [19] была предложена модель MASS: предварительное обучение маскированных последовательностей для задач генерации языка, которое восстанавливает один случайно выбранный фрагмент предложения с учетом оставшейся части предложения в структуре кодировщик-декодировщик. Кодировщик считывает исходную последовательность и генерирует набор представлений; декодер оценивает условную вероятность каждого целевого токена с учетом исходных представлений и его предшествующих токенов. Механизм внимания [15] дополнительно вводится между кодеровщиком и декодервщиком, чтобы найти, на каком исходном представлении сосредоточиться при предсказании текущего токена. MASS был первым предварительно обученным методом «из последовательности в последовательность», не основанном на BERT, который достиг значительных результатов в реферировании.

UniLM [20] совместно обучается на трёх типах задач для языковых моделей: однонаправленных (слева направо и справа налево), двунаправленных (маска на уровне слова, с предсказанием следующего предложения) и «из последовательности в последовательность» (маски на уровне слов). Этот комбинированный подход также улучшил метрику ROUGE на CNN/Daily Mail.

T5 [21] это унифицированная структура, которая преобразует каждую языковую проблему в задачу «из текста в текст». Эта структура показала преимущество увеличения размера модели (до 11 миллиардов параметров) и предтренировочного корпуса. T5 был предварительно обучен с использованием случайным образом поврежденных участков текста с различными соотношениями масок и размерами участков.

BART [22] представил шумоподавляющий автоэнкодер для предварительной тренировки моделей «из последовательности в последовательность». BART использует текст, искажённый двумя способами: случайным образом перетасовывая порядок оригинальных предложений; используя новую схему заполнения, где участки текста заменяются одним токеном маски и учатся восстанавливать исходный текст. Для задач генерации шумовой функцией производилось заполнение текста, которое использовало одиночные маски для токенов для маскировки произвольно выбранных участков текста.

PEGASUS [23] решает проблему, связанную с тем, что предварительно обученные Transformers должны быть дополнительно обучены для последующих задач NLP, включая реферирование текста. В работе предложено предварительное обучение без учителя на массивных текстовых корпусах больших моделей вида кодировщик-декодировщик на базе Transformer. Основная идея - маскировать или удалять целые предложения из документа и генерировать эти пропуски из остальной части документа хорошо подходит для предварительной подготовки к задачам последующего реферирования. Этот подход является наиболее результативным в большинстве разнообразных задач реферирования.

Заключение

Использование предварительно обученных языковых моделей стало распространенным явлением в недавних исследованиях, показывающих наилучшие результаты. Применение моделей представления языка в методах реферирования текста не только улучшает результаты, но и делает эти методы пригодными для абстрактного реферирования во многих случаях. Более того, некоторые из этих фреймворков способны обучаться различным задачам NLP без учителя, что представляет значительный интерес для развития сильного искусственного интеллекта.

Список литературы

1. Gambhir M., Gupta V. Recent automatic text summarization techniques: a survey // Artif Intell Rev. 2017. Vol. 47. № 1. P. 1–66.

2. Fattah M.A., Ren F. GA, MR, FFNN, PNN and GMM based models for automatic text summarization // Computer Speech & Language. 2009. Vol. 23. № 1. P. 126–144.

3. Gupta S., Gupta S.K. Abstractive summarization: An overview of the state of the art // Expert Systems with Applications. 2019. Vol. 121. P. 49–65.

4. Cao Z. et al. Learning Summary Prior Representation for Extractive Summarization // Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing

(Volume 2: Short Papers). Beijing, China: Association for Computational Linguistics. 2015. P. 829–833.

5. Zhou Q. et al. Neural Document Summarization by Jointly Learning to Score and Select Sentences // arXiv:1807.02305 [cs]. 2018.

6. Hermann K.M. et al. Teaching Machines to Read and Comprehend // arXiv:1506.03340 [cs]. 2015.

7. Lin C.-Y. ROUGE: A Package for Automatic Evaluation of Summaries // Text Summarization Branches Out. Barcelona, Spain: Association for Computational Linguistics. 2004. P. 74–81.

8. Mikolov T. et al. Distributed Representations of Words and Phrases and their Compositionality // Advances in Neural Information Processing Systems 26 / ed. Burges C.J.C. et al. Curran Associates, Inc. 2013. P. 3111–3119.

9. Pennington J., Socher R., Manning C. Glove: Global Vectors for Word Representation // Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha, Qatar: Association for Computational Linguistics. 2014. P. 1532–1543.

10. Peters M.E. et al. Deep contextualized word representations // arXiv:1802.05365 [cs]. 2018.

11. Radford A. et al. Improving Language Understanding by Generative Pre-Training. 2018. P. 12.

12. Devlin J. et al. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers). Minneapolis, Minnesota: Association for Computational Linguistics. 2019. P. 4171–4186.

13. Miller D. Leveraging BERT for Extractive Text Summarization on Lectures. P. 7.

14. Liu Y., Lapata M. Text Summarization with Pretrained Encoders // arXiv:1908.08345 [cs]. 2019.

15. Vaswani A. et al. Attention Is All You Need // arXiv:1706.03762 [cs]. 2017.

16. See A., Liu P.J., Manning C.D. Get To The Point: Summarization with Pointer-Generator Networks // arXiv:1704.04368 [cs]. 2017.

17. Zhang H., Xu J., Wang J. Pretraining-Based Natural Language Generation for Text Summarization // arXiv:1902.09243 [cs]. 2019.

18. Radford A. et al. Language models are unsupervised multitask learners // OpenAI Blog. 2019. Vol. 1. № 8. P. 9.

19. Song K. et al. MASS: Masked Sequence to Sequence Pre-training for Language Generation // arXiv:1905.02450 [cs]. 2019.

20. Dong L. et al. Unified Language Model Pre-training for Natural Language Understanding and Generation // arXiv:1905.03197 [cs]. 2019.

21. Raffel C. et al. Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer // arXiv:1910.10683 [cs, stat]. 2019.

22. Lewis M. et al. BART: Denoising Sequence-to-Sequence Pre-training for Natural Language Generation, Translation, and Comprehension // arXiv:1910.13461 [cs, stat]. 2019.

23. Zhang J. et al. PEGASUS: Pre-training with Extracted Gap-sentences for Abstractive Summarization // arXiv:1912.08777 [cs]. 2019.

В.А. ДЕМАРЕВА
Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского
kaleria.naz@gmail.com

ХАРАКТЕРИСТИКИ ФИКСАЦИЙ ГЛАЗ НА СЛОВАХ РАЗНОГО СЕМАНТИЧЕСКОГО КЛАССА ПРИ ЧТЕНИИ НА АНГЛИЙСКОМ ЯЗЫКЕ КАК ОТОБРАЖЕНИЕ УРОВНЯ ЯЗЫКОВОЙ КОМПЕТЕНЦИИ*

Рассматривается задача подбора паттернов движений глаз при чтении текстов, отличающих людей с разным уровнем владения иностранным языком. Анализируется специфика восприятия слов разных семантических классов при чтении текстов на иностранном языке и ее связь с уровнем языковой подготовки человека. Предложена психофизиологическая основа для построения классификатора, позволяющего идентифицировать в выборке людей, которые профессионально осваивают иностранный язык.

Ключевые слова: *движения глаз, чтение, языковая компетенция, иностранный язык, классификация.*

Введение

Для носителей разных языков существует сходство в движениях глаз во время чтения и сходство во влиянии лингвистических эффектов на движение глаз. Это универсальные особенности при чтении. Например, лингвистический эффект частоты свойственен многим языкам, те слова, которые встречаются чаще, читаются быстрее, чем более редкие. Также эффект длины слов существует во многих языка, длинные слова занимают больше времени на прочтение, чем короткие. Наконец, слова, являющиеся предсказуемыми на основе предыдущего контекста, читаются быстрее, чем те, которые менее предсказуемы. Тот факт, что эффект частоты слов, длины слов и их предсказуемости («большая тройка» чтения» [3]) встречается во всех языках, обеспечивает очевидность более общего предположения о схожести обработки слов во время чтения на разных языках [4].

Эффект частотности слов (связь между частотностью слова и временем его обработки), – одно из важнейших открытий психолингвистики.

* Данная работа выполнена при поддержке РФФИ, проекты № 18-013-01169, № 18-013-01225.

Это подтверждают результаты множества исследований на разном языковом материале, в различных экспериментальных парадигмах. К примеру, Мак Каск и соавторы предположили, что обработка высокочастотных слов происходит «напрямую» посредством визуальной репрезентации, в то время, как низкочастотные слова воспринимаются на основе фонологического декодирования [5]. Результаты некоторых нейролингвистических исследований показывают, что процесс декодирования зависит не только от частотности слова, но и от класса слова.

Представители английской лингвистической школы разделяют части речи на «открытые» (знаменательные) и «закрытые» (функциональные) классы по критерию способности лексем к словообразованию. «Закрытый» класс включает в себя артикли, указательные местоимения (demonstrative), местоимения, предлоги, союзы и междометия [7]. «Закрытые» и «открытые» слова выполняют разные лингвистические функции [1].

Очевидным является наличие некоторой связи между частотностью слова и его классом. Лингвистические исследования восприятия «открытых» и «закрытых» слов с разной частотностью 1980-х гг. показали, что частотность слова влияет на время его обработки для «открытых» слов, но не для «закрытых». При этом, у больных с афазией Брока эффект частотности выражен для слов обоих классов. Те же закономерности были получены и в исследовании больных с афазией Вернике. Данные факты свидетельствуют о том, что у больных с афазией обработка «закрытых» слов происходит по тому же алгоритму, что и «открытых». Это позволяет предполагать, что существует две системы: «общая» частотночувствительная и «специализированная», или «интенсивная», которая управляет обработкой «закрытых» слов [2].

Предположение, что в обработке слов разных классов участвуют разные нейронные системы, было опровергнуто в работе Мюнте и соавт. [6]. Потенциал N400 во фронтальных отделах левого полушария был значимо менее выражен при чтении «закрытых», чем «открытых» слов при одинаковой частотности. Фронтальная негативность 400 мс была зафиксирована только для очень высокочастотных «закрытых» слов. В исследовании [6] показано, что потенциал N400 во фронтальных отделах левого полушария не отличается при работе с «закрытыми» и «открытыми» словами, что может означать отсутствие специфичности зон мозга в обработке слов разных классов. Эффект N400-700 может быть связан с особыми грамматическими функциями, выполняемыми некоторыми «закрытыми» словами (например, определителями).

Тем не менее, класс слов влияет на паттерны внимания при чтении, которые проявляются в большем количестве фиксаций на «открытых» сло-

вах; фиксации на «закрытых» словах, как правило, отсутствуют или являются менее длительными. Показано, что при чтении текста на родном языке, примерно 15 % «открытых» и около 65 % «закрытых» слов пропускаются [8]. При этом, на «закрытом» слове могут делаться длительные фиксации в случае, если в данный момент происходит обработка последующего «открытого» слова, которое находится в парафовеолярной области воспринимаемого диапазона.

Таким образом, данные исследований динамики движения взора при чтении показывают, что «закрытые» слова часто пропускаются. Если же на них и появляются фиксации, то это часто связано с саккадической ошибкой и рефлексивными саккадами, направленными на чтение соседних «открытых» слов [8]. В целом, в психофизиологических исследованиях продемонстрировано, что обработка «открытых» и «закрытых» слов предполагает разные механизмы, которые до сих пор не ясны.

При этом все исследования специфики восприятия слов разных классов проводились только при чтении текстов на родном языке, и нет данных об особенностях чтения «закрытых» слов и слов с разной частотностью на иностранном языке и их связи с уровнем языковой подготовки человека.

Материалы и методы исследования

Выборка исследования. В исследовании приняли участие студенты-психологи ФСН ННГУ им. Лобачевского (11 человек), и студенты-лингвисты НГЛУ им. Добролюбова, получающие профессиональное лингвистическое образование (22 человека). Все добровольцы имели нормальное или скорректированное до нормального зрение.

Стимульный материал. В качестве стимулов использовались тексты вопросов из теста на определение уровня знания языка.

Процедура эксперимента. Перед проведением измерений испытуемым давалась следующая инструкция: «Сейчас Вам будет необходимо ответить на вопросы тестов по английскому языку. На слайде Вам будет предъявлен текст вопроса. Прочитайте его внимательно, когда прочитаете, посмотрите в правый нижний угол экрана. Запоминать текст вопроса не нужно. На третьем слайде Вам будет еще раз предъявлен текст вопроса и варианты ответов на него. Выберете правильный вариант ответа и запомните его номер. На следующем слайде посмотрите только на ту цифру, которая соответствует номеру правильного варианта ответа».

Процедура заключалась в предъявлении вопросов на английском языке. Предъявлялись 9 вопросов теста по английскому языку.

В рамках данного исследования анализировалась траектория движения взора при чтении тестовых предложений. Каждое «закрытое» слово было обозначено как самостоятельная зона интереса «Area of Interest» (AOI) в модуле BeGaze.

Главной независимой переменной выступал профиль обучения студентов: лингвистический и психологический (фактор «профиль»). Также в ходе анализа вводился дополнительный предиктор - тип «закрытого» слова (the, you, what, I, at, to, that, it, if, a, their, so, my, of, in, not) – фактор «Area of interest». Анализировались только те закрытые слова в позиции n, рядом с которыми (в позициях n + 1 и n – 1) не находится другое слово из того же класса. Анализ проводился отдельно для каждой зависимой переменной: длительность первой фиксации, суммарная продолжительность фиксаций, средняя длительность фиксации, количество фиксаций, наличие/отсутствие фиксации на «закрытом» слове.

Использовался однофакторный и многофакторный дисперсионный анализ, кластерный анализ методом К-средних. Все массивы данных проверялись на нормальность по критерию Колмогорова-Смирнова.

Результаты и их обсуждение

1. Доля зафиксированных «закрытых» слов при чтении.

При анализе наличия/отсутствия фиксаций на «закрытых» словах было выявлено, что в среднем делаются фиксации на 38 % «закрытых» слов. При этом лингвисты делают фиксации на 33 % слов, а психологи – на 48 %. Получено, что 55 % из выборки лингвистов и 0 % из выборки психологов сделали фиксации менее чем на 30% «закрытых» слов.

Влияние фактора «профиль» на наличие/ отсутствие фиксации на «закрытом» слове с учетом фактора «Area of interest» оказалось незначимым ($F(15, 706) = .76$, $p = .72$). При этом выявлено, что лингвисты достоверно чаще делают пропуск на словах «the» и «what» ($p < 0,05$).

2. Анализ длительности первой фиксации.

При однофакторном дисперсионном анализе было получено, что фактор «профиль» обучения значимо влияет на длительность первой фиксации на «закрытых» словах при чтении ($F(1, 736) = 22.01$, $p < .001$).

Таким образом, у студентов, получающих специализированную лингвистическую подготовку, длительность первой фиксации значимо меньше, чем у студентов, не имеющих опыта изучения английского языка помимо стандартной школьной программы.

3. Анализ общего времени фиксаций.

В ходе дисперсионного анализа выяснилось, что фактор «профиль» обучения значимо влияет на общее время фиксаций на «закрытых» словах при чтении ($F(1, 736) = 7.54$, $p < .01$). Общее время просмотра «закрытых» слов у студентов-лингвистов значимо меньше, чем у студентов-психологов.

4. Анализ средней продолжительности фиксаций.

Фактор «профиль» обучения значимо влияет на общее время фиксаций на «закрытых» словах при чтении ($F(1, 736) = 23.16$, $p < .001$). Средняя длительность фиксаций на «закрытых» словах студентов-лингвистов значимо меньше, чем у студентов-психологов.

5. Анализ количества фиксаций.

Фактор «профиль» обучения значимо влияет на количество фиксаций на «закрытых» словах при чтении ($F(1, 736) = 4.67$, $p < .05$). У студентов-лингвистов количество фиксаций на «закрытых» словах значимо меньше, чем у студентов-психологов.

6. Кластеризация выборки по параметрам айтрекинга.

При классификации методом К-средних было получено, что по двум параметрам (количество фиксаций и общее время фиксаций) вся выборка разделяется на 3 кластера – табл. 1.

Таблица 1

Основные результаты кластеризации выборки

Кластер	Профиль	Количество фиксаций	Общее время фиксаций	N случаев
1	лингвист	0.25±0.24	42.33±40.12	17
2	лингвист	1.40±0.40	274.78±137.48	5
3	психолог	0.64±0.45	122.57±87.50	11

Используя описательные статистики кластеров, возможен отбор из выборки только студентов-лингвистов с чувствительностью 0.5 и надежностью 0.78.

Таким образом, в исследовании было выявлено, что при чтении текста на иностранном (английском) языке русскоязычные студенты-лингвисты делают фиксации на 33 % «закрытых» слов, а психологи – на 48 %. При этом, в литературе показано, что при чтении текста на родном языке примерно 65 % «закрытых» слов пропускаются [8]. Следовательно, мы выявили, что студенты, имеющие специализированную лингвистическую подготовку, используют при чтении текста на иностранном языке схожую модель чтения, что и при работе с текстом на родном языке.

Результат о меньшей длительности первой, средней и всех фиксаций на «закрытых» словах у студентов-лингвистов также согласуется с лите-

ратурными данными о том, что при чтении текста на родном языке фиксации на «закрытых» словах обычно отсутствуют или являются менее длительными, чем на «открытых» [9]. Это также подтверждает, что студенты, которые профессионально осваивают английский язык, читают иноязычные тексты, используя модель работы с вербальными стимулами на родном языке.

Выводы

Полученные в исследовании результаты свидетельствуют о том, что по мере профессионального изучения иностранного языка, происходит перенос модели языковой деятельности в условиях родного языка на условия иностранного языка.

Результаты, полученные в наших исследованиях, свидетельствуют в пользу возможности создания инструмента оперативной оценки языковой компетенции с опорой на объективные параметры движения глаз.

Список литературы

1. Рянская Э.М. К вопросу о соотношении лексики и грамматики в языке // Вестник НВГУ. 2008. № 4. С. 42–47.

2. Bradley D.C., Garrett M.F., Zurif E.B. Syntactic deficits in Broca's aphasics. In: Caplan D (ed) Biological studies of mental processes. Cambridge, Massachusetts: MIT Press. 1980. P. 269–286.

3. Clifton C.E., Ferreira F., Henderson J.M., Inhoff A.W., Liversedge S., Reichle E.D., Schotter E.R. Eye movements in reading and information processing: Keith Rayner's 40 year legacy // Journal of Memory and Language. 2016. V. 86. P. 1–19.

4. Li. X., Bicknell, K., Liu, P., Wei, W., Rayner, K. Reading is fundamentally similar across disparate writing systems: A systematic characterization of how words and characters influence eye movements in Chinese reading. // Journal of Experimental Psychology: General. 2014. V. 143. P. 895–913.

5. McCusk K., Hillinger M.L., Bias R.G. Phonological recoding and reading // Psycho- logical Bulletin. 1981. No 89. P. 217–245.

6. Münte T.F., Weyerts H., Wieringa B.M., Szentkuti A., Matzke M., Johannes S. Differences in brain potentials to open and closed class words: class and frequency effects // Neuropsychologia. 2001. No 39 (1). P. 91–102.

7. Pennebaker J.W., Chung C.K, Frazee J., Lavergne G.M., Beaver D.I. When Small Words Foretell Academic Success: The Case of College Admissions Essays // PLoS ONE. 2014. No 9(12). e115844.

8. Rayner K, Pollatsek A., Drieghe D., Slattery T.J., Reichle E.D. Tracking the mind during reading via eye movements: Comments on Kliegl, Nuthmann, and Engbert // Journal of Experimental Psychology: General. 2007. No 136 (3). P. 520–529.

9. Segui J., Frauenfelder U.H., Lainé C., Mehler J. The word frequency effect for open- and closed-class items // Cognitive Neuropsychology. 1987. No 41 (1). P. 33–44.

ИМЕННОЙ УКАЗАТЕЛЬ АВТОРОВ

– B –

Bartsev S.I., 72
Basarab M., 324
Belousov E.A., 11

– C –

Chernenkiy V.M., 11

– G –

Gapanyuk Y.E., 11

– I –

Ivanov I., 324

– K –

Kharlamov A.A., 241
Konnova N., 304
Kulikova S.P., 120
Kuznetsov V.V., 165

– L –

Lunin B., 324

– M –

Malykhina G.F., 82
Markova G.M., 72
Moskalenko V.A., 165

– P –

Pilgun M., 241
Popov I.A., 11

– R –

Rudnev N., 225

– S –

Salnikov V.Y., 82
Samsonovich A.V., 351
Semenyutin V.B., 82
Shats Vladimir N., 127
Shiriyazdanov R., 225

– T –

Tikhomirova D.V., 351

– U –

Ustyuzhanin K., 225

– Z –

Zolotykh N.Yu., 165

– А –

Агеев А.В., 259
Алексеева А.Н., 359
Ашина Н.П., 183

– Б –

Богатырев А.А., 388
Божокин С.В., 54
Браницкий А.А., 388

– В –

Ванчакова Н.П., 388
Вечкапова С.О., 103
Воронков Г.С., 112

– Г –

Галкин М.В., 359
Голубева Д.Н., 37
Горбань А.Н., 183

– Д –

Данилов Г.В., 359
Демарева В.А., 405
Демин В.А., 155
Дойникова Е.В., 388
Дорогов А.Ю., 134, 214

– Е –

Емельянов А.В., 155

– Ж –

Жданов А.А., 18, 174

– З –

Забелин А.Н., 250
Запара Т.А., 64

– И –

Изотов В.А., 112

– К –

Каверина М.Ю., 359
Каганова И.М., 144
Карандашев Я.М., 269
Кашкаров П.К., 155
Котенко И.В., 388, 388
Красильникова Н.В., 388
Кропотов Ю.Д., 367
Кроткова О.А., 359
Крыжановский Б.В., 144
Кузнецов А.А., 93

– Л –

Лавренков Ю.Н., 313
Лавров В.В., 204
Лавров Н.В., 204
Левшун Д.С., 388
Липкович М., 367
Литвинов О.В., 397
Литвинов О.С., 250, 269
Литинский Л.Б., 144
Лукашов А.И., 294

– М –

Мазуров М.Е., 232
Майоров В.И., 27, 45
Малахин И.А., 64
Малкин С.Л., 37
Малыхина Г.Ф., 333
Марьясин О.Ю., 294
Масленников О.В., 195
Мацукатова А.Н., 155
Микрюков А.А., 232
Миннеханов А.А., 155
Муродьянц Д.В., 269
Мяэ М.А., 333

– Н –

Некоркин В.И., 195
Несмелов А.А., 155
Никифоров М.Б., 277
Нуйдель И.В., 183, 377

– П –

Парин С.Б., 183
Пермяков С.А., 93
Плотников С.А., 367
Полевая С.А., 183
Проскура А.Л., 103

– Р –

Ратушняк А.С., 64, 103
Рыльков В.В., 155

– С –

Сахарутов Д.А., 155
Семенов Д.М., 367
Смолин В.С., 259
Соколов С.М., 259
Старков С.О., 313

– Т –

Тарасов А.С., 277, 286
Тарасова В.Ю., 277, 286
Тельных А.А., 377
Тихонов И.В., 174
Тишков А.В., 388

– У –

Уланов В.Н., 397

– Ф –

Филатов Н.С., 397
Филяев М.А., 183
Фокин С.И., 341
Форш П.А., 155
Фрадков А.Л., 367

– Ч –

Чвалун С.Н., 155
Чижов А.В., 37

– Ш –

Швецов Б.С., 155
Шемагина О.В., 183, 377
Шестаков Е.И., 18

– Я –

Яхно В.Г., 183