

# **Нейроинформатика, её приложения и анализ данных**

**XXXII Всероссийский семинар**

**Красноярск  
2024**

Министерство науки и высшего образования РФ  
Сибирское отделение РАН  
Российская ассоциация нейроинформатики  
Институт вычислительного моделирования СО РАН

# **НЕЙРОИНФОРМАТИКА, ЕЁ ПРИЛОЖЕНИЯ И АНАЛИЗ ДАННЫХ**

МАТЕРИАЛЫ  
ТРИДЦАТЬ ВТОРОГО ВСЕРОССИЙСКОГО СЕМИНАРА  
27 сентября 2024 года

Красноярск 2024

УДК 007.52 (042.3)

Н 43

**Нейроинформатика, её приложения и анализ данных:** Материалы XXXII Всероссийского семинара, 27 сентября 2024 года / Под ред. М.Г.

Садовского, отв. за вып. М.Ю. Сенашова; – Красноярск: Институт вычислительного моделирования СО РАН, 2024. – 129 с.

*В сборнике представлены материалы XXXII Всероссийского семинара «Нейроинформатика, её приложения и анализ данных», проходившей в городе Красноярске 27 сентября 2024 года.*

*Основной задачей конференции является всесторонний и высоко квалифицированный обмен новейшими достижениями в различных областях нейроинформатики (как теории нейросетей, так и в области различных практических приложений), а также в области нелинейного статистического анализа многомерных данных, обладающих нетривиальными структурами.*

*Большое внимание уделено анализу областей применимости и точности методов обработки многомерных данных, анализу устойчивости различных новых (нелинейных) методов кластеризации, разбор большого числа конкретных случаев, иллюстрирующих эти проблемы и достижения.*

*Материалы предназначены для научных работников, преподавателей, студентов и аспирантов соответствующих специальностей.*

**Конференция проводится при поддержке Красноярского математического центра, финансируемого Минобрнауки РФ в рамках мероприятий по созданию и развитию региональных НОМЦ (Соглашение № 075-02-2024-1378).**

**Редакционная коллегия:**

Садовский Михаил Георгиевич – ответственный редактор

Сенашова Мария Юрьевна – ответственный за выпуск

© ИВМ СО РАН, 2024

© Коллектив авторов, 2024

ISBN 978-5-6047078-8-3



9 785604 707883

# OPTIMIZED MODEL FOR GEARBOX FAULT DETECTION: A RANDOM FOREST APPROACH USING VIBRATION DATA

H.S. Al Ouatiq<sup>1</sup>, S.P. Pronin<sup>1</sup>

<sup>1</sup>Altai State Technical University named after I.I. Polzunov,  
Faculty of Information Technologies, Department of Information Technologies,  
*alh@dr.com*

## Abstract

This study presents the development and evaluation of a Random Forest classifier for predicting gearbox faults using engineered features from vibration data. The model training process, including data preparation, stratified sampling, and hyperparameter tuning, is detailed, and a comprehensive performance analysis is provided. The results demonstrate the effectiveness of the Random Forest algorithm in distinguishing between normal, cracked, and broken gearbox states with high precision and recall. This approach shows promise for practical implementation in predictive maintenance systems, reducing downtime and maintenance costs in industrial settings.

## Keywords

Random Forest; Gearbox Fault Detection; Predictive Maintenance; Vibration Data; Feature Engineering; Hyperparameter Tuning; Performance Analysis

## 1. Introduction

Predictive maintenance in industrial settings, particularly for critical components like gearboxes, has become increasingly important for minimizing downtime and reducing maintenance costs. Machine learning techniques, such as Random Forest classifiers, have shown promise in accurately predicting equipment faults based on sensor data [6].

The Random Forest algorithm is an ensemble learning method that constructs multiple decision trees during training and outputs the mode of the classes for classification tasks [1]. This approach is known for its robustness, ability to handle complex non-linear relationships, and effectiveness in preventing overfitting.

This study focuses on the application of a Random Forest classifier for gearbox fault prediction using engineered features derived from vibration data. The goal is to develop a reliable model that can distinguish between normal, cracked, and broken gearbox states, enabling timely maintenance interventions and enhancing operational efficiency.

## **2. Methodology**

### **2.1. Data Preparation**

The dataset used in this study comprises engineered features extracted from vibration signals of gearboxes [4]. The dataset was preprocessed and inspected, and any missing values were handled using forward fill imputation. To ensure that all features contribute equally to the model training process, standard scaling was applied to the dataset.

Given the imbalanced nature of the dataset, with a higher proportion of normal state samples compared to fault states, stratified sampling was employed to ensure that the training and test sets have a proportional representation of each class. Additionally, the Synthetic Minority Over-sampling Technique (SMOTE) was used to address the class imbalance by generating synthetic samples for the minority class.

The preprocessed and balanced dataset was then split into training and testing sets using a 70-30 split ratio, maintaining the class distribution in both sets through stratified sampling.

### **2.2. Optimized Model Training Process**

The preprocessed and balanced dataset was split into training and testing sets using a 70-30 split ratio. The Random Forest Classifier was initialized, with hyperparameter tuning performed using Grid Search with Cross-Validation. The parameters fine-tuned included:

- **Number of Estimators** (`n_estimators`): {100, 200, 300}
- **Maximum Depth** (`max_depth`): {10, 20, None}
- **Minimum Samples Split** (`min_samples_split`): {2, 5, 10}
- **Minimum Samples Leaf** (`min_samples_leaf`): {1, 2, 4}
- **Bootstrap** (`bootstrap`): {True, False}

The model was then trained on the balanced dataset, where each tree in the Random Forest contributed to the final prediction by voting. The training process and hyperparameter optimization significantly enhanced the model's accuracy and generalization ability.

### 2.3. Feature Significance

The importance of each feature in the model's decision-making process was assessed using the Mean Decrease in Impurity (MDI) method. The MDI for a feature  $X_m$  is computed as:

$$I(X_m) = \frac{1}{N_T} \sum_T \sum_{t \in T: v(s_t) = X_m} p(t) \Delta i(s_t, s_{t_L}, s_{t_R})$$

where  $N_T$  is the number of trees in the forest,  $T$  represents each tree in the forest,  $t$  are the nodes in the tree,  $v(s_t)$  is the variable used for splitting at node,  $t$ ,  $p(t)$  is the proportion of samples reaching node  $t$ , and  $\Delta i(s_t, s_{t_L}, s_{t_R})$  is the decrease in impurity from splitting on  $X_m$  at node  $t$ .

## 3. Model Performance

### 3.1. Accuracy

The Random Forest classifier achieved 97% accuracy on the test set, reflecting the model's effectiveness in capturing underlying vibration data patterns and ensuring reliable performance in practical applications.

### 3.2. Precision, Recall, and F1-Score

The classification report for the optimized model is summarized in Figure 1. The model achieved a perfect precision, recall, and F1-score for both the "Cracked" and "Normal" classes, demonstrating an excellent balance between precision and recall. This balance is crucial in fault detection, ensuring the model makes few false-positive errors while effectively identifying actual faults, making it both accurate and dependable across different conditions.




Fig.1. Classification Report Heatmap for Optimized Model

### 3.3. Confusion Matrix

The confusion matrix for the optimized model is shown in Figure 2. The matrix shows that the model correctly identified all instances of "Cracked" faults and most instances of "Normal" states, with only one misclassification.

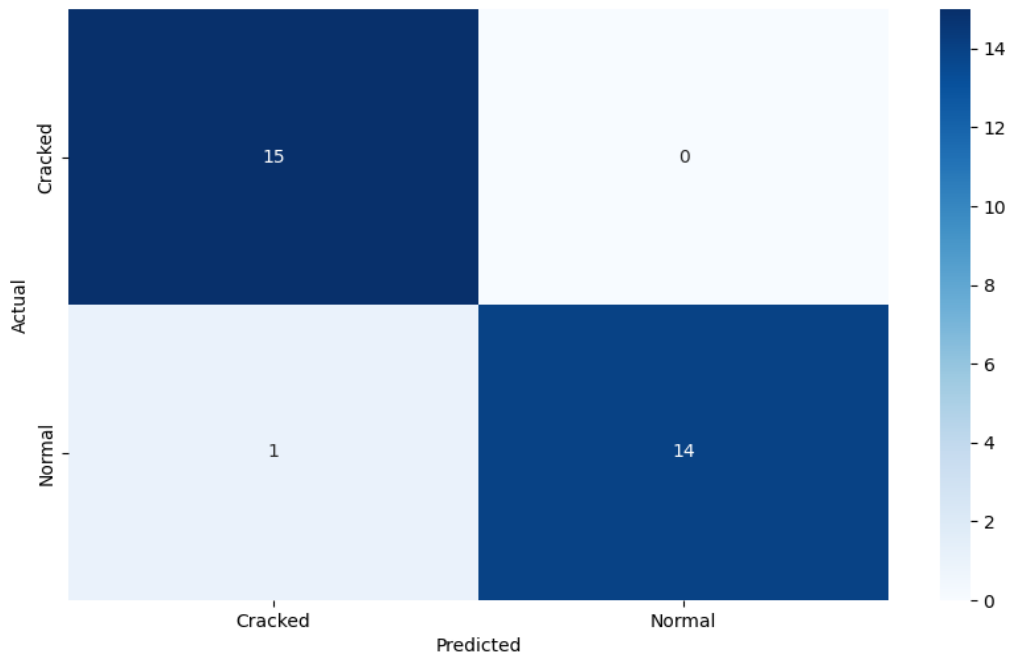


Fig.2. Confusion Matrix for Optimized Model

### **3.4. Feature Importance Analysis**

The feature importance analysis reveals several critical insights:

1. *Dominant Features:* The top three features account for a significant portion of the total importance, indicating their critical role in fault detection. Specifically, features related to the standard deviation and skewness of vibration signals at 60Hz and 50Hz are highly influential.

2. *Vibration Characteristics:* The standard deviation and skewness of vibration signals at specific frequencies are the most influential features. This suggests that variations in the amplitude and distribution of the vibration signals are key indicators of gearbox faults.

3. *Balanced Importance:* The relatively even distribution of importance among the top features suggests that the model relies on a combination of indicators rather than a single dominant feature. This indicates a robust model that is less likely to be overly dependent on any single feature, enhancing its generalizability.

4. *Frequency Diversity:* The presence of features at different frequencies (50Hz and 60Hz) highlights the importance of analyzing multiple frequency bands for comprehensive fault detection. This diversity ensures that the model can capture a wide range of fault-related characteristics in the vibration signals.

### **4. Conclusion**

In this study, we developed and rigorously evaluated an optimized Random Forest classifier for predicting gearbox faults using features derived from vibration data. The Random Forest algorithm was chosen for its robustness and ability to handle complex non-linear relationships. Our results demonstrate that the model can reliably distinguish between normal, cracked, and broken gearbox states with high precision and recall, making it a valuable tool for predictive maintenance.

The data preparation involved careful feature engineering to extract key time-domain and frequency-domain characteristics from raw vibration signals. These features were used to train and optimize the model, which was evaluated through stratified



sampling, SMOTE for class imbalance, and hyperparameter tuning. The model achieved a high accuracy of 97% on the test set.

The classifier showed high precision and recall, effectively leveraging a diverse set of vibration features, particularly those related to the standard deviation and skewness of signals at specific frequencies. The balanced distribution of feature importance suggests the model is not overly reliant on any single feature, enhancing its generalizability.

The strong performance of our model highlights its potential for real-world applications in predictive maintenance, helping to reduce downtime and maintenance costs. However, future work should focus on the following areas:

- **Validation:** Testing on independent datasets to ensure robustness across different conditions.
- **Advanced Feature Engineering:** Exploring more sophisticated techniques and incorporating additional data sources to enhance predictive capabilities.
- **Complex Fault Categories:** Expanding the model to handle more nuanced fault types.
- **Real-Time Implementation:** Developing real-time monitoring systems for continuous fault detection.

In conclusion, this study demonstrates the effectiveness of an optimized Random Forest classifier for gearbox fault prediction. While the results are promising, further research is needed to fully realize its potential in diverse industrial applications, contributing to smarter, data-driven maintenance strategies.

### References

1. Breiman, L. Random Forests / L. Breiman // Machine Learning. — 2001. — Vol. 45, № 1. — P. 5-32.
2. Kohavi, R. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection / R. Kohavi // International Joint Conference on Artificial Intelligence (IJCAI). — 1995. — Vol. 14, № 2. — P. 1137-1143.

3. Cerrada, M., Sánchez, R. V., Li, C., Pacheco, F., Cabrera, D., Valente de Oliveira, J., & Vásquez, R. E. A review on data-driven fault severity assessment in rolling bearings / M. Cerrada, R. V. Sánchez, C. Li, F. Pacheco, D. Cabrera, J. Valente de Oliveira, R. E. Vásquez // *Mechanical Systems and Signal Processing*. — 2018. — Vol. 99. — P. 169-196.
4. Tian, J. Motor Bearing Fault Detection Using Spectral Kurtosis-Based Feature Extraction Coupled with K-Nearest Neighbor Distance Analysis / J. Tian, C. Morillo, M. H. Azarian, M. Pecht // *IEEE Transactions on Industrial Electronics*. — 2016. — Vol. 63, № 3. — P. 1793-1803.
5. Li, J. Review of research on signal decomposition and fault diagnosis of rolling bearing based on vibration signal / J. Li, W. Luo, M. Bai // *Measurement Science and Technology*. — 2024. — Vol. 35, № 9. — P. 092001.
6. Kizito, R., Scruggs, P., Li, X., Kress, R., Devinney, M., Berg, T. The Application of Random Forest to Predictive Maintenance / R. Kizito, P. Scruggs, X. Li, R. Kress, M. Devinney, T. Berg // 2018.

# WEIGHT REGULARIZATION IN SPIKING NEURAL NETWORKS<sup>1</sup>

D.I. Antonov<sup>1,2</sup>, S.V. Sukhov<sup>2</sup>

<sup>1</sup>Ulyanovsk State Technical University

<sup>2</sup>Ulyanovsk Branch of Kotel'nikov Institute of Radio Engineering and Electronics of Russian Academy of Sciences, *d.antonov@ulireran.ru*

The separation of useful information from noise is an essential process in many machine-learning phenomena. The process of useful feature extraction and their separation from noisy input can be found in many applications of artificial neural networks (ANNs).

The desired result of any learning is not the mere memorization of training data but the ability to generalize the knowledge for solving new problems [1]. During the training of the ANN, the error on the training set (loss function) is calculated and minimized. However mindless minimization of the loss function may result in *overfitting* of the model [2]. Overfitting is a result of training taking into account both essential and insignificant features, noise. *Regularization* methods are intended to minimize the influence of random noise and to identify regular features during the model training process. Thus, regularization helps in preventing ANNs from overfitting.

Segregation and different treatment of familiar and unfamiliar data and noise might be necessary during the predictive processing of information in ANNs [3]. Unfamiliar information should propagate further along the neural network for processing, the familiar (expected) result should not result in additional processing, and the noise should not propagate along the network at all [3].

Another serious problem for practical applications of artificial neural networks is their weak protection against various types of adversarial attacks. Noise-like changes to the images that are insignificant for human perception may cause errors in their classification by ANNs. This, in turn, may cause major failures in the operation of ANN-based devices.

To prevent the overfitting in ANNs or make them more robust against adversar-

---

<sup>1</sup> The reported study was funded by the Russian Science Foundation (project number 24-21-00470).

ial attacks, various regularization methods are used. Many regularization methods are related to the minimization or pruning of some redundant weights. In the practice of ANN training, three methods are most often used: dropout, L1-, and L2-regularizations.

The L2-regularization (also called Ridge regression) uses the square of weights as a penalty term to the loss function:

$$F_{loss} = E(Y - \hat{Y}) + \lambda \sum_{i=0}^n w_i^2, \quad (1)$$

where  $\lambda$  is the regularization parameter,  $E$  is some error function measuring the difference between ground truth  $Y$  and the prediction  $\hat{Y}$ . The L2-regularization encourages a more balanced distribution of weights across features and prevents them from acquiring large values.

In the case of L1-regularization (also called Lasso regression), in the loss function  $F_{loss}$ , a regularization term with absolute values of weights is added:

$$F_{loss} = E(Y - \hat{Y}) + \lambda \sum_{i=0}^n |w_i|. \quad (2)$$

While L2-regularization minimizes weights, L1-regularization makes redundant weights equal exactly to zero creating a sparse model.

Similar to L1-regularization, dropout involves randomly selecting weights or entire neurons to be removed from the learning process. The effect of dropout is that the network becomes less sensitive to the specific weights of neurons.

Spiking neural networks (SNNs) are the next generation of neural networks, with a promise of more energy-efficient and more biologically plausible computations [4]. The neurons in SNNs transmit information by short pulses (spikes), and training of SNNs is performed by local rules. Some prior research found that SNNs are more robust against exposure to noise and more robust against adversarial attacks [5-7]. However, other research found SNNs still susceptible to noise [8]. Here, we propose a regularization method for SNNs that significantly reduces the neural activity caused by noise input.

Instead of error backpropagation, local training methods are often used in SNNs. Spike-timing-dependent plasticity (STDP) is the most frequently used learning rule for unsupervised learning in SNNs. The property of STDP to cluster data directly

corresponds to the needs of unsupervised learning. During such training according to the STDP rule, the synaptic weights change according to the law:

$$\Delta w(\Delta t) = \begin{cases} A_{pre} \cdot \exp(-\Delta t/\tau_{pre}), & \Delta t > 0 \\ A_{post} \cdot \exp(\Delta t/\tau_{post}), & \Delta t < 0 \end{cases} \quad (3)$$

where  $\Delta t$  is the time interval between the occurrence of a spike in the postsynaptic neuron and the occurrence of a spike in the presynaptic neuron, the coefficients  $A_{pre} > 0$ ,  $A_{post} < 0$ , and the time constants  $\tau_{pre} > 0$  and  $\tau_{post} > 0$ .

Supervised learning is commonly used for classification and regression problems. In [9, 10], we modified STDP to be applicable for supervised learning. A law similar to eq. (3) describes another bio-plausible rule, the all-long-term-depression rule (all-LTD). The change in synaptic connection in the case of all-LTD is determined by the expression:

$$\Delta w(\Delta t) = \begin{cases} -A_{pre} \cdot \exp(-\Delta t/\tau_{pre}), & \Delta t > 0 \\ A_{post} \cdot \exp(\Delta t/\tau_{post}), & \Delta t < 0 \end{cases} \quad (4)$$

The STDP and all-LTD rules were used for supervised learning of the SNN network [10].

Both STDP and all-LTD learning rules do not assume any global loss. Thus, usual regularization methods (1), (2) are not suitable for SNNs. Thus, redundant weights are not eliminated during the training process. Indeed, looking at eqs. (3), (4) one can notice that weights change only in the case of presynaptic neuron firing. In the case of silent presynaptic neurons, their outgoing weights remain the same as during initialization. These redundant weights can be later misused for the propagation of noise or unnecessary/adverse information.

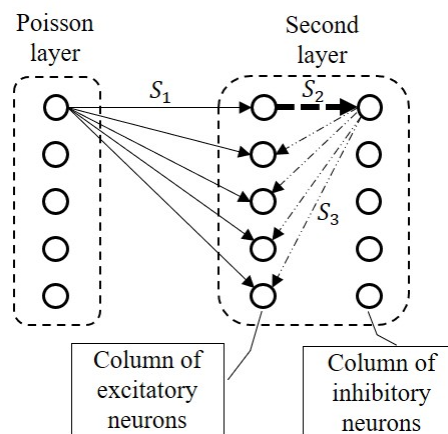
In this paper, we propose the weight regularization method for SNNs based on the biological ‘use it or lose it’ concept [11]: if a synaptic connection is not used in a brain, it is pruned. To ensure the pruning of unnecessary weight in SNNs, all the weights become time-dependent:

$$w(t) = w(t_s) \exp\left(-k_p \left(\frac{t-t_s}{\tau_{prun}}\right)^2\right), \quad (5)$$

where  $t_s$  is the time of the last spike,  $\tau_{prun}$  is the characteristic time over which pruning occurs,  $k_p$  is the pruning coefficient. For frequently spiking neurons, the exponent in

eq. (5) is almost unity and no weight decay occurs. However, the weights of a neuron silent over  $\tau_{\text{prun}}$  time become pruned.

To test our regularization concept, we perform a series of experiments with SNNs. In experiments, the SNN is trained with the aim of classification of MNIST images of handwritten digits. The purpose of the experiments was to compare the SNN output activity with or without weight regularization. The SNN in all the experiments uses the leaky integrate-and-fire neurons with an adaptive threshold for excitatory neurons. The network consists of two layers (Fig. 1) and has an architecture similar to the one described in the paper [12]. The first input layer of the SNN (Fig. 1) contains 784 Poisson neurons, and the second layer consists of an equal number of excitatory and inhibitory neurons (10 neurons per data class). Each neuron in the Poisson layer corresponds to one pixel of input data. Each Poisson neuron generates a spike train with an average frequency equal to the intensity of a given pixel (rate coding). The signal passes from Poisson neurons to excitatory neurons of the second layer through synapses of the  $S_1$  group in a one-to-all manner. Through the synapses of the  $S_2$  group, the spikes pass to the inhibitory neurons of the second layer in a one-to-one manner. And through synapses of the  $S_3$  group, the spikes generated by inhibitory neurons return to excitatory neurons in a one-to-all-except-initiator manner.




**Fig. 1.** SNN architecture: the first layer contains 784 Poisson neurons, the second layer contains 30 excitatory and 30 inhibitory neurons;  $S_1$ ,  $S_2$ , and  $S_3$  are the synaptic connections.

To implement the combined Hebbian learning rule ‘*STDP + all-LTD*’ we divided the excitatory neurons of the second layer into subsets, the number of subsets is equal to the number of data classes, and the sizes of these subsets are the same. When the input data of a certain class are given, synapses of the  $S_1$  group associated with a subset of neurons recognizing the target class are trained according to the STDP rule. If an excitatory neuron of a wrong class becomes active, its incoming weights are modified according to the all-LTD rule.

During the test stage, the recognized class of data is determined by the highest activity of the neuron populations assigned to each class.

We used just 15000 images for training and 1500 images for testing from the MNIST dataset. In the experiments, we used only 3 classes of images out of 10 possible.

The SNN was implemented in the Brian 2.0 package, an open-source framework for SNN modeling. We used a computer with an Intel Core i9 processor (3,1 GHz), 32 GB RAM, PyTorch 1.8.0, and Ubuntu 20.0 to run the code.



**Fig. 2.** 784 weights of the synaptic group  $S_1$ , associated with one of the excitatory neurons: a. in the model without regularization technique; b. the same weights in the model with regularization.

The result of training with and without weight regularization is illustrated in Fig.2. Fig. 2 shows the 784 weights of the synaptic group  $S_1$  that are responsible for the recognition of one of the features of the digit 7. 784 synapses connect all Poisson neurons to one of the excitatory neurons. Fig.2a shows the weights without regulariza-

tion technique, while Fig.2b shows weights with regularization. The effect of regularization is clearly visible: the nonzero weights around the border of Fig.2a corresponding to the silent neurons are pruned by regularization as can be seen in Fig. 2b.

To study the effects of regularization, the trained networks were tested on four different datasets with 1500 images each:

1.  $28 \times 28$  pixel images with delta-correlated noise with an average intensity equal to the average intensity of the images in the training dataset;
2.  $28 \times 28$  pixel noise images processed with a Gaussian filter with a standard deviation of 2 pixels (finite-correlation noise images);
3. images of the digits corresponding to the same classes the network was trained on;
4. images of the digits different from the classes the network was trained on.

The elimination of the insignificant synaptic weights that are not involved in recognition is expressed in a decrease in the overall neural activity of the SNN when it is tested on images of both ‘known’ (image classes coincide with those used in training) and ‘unknown’ digits (see Table).

Table

Neuronal output activity (total number of spikes) for different datasets

No	Test set	Model without regularization	Model with regularization
1	Delta-correlated noise	3162	1
2	Gaussian blurred images	3265	1
3	‘Known’ digits	416	344
4	‘Unknown’ digits	346	240

In the model without regularization, ‘unknown’ data generated 17% fewer spikes than ‘known’ data; in the model with regularization, the difference in spike number increased up to 30%. The trained network also shows a significant difference in neuronal spiking activity for noise images with and without regularization (see Table). According to the data in the Table, it is clearly seen that the SNN with regularization is almost completely unresponsive to the noise signal.



In conclusion, the use of weight regularization in SNNs eliminates the weights that are not involved in the recognition process. As a result, this allows:

- to significantly reduce the noise impact on the recognition process and thereby significantly reduce the risk of adversarial attacks on the SNN,
- to reduce neural activity in response to ‘unknown’ data (in experiments by 1,8 times), which increases the accuracy of the SNN and improves its ability to generalize,
- to modulate the propagation of known and unknown information that is vital for the implementation of predictive computations in SNNs.

#### Список литературы

1. Urolagin S. Generalization capability of artificial neural network incorporated with pruning method / S.Urolagin, K.V.Prema, N.V.S.Reddy // *Advanced computing, networking and security. Lecture notes in computer science*. Eds. P.S.Thilagam, A.R.Pais, K.Chandrasekaran, N.Balakrishnan. — Berlin, Heidelberg: Springer. — 2012. — V.7135. — P.171–178.
2. Montesinos López O.A. Overfitting, model tuning, and evaluation of prediction performance / O.A.Montesinos López, A.Montesinos López, J.Crossa // *Multivariate statistical machine learning methods for genomic prediction*. — Springer Cham. — 2022.
3. N'dri A.W. Predictive coding light: learning compact visual codes by combining excitatory and inhibitory spike timing-dependent plasticity / A.W.N'dri, T.Barbier, C.Teulière, J.Triesch // *Proceedings of the IEEE/CVF Conference on computer vision and pattern recognition*. – 2023. – P.3997-4006.
4. Maass W. Networks of spiking neurons: The third generation of neural network models / W.Maass // *Neural Networks*. – 1997. – V.10. – No.9. – P.1659–1671.
5. Sharmin S. A comprehensive analysis on adversarial robustness of spiking neural networks / S.Sharmin, P.Panda, S.S.Sarwar, C.Lee, W.Ponghiran, K.Roy // *2019 International joint conference on neural networks (IJCNN)*. Budapest. Hungary. — 2019. — P.1-8.
6. Tan Y.X.M. Exploring the back alleys: analysing the robustness of alternative neu-

- ral network architectures against adversarial attacks / Y.X.M.Tan, Y.Elovici, A.Binder // E-print: <https://www.arxiv.org/abs/1912.03609>.
7. Marchisio A. Is spiking secure? A comparative study on the security vulnerabilities of spiking and deep neural networks / A.Marchisio, G.Nanfa, F.Khalid, M.A.Hanif, M.Martina, M.Shafique, // 2020 International joint conference on neural networks (IJCNN). – 2020. – P.1-8.
  8. Leontev M. Robustness of spiking neural networks against adversarial attacks / M.Leontev, D.Antonov, S.Sukhov // 2021 International Conference on Information Technology and Nanotechnology (ITNT). – 2021. – P.1-6.
  9. Antonov D. Spiking neural networks training with combined Hebbian rules / D.Antonov, B.Batuev, S.Sukhov // X International conference on information technology and nanotechnology (ITNT). — Samara. Russian Federation. — 2024. — P.1-5.
  10. Antonov D.I. Training of spiking neural networks-classifiers with local rules / D.I.Antonov, S.V.Sukhov // Proceedings of XXV international conference on artificial neural networks «Neuroinformatics-2023». – 2023. – P.116-125. (in Russian)
  11. Shors T.J. Use it or lose it: how neurogenesis keeps the brain fit for learning / T.J.Shors, M.L.Anderson, D.M.Curlik II, M.S.Nokia // Behavioural brain research. – 2012. – V.227(2). – P.450-458.
  12. Diehl P. Unsupervised learning of digit recognition using spike-timing-dependent plasticity / P.Diehl, M.Cook // Frontiers in Computational Neuroscience. – 2015. – V.9. – P. 1-9.

# ПРЕДСКАЗАНИЕ ПОСЛЕДОВАТЕЛЬНОСТЕЙ С ПОМОЩЬЮ ИМПУЛЬСНЫХ НЕЙРОННЫХ СЕТЕЙ<sup>2</sup>

Б.Б.Батуев<sup>1</sup>, С.В.Сухов<sup>2,3</sup>

<sup>1</sup> ИРЭ им. В.А. Котельникова РАН, *buligarmouth@gmail.com*

<sup>2</sup> УФИРЭ им. В.А. Котельникова РАН, *ssukhov@ulireran.ru*

<sup>3</sup> Ульяновский государственный технический университет

Прогнозирование временных последовательностей является одной из ключевых задач в области анализа данных. Временные данные, представляющие собой последовательности событий или сигналов, также являются основой для понимания многих когнитивных и нейрофизиологических процессов в мозге [1]. Точность прогнозирования таких данных может существенно улучшить наше понимание механизмов работы мозга, что, в свою очередь, способствует разработке более эффективных и биологически правдоподобных моделей искусственных нейронных сетей.

Мозг человека обрабатывает информацию посредством сложных временных паттернов электрической активности, которые могут быть записаны и проанализированы с помощью различных методов нейровизуализации и электрофизиологических исследований [2]. Предсказание этих временных паттернов позволяет не только углубить наше понимание функционирования нейронных сетей, но и разработать новые методы диагностики и лечения неврологических расстройств. Например, точные модели прогнозирования могут способствовать раннему выявлению аномалий в нейронной активности, связанных с заболеваниями, такими как эпилепсия или болезнь Паркинсона, что позволяет своевременно применять терапевтические вмешательства [3].

В области искусственного интеллекта и машинного обучения, временные данные играют важную роль в обучении и совершенствовании нейросетевых моделей. Современные рекуррентные нейронные сети, такие как Long Short-Term Memory (LSTM) и Gated Recurrent Unit (GRU), демонстрируют высокую эффек-

---

<sup>2</sup> The reported study was funded by the Russian Science Foundation (project number 24-21-00470).

тивность в обработке временных данных, однако они все еще далеки от биологического реализма. Прогнозирование временных данных с использованием моделей, более приближенных к работе человеческого мозга, таких как импульсные нейронные сети (ИмНС), открывает новые перспективы для создания более мощных и энергоэффективных систем искусственного интеллекта. Импульсные нейронные сети, вдохновленные принципами работы биологических нейронов, способны обрабатывать информацию в реальном времени и более эффективно имитировать динамическую природу нейронных процессов [4].

Преобразование традиционных рекуррентных сетей, таких как LSTM, BiGRU, в импульсные нейронные сети представляет собой важный шаг в этом направлении. Такое преобразование позволяет объединить преимущества высокоэффективных алгоритмов машинного обучения с биологически правдоподобными моделями обработки информации. Это не только улучшает точность предсказания временных данных, но и способствует созданию новых подходов к моделированию когнитивных функций и разработке инновационных нейротехнологий.

Рекуррентные нейронные сети (РНС) являются классом нейронных сетей, специально разработанным для обработки последовательных данных. В отличие от традиционных нейронных сетей, РНС обладают способностью сохранять информацию о предыдущих состояниях через рекуррентные связи. Это позволяет им учитывать контекст предыдущих элементов последовательности при обработке текущего элемента [5].

Основная идея РНС заключается в использовании скрытого состояния  $h_t$ , которое обновляется на каждом временном шаге в соответствии с входными данными  $x_t$  и предыдущим скрытым состоянием  $h_{t-1}$ . Математически это выражается следующими уравнениями:

$$h_t = \sigma(W_h \cdot h_{t-1} + W_x \cdot x_t + b),$$
$$y_t = \varphi(W_y \cdot h_t + c),$$

где  $h_t$  – скрытое состояние в момент времени  $t$ ,  $x_t$  – входной вектор,  $y_t$  – выходной вектор,  $W_h$ ,  $W_x$ ,  $W_y$  – весовые матрицы,  $b$  и  $c$  – смещения,  $\sigma$  и  $\varphi$  (tanh) – активационные функции.

Long Short-Term Memory (LSTM) – это разновидность рекуррентных нейронных сетей, разработанная для решения проблемы исчезающего градиента, характерной для стандартных РНС. LSTM имеет более сложную структуру, включающую в себя три вентиля (gate): входной, выходной и забывания, что позволяет эффективно управлять потоком информации через сеть [7]. LSTM-сеть содержит так называемую ячейку состояния, которая способна сохранять информацию на длительные временные интервалы. Вентили управляют тем, какую информацию сохранить, какую забыть и какую передать на следующий временной шаг [7].

Gated Recurrent Unit (GRU) – это упрощенная версия LSTM, предложенная для снижения вычислительной сложности при сохранении способности моделирования долгосрочных зависимостей. В GRU используется два вентиля: обновления и сброса, что делает архитектуру более простой и менее ресурсоемкой. Обновляющий вентиль решает, какую часть предыдущего скрытого состояния сохранить, а сбрасывающий вентиль управляет тем, какую часть нового входа использовать для обновления текущего скрытого состояния [8].

И LSTM, и GRU к настоящему времени были реализованы в искусственных нейронных сетях с аналоговым кодированием данных. В нашей работе предложена реализация этих типов РНС в импульсных нейронных сетях. Импульсные нейронные сети (ИмНС) моделируют работу биологических нейронов, передавая информацию в виде отдельных импульсов (спайков), что отличает их от традиционных искусственных нейронных сетей с непрерывными значениями. Временная информация имеет ключевое значение для работы ИмНС, поскольку время появления спайков и интервалы между ними используются для кодирования и обработки данных. Стремление к биологической правдоподобности делает ИмНС перспективными для использования в нейроморфных системах.

Одной из платформ для разработки и моделирования импульсных нейрон-

ных сетей является Nengo. Она позволяет создавать и тренировать модели, используя высокоуровневые абстракции, что упрощает процесс разработки. Nengo поддерживает различные типы нейронов и интеграцию с нейроморфными вычислительными платформами, такими как SpiNNaker и Loihi [10]. Поддержка биологически правдоподобных механизмов, таких как синаптическая пластичность и временная динамика, делает Nengo полезным для нейробиологических исследований и разработки нейроморфных систем [11].

Построение модели в Nengo основано на трех основных постулатах [4]. Во-первых, любой нейронной популяции в Nengo ставится в соответствие векторная переменная  $\mathbf{x}$ , связанная с активностями нейронов  $a_i$  соотношением

$$a_i = G(\alpha_i \mathbf{e}_i \mathbf{x} + b_i),$$

где  $G$  – нелинейная функция специфичная на используемых нейронах,  $\alpha_i$  – коэффициенты усиления,  $\mathbf{e}_i$  – кодирующие векторы,  $b_i$  – фоновый ток смещения. И наоборот, оценка вектора  $\mathbf{x}$  может быть получена из активностей нейронов  $a_i$  с помощью следующего выражения:

$$\hat{\mathbf{x}} = \sum a_i d_i,$$

где  $d_i$  – линейные декодеры.

Во-вторых, Nengo позволяет вычислять линейные и нелинейные функции  $f(\mathbf{x})$ . В-третьих, нейронные ансамбли в Nengo способны моделировать динамическое поведение, используя рекуррентные связи:

$$\frac{d\mathbf{x}}{dt} = A\mathbf{x} + B\mathbf{u},$$

где  $A$  и  $B$  – произвольные матрицы.

Один из самых простых способов получения ИмНС – это преобразование в импульсные обычных искусственных нейронных сетей. Процедура начинается с разработки РНС в Keras. Keras, будучи высокоуровневой библиотекой для глубокого обучения, предоставляет удобные инструменты для создания и обучения сложных нейронных сетей [12]. Следующий этап включает использование инструмента Converter из пакета Nengo, разработанного для преобразования Keras-моделей в Nengo-совместимые сети. Converter автоматически преобразует слои

Keras-модели в соответствующие компоненты Nengo, сохраняя архитектуру сети. Заключительный этап включает в себя тестирование и валидацию конвертированной сети. Важно убедиться, что поведение импульсной сети соответствует исходной Keras-модели. Для этого в Nengo предусмотрены инструменты оценки точности работы модели на тестовых данных.

Нами было построено несколько моделей конвертированных импульсных сетей. Первая модель выполняла прогнозирование следующего слова в предложении. В качестве обучающего набора данных использовался набор Kaggle состоящий из 12000 предложений текста. Важным параметром является число слов, на основе которых строится прогноз. Текст разбивается на слова, и наиболее часто встречающиеся из них формируют словарь. После этого текст преобразуется в последовательность чисел, соответствующих словам в словаре. Затем эти числа кодируются унитарным кодом, образуя двумерную матрицу, которая используется для формирования тензора обучающей выборки и соответствующего набора выходных значений.

Однако при использовании такого подхода входной тензор занимает значительное количество памяти, особенно при увеличении числа слов в словаре. Альтернативным подходом является использование слоя Embedding, который существенно снижает объем памяти, необходимый для хранения обучающей выборки. Этот слой преобразует входные векторы в плотные представления, соответствующие весам связей для каждого слова, что позволяет эффективно обучать модель. Использование слоя Embedding не только уменьшает объем используемой памяти, но и упрощает саму программу. Входной тензор теперь представлен последовательностью порядковых номеров слов, что облегчает обработку данных и сохраняет точность модели. Обучение проводится аналогично предыдущему подходу, с использованием Embedding слоя в качестве входного слоя модели.

В данной модели нейронной сети используется Embedding слой размерностью 300, который применен к входным данным длиной в 5 слов. На выходе Embedding слоя следуют слой LSTM с 150 нейронами и полносвязный слой с

функцией активации softmax, преобразующий результат в вероятности появления каждого из 5000 возможных слов. Модель компилируется с использованием функции потерь категориальной кросс-энтропии и оптимизатора Adam. Далее модель конвертируется в импульсную нейронную сеть с помощью `nengo.Converter` и затем происходит обучение. После обучения модели в Nengo, полученная импульсная сеть может быть использована для прогнозирования слов в тексте.

Как показано в таблице сравнения, тестовые ошибки Nengo сетей немного меньше, чем у обычных сетей, но время обучения на порядок больше.

Таблица сравнения обучения Nengo и обычных сетей

	Параметры сети	Loss	Test Loss	Время обучения (мин)	Время оценки (сек)	Время тестирования (сек)
Обычные сети (word_predict.py)	Batch_size=64 Num_sentences=22 Maxword-count=1000	0,0045	12,51	0,51	0,17	2,32
	Batch_size=64 Num_sentences=500 Maxword-count=5000	0,0315	10,40	4,93	0,71	2,13
Nengo (word_predict_nengo.p)	Batch_size=64 Num_sentences=22 Maxword-count=1000	0,0050	12,03	0,78	0,19	2,38
	Batch_size=64 Num_sentences=500	0,034	9,53	11,68	3,16	2,61



	Maxword- count=5000					
	Batch_size=1 Num_sentences=500 Maxword- count=5000	1,46	12,05	203	32	14

Двунаправленные рекуррентные нейронные сети реализуются с использованием двух рекуррентных слоев, разворачивающихся в противоположных направлениях. В Keras для создания таких сетей применяется класс ``keras.layers.Bidirectional``, который позволяет превратить обычный рекуррентный слой в двунаправленный.

В качестве примера рассмотрим задачу регрессии на основе синусоидального сигнала с добавленным шумом. Входные данные формируются следующим образом: берутся три предыдущих и три следующих наблюдения относительно прогнозируемого значения. Эти данные представляются в виде трехмерного тензора, что позволяет сети корректно обрабатывать последовательность наблюдений.

Для реализации данной сети в Keras сначала создается входной слой, размером, соответствующим числу входных наблюдений за исключением прогнозируемого значения. Далее, используется двунаправленный рекуррентный слой, состоящий из двух нейронов в каждой ячейке GRU. На выходе сети размещается один нейрон с линейной функцией активации, что типично для задач регрессии. Далее модель Keras конвертируется в импульсную нейронную сеть с использованием ``pengo.Converter``. Модель компилируется с функцией потерь, минимизирующей среднеквадратическую ошибку, и оптимизатором Adam с шагом сходимости 0,01. После этого запускается процесс обучения модели. На выходе получается прогнозируемая кривая, которая сглаживает исходный сигнал (см. рисунок).

Таким образом, описанный процесс позволяет эффективно интегрировать достижения глубокого обучения с моделями, более биологически реалистичными, что открывает новые перспективы для исследования нейронных механизмов и применения нейронных сетей в различных научных и прикладных задачах. В данной работе показан сам факт того, что сети LSTM, BiGRU могут быть реализованы с помощью импульсных нейросетей. В дальнейшем преимущество ИмНС необходимо проверить на соответствующем нейроморфном оборудовании.




Рис. График достраивания точки (оранжевая линия - исходные данные, синяя - предсказанная линия).

Набор использованных тренировочных данных [13] и разработанный нами код [14] доступны в сети Интернет.

#### Список литературы

1. Hamilton J. D. Time series analysis / J.D.Hamilton // Princeton: Princeton University Press, 2020. – 856 p.
2. Cohen M. X. Analyzing neural time series data: theory and practice / M.X.Cohen // Cambridge: MIT Press, 2014. – 600 p.
3. Güler I. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients / I.Güler, E.D.Übeyli // Journal of Neuroscience Meth-

- ods. – 2005. – V.148. – No.2. – P.113-121.
4. Eliasmith C. How to build a brain: A neural architecture for biological cognition / C.Eliasmith // New York: Oxford University Press, 2013. – 352 p.
  5. Goodfellow I. Deep learning / I.Goodfellow, Y.Bengio, A.Courville // Cambridge: MIT Press, 2016. – 775 p.
  6. Colah's Blog. Understanding LSTMs. [Электронный ресурс] – 2015. – URL: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/> (дата обращения: 08.08.2024).
  7. Hochreiter S. Long short-term memory / S.Hochreiter, J.Schmidhuber // Neural Computation. – 1997. – V.9. – No.8. – P.1735-1780.
  8. Cho K. Learning phrase representations using PHC encoder-decoder for statistical machine translation / K.Cho, B.van Merriënboer, C.Gulcehre, D.Bahdanau, F.Bougares, H.Schwenk, Y.Bengio // arXiv preprint arXiv:1406.1078. – 2014.
  9. Mekruksavanich S. A hybrid deep residual network for efficient transitional activity recognition based on wearable sensors / S.Mekruksavanich, N.Hnoohom, A.Jitpattanakul // Applied Sciences. – 2022. – V.12. – No.10. – P.4988.
  10. Bekolay T. Nengo: a Python tool for building large-scale functional brain models / T.Bekolay, J.Bergstra, E.Hunsberger, T.DeWolf, T.C.Stewart, D.Rasmussen, X.Choo, A.R.Voelker, C.Eliasmith, // Frontiers in Neuroinformatics. – 2014. – V.7. – P.48.
  11. Bi G. Synaptic modifications in cultured hippocampal neurons: dependence on spike timing, synaptic strength, and postsynaptic cell type / G.Bi, M.Poo // Journal of Neuroscience. – 1998. – V.18. – No.24. – P.10464-10472.
  12. Gulli A. Deep learning with Keras / A.Gulli, S.Pal // Birmingham: Packt Publishing Ltd, 2017. – 318 p.
  13. English Tense Classification [Электронный ресурс] <https://www.kaggle.com/datasets/hafizflow/english-tense-classification/data> (дата обращения: 22.08.2024).
  14. Convert\_nengo [Электронный ресурс] [https://github.com/buligar/Convert\\_nengo](https://github.com/buligar/Convert_nengo) (дата обращения: 22.08.2024).

# **ВЛИЯНИЕ ПСИХОЛОГИЧЕСКИХ ОСОБЕННОСТЕЙ СУБЪЕКТОВ НА РЕЗУЛЬТАТИВНОСТЬ ПРОЦЕССОВ САМОРЕГУЛЯЦИИ**

Н.М. Богатов, А.Н. Богатова, А.Л. Еремин, С.А. Сухих

Кубанский государственный университет, *bogatov@phys.kubsu.ru*

## **Введение**

Психолого-психофизические исследования информационных процессов в мозге – одно из современных направлений нейробиологии, нейропсихологии, криминалистики, медицины и биоинженерии. Среди различных методов визуализации процессов головного мозга, используемых для работы с интерфейсом мозг-компьютер (ИМК), наиболее популярными являются функциональная магнитно-резонансная томография (фМРТ) [1, 2] и электроэнцефалография (ЭЭГ) [3 – 5].

Процессы, происходящие в мозге человека, отражающие гемодинамический ответ, вызванный активностью нейронов, визуализируются с помощью фМРТ. В [6] предложен алгоритм структурной-функциональной специализации данных фМРТ по стандартам определения координат локусов и Международной классификации функционирования ВОЗ, разработана модель табличной матрицы, где систематизированы данные метаанализа по умственным функциям в трехмерной структуре мозга.

Метод ЭЭГ является неинвазивным и позволяет достичь высокого временного разрешения. Он активно применяется в области носимых технологий и вычислительного интеллекта, создания систем взаимодействия человека и машины, использующих ИМК, устанавливающих прямой канал связи между мозгом и физической реальностью. Аппаратно-программные комплексы (АПК) с нейророботной связью используются для тренировки когнитивных способностей и овладения техниками саморегуляции [7].

Использование парадигмы фМРТ и ЭЭГ в психофизических исследованиях позволяет количественно оценить активацию мозга при психоэмоциональных нагрузках и изучить процессы саморегуляции функциональных состояний [2, 7].

В работе [5] отмечается, что любой набор физиологических параметров человека статистически уникален. Этот факт должен учитываться при моделировании нейронных сетей мозга, анализе психоэмоциональных состояний, разработке АПК с ИМК. Улучшение характеристик систем, использующих ИМК, возможно за счёт создания новых алгоритмов, учитывающих психоэмоциональные и физиологические особенности субъектов, включенных в контур ИМК [8].

В работах [9 – 10] развивается концепция, согласно которой воздействие сознания субъекта изменяет энергоинформационный обмен в организме, отражающийся в функционировании его органов и систем. Проанализируем влияние психологических особенностей субъектов психофизиологической саморегуляции на динамику функциональных состояний их организма.

Методологической основой проведенного исследования выступает положение, согласно которому, категория субъекта определяется в большей степени уровнем эволюции сознания. Сознание субъекта отличает рефлексивность, т.е. способность субъекта интерпретировать мир с различных углов зрения. Это предполагает большую осознанность происходящих событий, как во внутреннем, так и внешнем пространствах человека. В этой интерпретации уместно говорить о субъектности как мере осознанности тех или иных аспектов бытия человека [11].

Активность как один из атрибутов субъекта может иметь разные формы проявления, такие как внешне материально-преобразующую деятельность. При этом субъект учитывает последствия совершаемых им деяний, распределенных во времени. Активность также может иметь пассивную форму реализации, связанную с созерцательно-рефлексивными действиями субъекта. Изменения как следствие этой активности происходят во внутреннем пространстве субъекта. Отсюда вытекает гипотеза исследования, согласно которой успешность саморегулятивной активности связана с мерой субъектности в человеке. Такой подход не противоречит деятельностной теории сознания [12].

Цель исследования – оценить влияние психологических особенностей субъектов на результативность процессов саморегуляции.

Объект исследования – субъекты учебной деятельности, работающие по программе психофизической саморегуляции.

Предмет исследования – процесс влияния состояния сознания на успешность овладения техникой саморегуляции.

### **Методика исследований**

В исследовании приняли участие 31 мужчина в возрасте от 20 до 23 лет. Все участники исследования были проинформированы о его цели и проинструктированы о методиках тестирования. Методика исследования включала шесть этапов: 1 – предварительное измерение (определение начального функционального и психоэмоционального состояния испытуемых с помощью аппаратно-программного диагностического комплекса (АПДК) Silver Step Pulse); 2 – стимуляцию (методически организованный сеанс саморегуляции); 3 – определение функционального и психоэмоционального состояния испытуемых после сеанса саморегуляции; 4 – психологическое тестирование; 5 – обработку результатов измерений, полученных с помощью Silver Step Pulse; 6 – анализ результатов исследований. Длительность сеансов саморегуляции составляла 10 ÷ 20 минут. Применялись следующие психотехники аутотренинга, направленные на регуляцию физиологических параметров: абдоминальное дыхание, концентрация сознания на энергетических центрах, кокон, дыхание в мозг и другие.

Для объективных измерений динамики состояний: вегетативной нервной системы, нейрогуморальной регуляции, психоэмоционального состояния, спектрограммы головного мозга и других показателей использовался метод кардиоинтервалографии (КИГ), реализованный в АПДК Silver Step Pulse. В результате обработки кардиоинтервалов с помощью гистографического анализа вычисляется мода распределения, ее амплитуда и вариационный размах. На основании этих параметров вычисляется интегральный показатель – индекс напряжения (ИН). Он пропорционален средней частоте сердечных сокращений и обратно пропорционален диапазону, в котором варьирует интервал между соседними R-зубцами. ИН отражает степень вовлеченности организма в стресс.

Для определения меры субъектности в качестве методического инструмен-

тария в работе использовались опросник Кейрси и опросник «Диагностика субъектности» Е.Н. Волковой. Опросник Кейрси содержит четыре биполярные шкалы, отображающие содержание восьми психологических факторов темперамента:

1. Шкала Е-І – ориентация сознания: Е (экстраверсия) – ориентация сознания наружу, на объекты, І интроверсия) – ориентация сознания внутрь, на субъекта;
2. Шкала S-N – способ ориентировки в ситуации: S (здравый смысл) – ориентировка на конкретную информацию, N (интуиция) – ориентировка на обобщённую информацию;
3. Шкала Т-F – основа принятия решений: Т (мышление) – рациональное взвешивание альтернатив; F (чувство) – принятие решений на эмоциональной основе;
4. Шкала J-P – способ подготовки решений: J (суждение) – предпочтение планировать и заранее упорядочивать информацию, P (восприятие) – предпочтение действовать без детальной предварительной подготовки, больше ориентируясь по обстоятельствам.

В тесте «Диагностика субъектности» Е.Н. Волковой используются 6 шкал: осознанная активность, способность к рефлексии, свобода выбора и ответственность за него, осознание собственной уникальности, понимание и принятие других, саморазвитие.

### **Результаты исследований**

Из всех показателей функционального состояния организма, определяемых АПДК Silver Step Pulse, выбраны показатели активности мозга (дельта-, тета-, альфа-, бета-, гамма-ритмов) и функционального состояния (индексы адаптации, напряженности, вегетативного равновесия, ресурсов организма, энергетического баланса, психоэмоционального состояния, гармонизации биоритмов, вегетативной регуляции, нейрогуморальной регуляции, комплексный показатель здоровья).

Изменение состояния респондентов определялось по изменению показателей активности мозга и функционального состояния в результате сеансов само-

регуляции. Наличие механизмов саморегуляции организма должно приводить к каким-либо закономерностям во взаимном изменении этих показателей. Поэтому для данных каждого респондента рассчитывались коэффициенты корреляции для каждой пары показателей, из которых один или оба характеризуют активность мозга. Коэффициент корреляции считался значимым, если модуль его значение больше 0,6. Для каждого респондента с номером  $k$  определялось число значимых корреляций  $m_k$ . Считаем, что значение  $m_k$  характеризует успешность процессов саморегуляции каждого субъекта и, таким образом, является объективной оценкой достигнутого результата.

Характеристику меры субъектности получим, анализируя связь между объективными результатами саморегуляции и результатами психологического тестирования. Обозначим результаты тестирования респондента с номером  $k$  по каждой из шкал: экстраверсия –  $e_k$ , интроверсия –  $i_k$ , здравый смысл –  $s_k$ , интуиция –  $n_k$ , мышление –  $t_k$ , чувство –  $f_k$ , суждение –  $j_k$ , восприятие –  $p_k$ , осознанная активность –  $a_k$ , способность к рефлексии –  $r_k$ , свобода выбора и ответственность за него –  $c_k$ , осознание собственной уникальности –  $u_k$ , понимание и принятие других –  $b_k$ , саморазвитие –  $d_k$ .

Для исследуемой группы мужчин определялась возможная зависимость между числом значимых корреляций и значениями параметров для каждой шкалы. Из зависимостей  $m_k(e_k)$ ,  $m_k(i_k)$ ,  $m_k(s_k)$ ,  $m_k(n_k)$ ,  $m_k(t_k)$ ,  $m_k(f_k)$ ,  $m_k(j_k)$ ,  $m_k(p_k)$ ,  $m_k(a_k)$ ,  $m_k(r_k)$ ,  $m_k(c_k)$ ,  $m_k(u_k)$ ,  $m_k(b_k)$ ,  $m_k(d_k)$ , где  $k = 1, 2, \dots, 31$ , выделены зависимости, имеющие ненулевой наклон линии тренда.

Меру субъектности для группы определим следующим образом:

$$ms_k = e_k + n_k + f_k + p_k - a_k + r_k - c_k + u_k + b_k + d_k, \quad k = 1, 2, \dots, 31. \quad (1)$$

Знак, с которым шкала дает вклад в меру субъектности, определяется знаком тангенса угла наклона линии тренда на графике этой шкалы.

На Рис.1 продемонстрирована зависимость между числом значимых корреляций и мерой субъектности для всей группы: точки имеют координаты  $(m_k, ms_k)$ ,  $k = 1, 2, \dots, 31$ . Линия тренда имеет положительный коэффициент наклона. Коэффициент корреляции между параметрами  $(ms, m)$  равен 0,52.



Статистический разброс параметров, характеризующих способность к саморегуляции и меру субъектности, закономерен, так как обусловлен уникальностью психических и физиологических параметров каждого человека. В работе [13] исследованы особенности рефлексивности у экстра- и интровертов. Показано, что у интровертов в отличие от экстравертов существуют значительные различия в структуре взаимосвязей трёх типов рефлексии (онтогенетической, ауто- и социорефлексии) с другими включёнными в исследование показателями, причём показатель онтогенетической рефлексии у них является системообразующим.




Рис.1. Влияния меры субъектности на способность к саморегуляции у исходной группы мужчин.

Показатели экстра- и интроверсии играют важную роль в формуле (1). Разделим группу испытуемых из 31 мужчины на две подгруппы: экстраверты 17 человек, интроверты 14 человек. Зависимости между числом значимых корреляций и мерой субъектности для этих подгрупп показаны на Рис.2 и Рис.3.




Рис.2. Влияния меры субъектности на способность к саморегуляции у экстравертов.

Мера субъектности для подгруппы экстравертов вычислялась по формуле (1) с  $k = 1, 2, \dots, 17$ , коэффициент корреляции между параметрами ( $ms$ ,  $m$ ) в этом случае равен 0,43.

Мера субъектности для подгруппы интровертов вычислялась по формуле (2):

$$ms_k = i_k + n_k + f_k + p_k + a_k + r_k - c_k + u_k - b_k + d_k, \quad k = 1, 2, \dots, 14, \quad (2)$$

коэффициент корреляции между параметрами ( $ms$ ,  $m$ ) в этом случае равен 0,58.




Рис.3. Влияния меры субъектности на способность к саморегуляции у интровертов.

интровертов.

Ни одна из рассмотренных шкал не является определяющей, имеет значение совокупность психологических свойств личности. У интровертов и экстравертов положительный вклад в меру субъектности дают шкалы интуиция –  $n_k$ , чувство –  $f_k$ , восприятие –  $p_k$ , способность к рефлексии –  $r_k$ , осознание собственной уникальности –  $u_k$ , саморазвитие –  $d_k$ , а отрицательный здравый смысл –  $s_k$  (противоположность  $n_k$ ), мышление –  $t_k$  (противоположность  $f_k$ ), суждение –  $j_k$  (противоположность  $p_k$ ), свобода выбора и ответственность за него –  $c_k$ . Шкала осознанная активность –  $a_k$  дает положительный вклад в  $ms_k$  для интровертов и отрицательный для экстравертов, а понимание и принятие других –  $b_k$  дает отрицательный вклад в  $ms_k$  для интровертов и положительный для экстравертов.

В среднем по каждой подгруппе вклад в показатель способности к саморегуляции  $m$  дают показатели активности всех пяти ритмов мозга. Однако дифференцировано для каждого субъекта саморегуляции ситуация иная. В подгруппе экстравертов доля участников, у которых ритмы дельта, тета, альфа, бета, гамма дают пренебрежимо малый вклад в  $m_k$ , соответственно, равна 0,35, 0,29, 0,47, 0,18, 0,41. В подгруппе интровертов доля таких участников 0,29, 0,5, 0,36, 0,5, 0,57.

### **Заключение**

Саморегуляция как методика управления своим психофизиологическим состоянием может достигаться посредством воздействия индивида на самого себя при помощи слов - аффирмаций, мыслеобразов, регулирования мышечного тонуса и дыхания. В процессе сеансов саморегуляции происходят целенаправленные трансформации отдельных функций психики и нервно-психических реакций. Эти процессы реализуются через специфические взаимодействия подкорковых и префронтальных отделов коры головного мозга, что направляет деятельность организма на решение функциональных задач. Результатами саморегуляции являются устранение эмоционального напряжения, снятие утомления, активизация способностей, реализация обратной связи в ИМК и другие эффекты.

Полученные результаты показывают, что существует связь между способностью к саморегуляции и психологическим типом личности. Для оценки результатов саморегуляции предлагается число значимых значений коэффициентов корреляции между физиологическими и психофизиологическими показателями, изменяющимися в результате осознанной деятельности субъекта с мысленными образами во внутреннем пространстве. Вариативность физиологических и психологических параметров каждого субъекта саморегуляции требует разработки алгоритмов ИМК, реализующих дифференцированный подход к построению информационного образа субъекта.

#### Список литературы

1. Орлов В.А. Исследования в парадигме сокрытия информации: оценка фМРТ-данных на групповом уровне / В.А. Орлов, С.И. Карташов, Д.Г. Малахов и др. // Экспериментальная психология. — 2024. — Т. 17. — № 1. — С. 86 – 107.
2. Novoa R.F. Correlation between emotional state and functional activation with magnetic resonance imaging / R.F. Novoa, I.B. Ceressa, M.A. Oliva, et al // Rev Argent Radiol. — 2023. — V. 87(2). — P. 45 – 53.
3. Tsolakis A.C. Electroencephalography classification of healthy, mild cognitive impairment and probable Alzheimer’s disease through linear and non-linear biomarkers / A.C. Tsolakis, C. Timplalexis, M. Tsolaki, et al. // Medical Research Archives. — 2022. — V. 10. — I. 9. — P. 1 – 20.
4. Portillo-Lara R. Mind the gap: State-of-the-art technologies and applications for EEG-based brain–computer interfaces / Roberto Portillo-Lara, Bogachan Tahirbegi, Christopher A.R. Chapman, et al. // APL Bioengineering. — 2021. — V. 5. — 031507. P. 1 – 16.
5. Eskov V.M. New information technologies in the analysis of Electroencephalograms / V.M. Eskov, M.A. Filatov, V.V. Grigorenko, al. // Journal of Physics: Conference Series. — 2020. — **1679** 032081. — P. 1 – 5.
6. Еремин А.Л. Матрица локусов умственных функций в трехмерном пространстве мозга по нейровизуализации фМРТ / А.Л. Еремин, М.А. Рейес //

- Современные проблемы физики, биофизики и инфокоммуникационных технологий В.13. – Краснодар: ЦНТИ, 2023. С. 84 – 100.
7. Ossadtchi A. Neurofeedback learning modifies the incidence rate of alpha spindles, but not their duration and amplitude / A. Ossadtchi, T. Shamaeva, E. Okorokova, et al. // *Scientific reports*. — 2017. — **7(1)** 3772.
  8. Волкова К.В. Интерфейс мозг-компьютер: опыт построения, использования и возможные пути повышения рабочих характеристик / К.В. Волкова, Н.И. Дагаев, А.С. Киселев и др. // *Журнал высшей нервной деятельности*. — 2017. — Т. 67. — № 4. — Р. 504 – 520.
  9. Сухих С.А. Условия успеха саморегулятивной практики / С.А. Сухих, Н.М. Богатов, А.Н. Богатова // *Приверженность вопросам психического здоровья: материалы III Международной научно-практической конференции*. Москва, РУДН, 5–7 октября 2022 г. / под ред. О.Б. Михайловой, Е.Б. Башкина. – Москва: РУДН. — 2022. — С. 103 – 109.
  10. Богатов Н.М. Способность управления состоянием организма мужчин и женщин / Н.М. Богатов, А.Н. Богатова, С.А. Сухих и др. // *Нейроинформатика, её приложения и анализ данных: Материалы XXXI Всероссийского семинара, 29 сентября 2023 г. Красноярск*. Красноярск: Институт вычислительного моделирования СО РАН. — 2023. — С. 13 – 20.
  11. Каленов А.А. К вопросу понимания субъектности и ее структуры в научных исследованиях / А.А. Каленов // *Образование и воспитание*. — 2017. — № 1(11). — С.3–6.
  12. Серкин В.П. Деятельностная теория сознания (сознание как атрибут системы деятельностей субъекта) / В.П. Серкин // *Психология. Журнал Высшей школы экономики*. — 2015. — Т. 12. — №. 2. — С. 93 – 111.
  13. Валиуллина М.Е. Особенности рефлексивности у экстра- и интровертов / М.Е. Валиуллина // *Ученые записки Казанского университета*. — 2012. — Т. 154. — Кн. 6. — С. 224 – 232.

# МЕТОДЫ ПРОГНОЗИРОВАНИЯ ТЕЧЕНИЯ ЗАБОЛЕВАНИЙ СЕРДЕЧНО-СОСУДИСТОЙ СИСТЕМЫ

С.Е.Головенкин

Красноярский Государственный медицинский университет,  
кафедра факультетской терапии, [gse2008@mail.ru](mailto:gse2008@mail.ru)

Разработка математических методов решения медико-биологических задач ведется уже не одну сотню лет. Учеными предложено огромное количество способов проверки гипотез и продукции выводов. В истории разработки этих методов прослеживаются два периода наибольшего интереса теоретиков и практиков. Первый период наблюдался в 60-е годы, когда были разработаны методы анализа, получившие некоторое распространение и вызвавшие волну публикаций. Среди них - анализ Вальда [1], применяющийся до сих пор, матричные алгоритмы, основанные на анализе присутствия или отсутствия признаков [2], методы правдоподобия (анализ частот встречаемости признаков при двух или более заболеваниях [3]), алгоритмы, основанные на логике фазового интервала (состояние выражается в виде совокупности точек в пространстве признаков [4]), вероятностные методы [5]. Довольно широкую популярность приобрели алгоритмы, основанные на поиске клинического прецедента [6]. Общим признаком, объединяющим все эти и другие традиционные методы, несмотря на их разнообразие, является наличие явных алгоритмов принятия решений [7]. Диагностический алгоритм включает в себя совокупность правил, определяющих порядок переработки медицинской информации с целью постановки диагноза. Несмотря на то, что наиболее популярные методы до сих пор активно используются в теоретической биологии и медицине [8], в практической медицине они не нашли широкого применения. Это связано, во-первых, с тем, что методы, ориентированные на обработку групповых данных, слабо применимы к отдельным объектам, а во-вторых, с особенностями самой медико-биологической информации. Решения в медицинских и биологических задачах зависят от огромного количества неодинаковых по значимости факторов. Поэтому, даже если удастся выстроить правила вывода, связывающие условия задачи с решением, метод, как правило, хоро-

шо работает только на той группе объектов, на которой производились исследования. Естественно, создать универсальный алгоритм невозможно, и при использовании метода для другой подобной группы объектов его приходится полностью переконструировать практически заново. Многолетние исследования, проводимые с самыми различными явными алгоритмами, показали, что медицинские задачи, имеющие неявный характер, решаются явными методами с точностью и удобством, совершенно недостаточными для широкого практического использования в конкретных задачах диагностики, прогнозирования и принятия решений. Поэтому в настоящее время наблюдается второй всплеск интереса к диагностическим системам. Он направлен на принципиально новое поколение решающих алгоритмов, являющихся неявными и обладающих способностью к самонастройке, которая может осуществляться на минимальном количестве данных. Основной группой таких алгоритмов, развиваемой сейчас наиболее интенсивно, являются нейросетевые методы [9].

Поиски и изучение неявных алгоритмов, позволяющих автоматически накапливать и затем использовать опыт при обучении, продолжаются уже более 100 лет. Однако первые серьезные попытки создания нейронных сетей были сделаны в 40-50-х годах, когда У.Маккалох и У.Питтс выдвинули основные положения теории работы головного мозга. Естественно, что с появлением дешевых ЭВМ произошел резкий скачок в этой области, которая в начале 80-х годов сформировалась в целую науку - нейроинформатику [10].

Неявные задачи медицины и биологии явились идеальным полем для применения нейросетевых технологий, и именно в этой области наблюдается наиболее яркий практический успех нейроинформационных методов.

Наибольший интерес для практического здравоохранения представляют системы для диагностики и дифференциальной диагностики заболеваний. При этом для принятия решений могут использоваться самые разнообразные данные - анамнез, клинический осмотр, результаты лабораторных тестов и сложных функциональных методов. Список областей медицины, в которых начали применяться новые технологии, чрезвычайно обширен и продолжает расти.

В области пульмонологии начаты исследования по применению нейрон-

ных сетей для дифференциальной диагностики интерстициальных заболеваний легких [11]. Конструируемая система обучается различать 9 диагнозов по 20 параметрам клинического состояния и данным рентгенографии. Появились работы с применением нейротехнологий для диагностики бронхиальной астмы [12], острой тромбоэмболии легких [13], рака легких [14]. Несколько работ посвящено решению задачи определения оптимальных параметров искусственного дыхания [15, 16]. Нейронные сети обучаются поддерживать оптимальный режим вентиляции легких и работают более гибко, чем системы, основанные на жестком алгоритме.

Одним из наиболее интенсивно развиваемых направлений является применение нейросетей в кардиологии.

В Италии разработана чрезвычайно интересная экспертная система для диагностики и лечения артериальной гипертонии [17]. Система включает в себя три нейросетевых модуля, причем ответы одних являются входными данными для других. В начале исследования больному проводят измерение систолического и диастолического давления каждые полчаса в течение суток. Данные за каждый час усредняются. Таким образом, образуется массив из 48 величин артериального давления (по 24 для систолического и диастолического). После этого первый модуль, состоящий из двух трехслойных нейросетей (в каждой из которых 2 входных, 4 "скрытых" и 24 выходных нейрона), на основании данных о поле и возрасте больного рассчитывает аналогичные "должные" величины и сравнивают их с реальными. Параллельно второй модуль (двухслойная нейросеть с 17 входными и 4 выходными нейронами) на основании клинических данных (симптоматика, анамнез) рассчитывает возможные сочетания гипотензивных лекарственных средств, которые могут быть использованы для лечения данного больного. Данные, снятые с выходов обоих модулей, вместе с клиническими данными подаются на вход последнего, третьего модуля (6-слойная нейросеть). Этот модуль оперирует 4 группами гипотензивных препаратов (диуретики, бетаадреноблокаторы, ингибиторы ангиотензина, блокаторы кальциевых каналов). Цель - назначить суточный (почасовой) график приема больным лекарств каждой (если требуется) из 4 групп. Поэтому этот модуль имеет 96 вы-



ходных нейронов (4 препарата x 24 часа). С каждого выходного нейрона снимается доза, соответствующая одному препарату, назначаемому на данный час суток. Естественно, что в реальной ситуации большинство выходных данных равны нулю. Таким образом, создается оптимальная для пациента схема лечения гипертонии. Нужно отметить, что система учитывает некоторые особенности приема препаратов больными, например, затруднение приема препаратов ночью (назначает ночной прием только в крайних случаях), запрет на назначение мочегонных лекарств на ночь. Отличительной чертой системы является возможность пользователя (врача) передавать нейронной сети свой опыт. Для этого создателями программы предусмотрен специальный блок, который выводит на экран компьютера суточные кривые артериального давления и предлагает врачу ввести в компьютер суточную схему приема гипотензивных препаратов в необходимых, по его мнению, дозах. Введенный пример помещается в базу данных. В любое время можно инициировать доучивание нейронных сетей с новыми примерами.

В работе [18] описывается нейронная сеть для диагностики коронарного атеросклероза на ранних стадиях. Диагноз выставляется на основании таких параметров, как пол, возраст, вес, рост, курительные привычки; данных семейного анамнеза, наличия у обследуемого диабета, показателей систолического и диастолического артериального давления, уровня холестерина и липопротеидов различных классов в крови.

Большое внимание уделяется применению нейросетей для диагностики атеросклероза. Нейросети могут проводить диагностику и определение стадии атеросклероза по рентгенологическим данным [19] и по акустическим сигналам [20].

Проводится комплекс исследований по использованию нейросетей для диагностики инфаркта миокарда [21]. Автор приводит данные по чувствительности (77,7%) и специфичности (97,2%) нейросетевого теста. В работе, кроме того, с помощью нейронной сети устанавливали диагностическую значимость клинических параметров при диагностике инфаркта миокарда.

Нейросети используются терапевтами для диагностики заболеваний печени по лабораторным данным исследования функций печени [22], желчного пу-

зыря [23], диагностики панкреатита [24], изучения характера камней в почках [25].

Актуальная проблема диагностики злокачественных новообразований, возможно, получит новый уровень осмысления с началом применения нейроалгоритмов. Так, в работе [26] показана 80%-я точность ранней диагностики меланом кожи - одного из самых злокачественных новообразований. Наличие скрытых метастазов этого же заболевания определяется с помощью нейросетевой интерпретации данных хроматографии мочи.

Описываются методы диагностики почечных карцином по данным УЗИ [27] и гепатоцеллюлярных карцином по данным ядерной морфометрии [28], ранняя диагностика рака печени по данным рентгенограмм и ультрасонограмм [29], диагностика и прогноз рака простаты [30], диагностика остеопороза и костных образований, а также дифференциальная диагностика злокачественных и доброкачественных костных опухолей [31].

Большое внимание в публикуемых работах уделяется нейросетевой диагностике опухолей молочной железы, представляющих серьезную медико-социальную проблему. Так, по 9 параметрам анализа крови осуществляется дифференциальная диагностика злокачественных и доброкачественных опухолей молочной железы [32]. Однако, описываемая нейросеть смогла обучиться ставить верный диагноз только у 80% примеров обучающей выборки. Результат тестирования на контрольной выборке - 84% верных диагнозов. Диагностику опухолей молочной железы проводят также по данным УЗИ [33].

Классической проблемой в кардиологии является интерпретация электрокардиограмм, требующая значительного опыта врача. Сотрудники Университета Глазго (Великобритания) ведут исследования по применению нейросетей для ЭКГ-диагностики инфарктов миокарда [34]. Входными данными для сетей являются избранные параметры 12-канальной электрокардиограммы и 12-канальной векторкардиограммы (длины зубцов, расстояния между зубцами). Исследователи обучили огромное количество нейросетей (167 сетей для диагностики инфаркта миокарда передней стенки и 139 сетей для инфаркта нижней стенки) на массиве данных из 360 электрокардиограмм. Обученные сети затем тестировали отдель-

ную выборку с заранее известными ответами (493 случая). Одновременно для получения отдельной серии ответов на тестируемой выборке был использован логический метод (с заранее заданным алгоритмом). Затем сравнивались результаты тестирования выборки лучшими нейросетями и с помощью логического алгоритма. Сравнение показало, что во многих случаях чувствительность и специфичность нейросетевого теста оказались выше, чем у логического метода. Авторы делают справедливый вывод, что в случаях, когда логический алгоритм решения задачи все-таки можно выстроить, разумно комбинировать в экспертных системах оба подхода. Эти же авторы применили нейросети для дифференцировки фибрилляции предсердий от желудочковых и наджелудочковых экстрасистол, возникающих на фоне синусового ритма.

Интерпретация ЭКГ с помощью нейросетей [35] была применена для диагностики злокачественных желудочковых аритмий. Трехслойная сеть с 230 входными синапсами была обучена на 190 пациентов (114 с хронической сердечной недостаточностью и 34 с дилатационной миокардиопатией) различать наличие (у 71 пациента) и отсутствие (у 119 пациентов) желудочковой тахикардии. Результаты тестирования сравнивались с логическим методом интерпретации данных. Показано, что нейросетевой тест обладает большей чувствительностью (73% по сравнению с 70 для логического метода) и специфичностью (83 и 59%). Эти же авторы использовали нейронные сети для интерпретации ЭКГ в диагностике дилатационных кардиомиопатий.

Интересная работа описывает моделирование применения нейросетей для работы электрокардиостимуляторов (искусственных водителей ритма) [36]. Выпускаемые за рубежом электрокардиостимуляторы задают ритм не жестко, а в зависимости от исходного ритма, генерируемого синусовым узлом сердца. Например, если синусовый узел при какой-либо патологии генерирует недостаточное количество импульсов, водитель ритма компенсирует ритм. Таким образом, электрокардиостимулятор представляет собой систему вход→преобразование→выход, где входом является ритм синусового узла, выходом - собственный ритм электрокардиостимулятора, а преобразование осуществляется по заданному логическому алгоритму. Авторы смоделировали заме-

ну логического преобразователя нейронной сетью, так как взаимоотношения между генерацией импульсов в синусовом узле и требуемым ритмом не линейны и применяемые алгоритмы на практике не всегда эффективны. Нейросеть, обученная на 27 здоровых людях в ситуациях с различной физической нагрузкой, показала гораздо лучшую способность задавать ритм, чем логический алгоритм, применяющийся в электрокардиостимуляторе.

Созданы нейросетевые экспертные системы для классификации опухолей молочной железы (определения, доброкачественная опухоль, или злокачественная) по данным маммографии (сканограмма молочной железы) [37]. По данным, которые приводят авторы, точность такого вывода до применения нейросети составляла не более 75%. При тестировании системы, нейросеть, анализирующая сканограмму, давала правильный ответ в 100% случаев. При тестировании изображения, получаемое в результате метода, представляется в виде матрицы точек размером 1024x1024 пиксела с 10-битовой шкалой яркости. Изображение подается на нейросеть, имеющую 2 входных, 80 "скрытых" и 2 выходных нейрона. При этом один из выходных нейронов "отвечает" за доброкачественную опухоль, другой за злокачественную. Диагноз определяется в зависимости от выходного нейрона, выдавшего больший по величине ответ. Столь высокий процент правильности распознавания, возможно, случаен, и объясняется недостаточным количеством примеров, использовавшихся при обучении и тестировании нейросети (по 10 примеров). Однако даже при такой малой обучающей выборке нейросеть выигрывала по сравнению с традиционным методом интерпретации сканограммы.

Несколько работ посвящены нейросетевой обработке лабораторных анализов и тестов. Приводится нейросетевой метод интерпретации лабораторных данных биохимического анализа крови [38]. В работе показаны преимущества нейронных сетей в сравнении с линейным дискриминантным анализом, которым параллельно обрабатывались данные. Описываются обработка нейросетями цитогенетических данных [39] и интерпретация данных иммунного анализа [40].

Особое место среди нейросетевых экспертных систем занимают прогностические модели, применяемые, например, для прогнозирования исходов забо-

леваний.

В 1990 году американская фирма "Апачи Медикл Системз Инк." установила в реанимационном отделении одной из больниц штата Мичиган экспертную систему "Апачи - III" [41]. Ее цель - прогнозирование исхода заболевания у больных, находящихся в тяжелом состоянии. Для прогноза в компьютер необходимо ввести 27 параметров больного: первичный диагноз, симптомы, степень утраты сознания, наличие или отсутствие СПИД и других заболеваний. После этого система выдает вероятность выживания больного в диапазоне от 0 до 100 процентов. Ценность применения системы заключается в том, что она позволяет очень быстро оценить динамику изменения состояния больного, незаметную "на глаз". Например, можно получить ответ у системы до и после введения какого-либо лекарства, и, сравнив ответы, посмотреть, будет ли наблюдаться эффект от терапии. Без программы же изменение состояния иногда не удастся обнаружить в течение нескольких дней. Тестирование показало, что прогноз, который делает программа, сбывается с точностью 97%, что значительно точнее, чем у лучших врачей. Необходимо отметить, что система была обучена на данных, взятых из историй болезней 17448 пациентов, лечившихся в 40 больницах штата в 1989 году. Очевидно, что если качество работы системы обеспечивается таким большим объемом выборки, возможности перенастройки системы не слишком велики. Идеология авторов, создавших эту систему, заключается в как можно большем охвате различных примеров и вариантов (сбор данных в 40 больницах), а не в возможности индивидуализации системы к конкретной клинике. Поэтому данная система не способна к подучиванию в процессе работы, опыт "защит" в нее жестко. Это может быть существенным недостатком при установке программы в регионы, резко отличающиеся по социально-географическим условиям от тех, где проводилось обучение. Кроме того, огромный массив примеров для обучения повышает стоимость программы.

Прогностические нейросетевые модели могут использоваться в демографии и организации здравоохранения. Создана экспертная система, предсказывающая, умрет ли человек (в возрасте 55 лет и старше) в ближайшие 10 лет. Прогноз делается по результатам ответов на 18 вопросов анкеты. В анкету включены

такие вопросы, как раса, пол, возраст, вредные привычки, семейное положение, семейный доход. 4 из 18 вопросов выявляют индекс массы тела (body mass index) в различные периоды жизни респондента. Индекс рассчитывается как отношение веса к квадрату роста (индекс более 27 кг/м считается тучностью). Повышенное внимание к этому показателю говорит о его значимости для прогноза жизни.

Развитие нейросетевых методов дает возможность их использования как инструмента научных исследований, с помощью которого можно изучать объекты и явления.

Судя по литературным данным, именно биологические научные исследования являются наиболее развиваемой областью применения нейросетей [42]. В последнее время биологи, знакомые с исследованиями в области нейроинформатики, приходят к выводу, что многие системы в живых организмах работают по принципам, сходным с алгоритмами нейронных сетей (или наоборот, нейронные сети работают по принципу биосистем). Таким образом, можно наблюдать "взаимное стимулирование" научных разработок в биологии и нейроинформатике. В работе [43] эндокринная система человека рассматривается как нейронная сеть из 30 элементов, которые представлены различными гормонами, взаимодействующими друг с другом с помощью прямых и обратных связей. Похожие исследования проводятся для иммунной системы [44]. Японские ученые [45] использовали нейросеть для экспериментов по моделированию нервной системы простых организмов.

Применение нейросетей для исследований в области нейрофизиологии строится на похожих принципах функционирования нейросетей и нервных структур живых организмов. С помощью нейросети осуществлена попытка моделирования простейшей нервной системы [46], ассоциативной памяти [47], глазодвигательной функции [48], функции мочевого пузыря [49].

Сделана попытка применения нейросети для классификации живых организмов [50]: нередко биологам, открывающим новые виды организмов, требуется определить, к какому виду (классу, типу) относится тот или иной представитель флоры или фауны (как правило, это касается микроорганизмов и растений). Система способна работать при отсутствии некоторых входных данных. Это яв-

ляется существенным преимуществом, так как часто при изучении живых объектов не всегда возможно получить всю необходимую информацию

Таким образом, обзор публикаций, посвященный применению экспертных систем в медицине и биологии позволяет сказать, что математические методы и вычислительная техника уверенно вошли в нашу жизнь и успешно помогают человеку в научных исследованиях и практической деятельности.

#### Список литературы

1. Вальд А. Последовательный анализ. М.: Физматгиз, 1960.- 76 с.
2. Быховский М.Л., Вишневский А.А., Харнас С.Ш. Вопросы построения диагностического процесса при помощи математических машин // Экспериментальная хирургия и анестезиология.- 1961.- N.4.- С.3-15.
3. Lipkin M. The likelihood concept in differential diagnosis // Perspect. Biol. Med.- 1964.- N.7.- P.485-497.
4. Быховский М.Л. Метод фазового интервала в проблеме диагностики // Экспериментальная хирургия и анестезиология.- 1962.- N.2.- С.16-19.
5. Todd B.S., Stamper R., Macpherson P. A probabilistic rule-based expert system // Int. J. Biomed. Comput.- 1993.- V.33, N.2.- P.129-148.
6. Артоболевский И.И., Вишневский А.А., Быховский М.Л. Информационно-поисковые системы в медицине // Машинная диагностика и информационный поиск в медицине.- М.: Наука, 1969.- С.19-34.
7. Гублер Е.В. Вычислительные методы анализа и распознавания патологических процессов. Л.: Медицина, 1978.- 294 с.
8. Марасанов В.В. Математические модели дифференциальной диагностики заболеваний. Кишинев: Штиинца, 1973.- 62 с.
9. Shufflebarger C.M. What is neural network? // Ann. Emerg. Med.- 1992.- V.21, N.12.- P.1461-1462.
10. Stefanuk V.L. Expert systems and its applications // The lectures of Union's workshop on the main problems of artificial intelligence and intellectual systems. Part 2, Minsk, 1990.- P.36-55.

11. Asada N., Doi K., MacMahon H. et al. Potential usefulness of an artificial neural networks for differential diagnosis of interstitial lung diseases: pilot study // *Radiology*.- 1990.- V.177, N.3.- P.857-860.
12. Moseholm L., Taudorf E., Frosig A. Pulmonary function changes in asthmatics associated with low-level SO<sub>2</sub> and NO<sub>2</sub> air pollution, weather, and medicine intake. An 8-month prospective study analyzed by neural networks // *Allergy*.- 1993.- V.48, N.5.- P.334-344.
13. Patil S., Henry J.W., Rubenfire M. et al. Neural network in the clinical diagnosis of acute pulmonary embolism // *Chest*.- 1993.- V.104, N.6.- P.1685-1689.
14. Chiou Y.S., Lure Y.M. Hybrid lung nodule detection (HLND) system // *Cancer Lett.*- 1994.- V.77, N.2-3.- P.119-126.
15. Ashutosh K., Lee H., Mohan C.K et al. Prediction criteria for successful weaning from respiratory support: statistical and connectionist analyses // *Crit. Care Med.*- 1992.- V.20, N.9.- P.1295-1301.
16. Snowden S., Brownlee K.G., Smye S.W. et al. An advisory system for artificial ventilation of the newborn utilizing a neural network // *Med. Inf. Lond.*- 1993.- V.18, N.4.- P.367-376.
17. Poli R., Cagnoni S., Livi R. et al. A Neural Network Expert System for Diagnosing and Treating Hypertension // *Computer*.- 1991.- N.3.- P.64-71.
18. Bertolucci E., Mariotti R., Biadi O. et al. Two different neural network models for coronary artery disease classification // *Eur. Heart J.*- 1993.- V.14.- Abstr. Supplement XVth Congress of the European Society of Cardiology, August, 1993.- (348).- P.23.
19. Fujita H., Horita K., Endo T. et al. Neural Network Approach to Classification of Benign and Malignant Tumours in Mammograms // *Med. Imag. Tech.*- 1992.- V.10.- P.126-129.
20. Akay M., Welkowitz W. Acoustical detection of coronary occlusions using neural networks // *J. Biomed. Eng.*- 1993.- V.15, N.6.- P.469-473.
21. Baxt W.G. A neural network trained to identify the presence of myocardial infarction bases some decisions on clinical associations that differ from accepted clinical teaching // *Med. Decis. Making*.- 1994.- V.14, N.3.- P.217-222.



- 22.Okamoto Y., Nakano H., Yoshikawa M. et al. Study on decision support system for the interpretation of laboratory data by an artificial neural network // *Rinsho. Byori.*- 1994.- V.42, N.2.- P.195-199.
- 23.Rinast E., Linder R., Weiss H.D. Neural network approach for computer-assisted interpretation of ultrasound images of the gallbladder // *Eur. J. Radiol.*- 1993.- V.17, N.3.- P.175-178.
- 24.Kazmierczak S.C., Catrou P.G., Van-Lente F. Diagnostic accuracy of pancreatic enzymes evaluated by use of multivariate data analysis // *Clin. Chem.*- 1993.- V.39, N.9.- P.1960-1965.
- 25.Volmer M., Wolthers B.G., Metting H.J. et al. Artificial neural network predictions of urinary calculus compositions analyzed with infrared spectroscopy // *Clin. Chem.*- 1994.- V.40, N.9.- P.1692-1697.
- 26.Ercal F., Chawla A., Stoeker W.V. et al. Neural network diagnosis of malignant melanoma from color images // *IEEE Trans. Biomed. Eng.*- 1994.- V.41, N.9.- P.837-845.
- 27.Maclin P.S., Dempsey J., Brooks J. et al. Using neural networks to diagnose cancer // *J. Med. Syst.*- 1991.- V.15, N.1.- P.11-19.
- 28.Erler B.S., Hsu L., Truong H.M. et al. Image analysis and diagnostic classification of hepatocellular carcinoma using neural networks and multivariate discriminant functions // *Lab. Invest.*- 1994.- V.71, N.3.- P.446-451.
- 29.Maclin P.S., Dempsey J. How to improve a neural network for early detection of hepatic cancer // *Cancer Lett.*- 1994.- V.77, N.2-3.- P.95-101.
- 30.Snow P.B., Smith D.S., Catalona W.J. Artificial neural networks in the diagnosis and prognosis of prostate cancer: a pilot study // *J. Urol.*- 1994.- V.152, N.5.- P.1923-1926.
- 31.Piraino D.W., Amartur S.C., Richmond B.J et al. Segmentation of magnetic resonance images using an artificial neural network // *Proc. Annu. Symp. Comput. Appl. Med. Care.*- 1991.- P.470-472.
- 32.Astion M.L., Wilding P. Application of neural networks to the interpretation of laboratory data in cancer diagnosis // *Clin. Chem.*- 1992.- V.38, N.1.- P.34-38.

33. Goldberg V., Manduca A., Ewert D.L. et al. Improvement in specificity of ultrasonography for diagnosis of breast tumours by means of artificial intelligence // Med. Phys.- 1992.- V.19, N.6.- P.1475-1481.
34. Yang T.-F., Devine B., Macfarlane P.W. Combination of artificial neural networks and deterministic logic in the electrocardiogram diagnosis of inferior myocardial infarction // Eur. Heart J.- 1994.- V.15.- Abstr. Supplement XII-th World Congress Cardiology (2408).- P.449.
35. Bortolan G., Willems J.L. Diagnostic ECG classification based on neural networks // J. Electrocardiol.- 1993.- V.26, Suppl.- P.75-79.
36. Nakajima H., Anbe J., Egoh Y. et al. Evaluation of neural network rate regulation system in dual activity sensor rate adaptive pacemaker // European Journal of Cardiac Pacing and Electrophysiology.- Abstracts of 9th International Congress, Nice Acropolis - French, Rivera, June 15-18, (228), 1994.- Rivera, 1994.- P.54.
37. Zhang W., Doi K., Giger M.L. et al. Computerized detection of clustered microcalcifications in digital mammograms using a shift-invariant artificial neural network // Med. Phys.- 1994.- V.21, N.4.- P.517-524.
38. Reinberger G., Weiss G., Werner-Felmayer G. et al. Neural networks as a tool for utilizing laboratory information: comparison with linear discriminant analysis and with classification and regression trees // Proc. Natl. Acad. Sci., USA.- 1991.- V.88, N.24.- P.11426-11430.
39. Molnar B., Szentirmay Z., Bodo M. et al. Application of multivariate, fuzzy set and neural network analysis in quantitative cytological examinations // Anal. Cell Pathol.- 1993.- V.5, N.3.- P.161-175.
40. Vertosick F.T., Rehn T. Predicting behavior of an enzyme-linked immunoassay model by using commercially available neural network software // Clin. Chem.- 1993.- V.39, N.12.- P.2478-2482.
41. Шварц Э., Трис Д. Программы, умеющие думать // Бизнес Уик.- 1992.- N.6.- С.15-18.
42. Karim M.N., Rivera S.L. Artificial neural networks in bioprocess static estimation // Adv. Biochem. Eng. Biotechnol.- 1992.- N.46.- P.1-33.

43. Budilova E.V., Teriokhin A.T. Endocrine networks // The RNNS/IEEE Symposium on Neuroinformatics and Neurocomputers, Rostov-on-Don, Russia, October 7-10, 1992.- Rostov/Don, 1992.- V.2.- P.729-737.
44. Varela F.J., Coutinho A., Dupire B. et al. Cognitive networks: immune, neural and otherwise // Theoretical immunology. Ed. by Perelson A.- Addison Wesley, 1988.- Part 2.- P.359-375.
45. Yamada S., Nakashima M., Shiono S. Neural Network Model to Simulate Neuronal Responses of Aplysia Gillwithdrawal Reflex // Proceedings of 1993 International Joint Conference on Neural Networks, Nagoya, Japan, October 25-29, 1993.- Nagoya, 1993.- V.1.- P.37-40.
46. Van Leeuwen J.L. Neural network simulations of the nervous system // Eur. J. Morphol.- 1990.- V.28, N.2-4.- P.139-147.
47. Carrie J.R. Evaluation of a neural network model of amnesia in diffuse cerebral atrophy // Br. J. Psychiatry.- 1993.- V.163.- P.217-222.
48. Doricchi F., Guariglia C., Paolucci S. et al. Disturbances of the rapid eye movements (REMs) of REM sleep in patients with unilateral attentional neglect: clue for the understanding of the functional meaning of REMs // Electroencephalogr. Clin. Neurophysiol.- 1993.- V.87, N.3.- P.105-116.
49. Bastiaanssen E.H., Vanderschoot J., Van-Leeuwen J.L. Learning procedure in a neural control model for the urinary bladder // Neurorol. Urodyn.- 1993.- V.12, N.3.- P.285-288.
50. Senna A.L., Junior W.M., Carvalho M.L.B., Siqueira A.M. Neural Networks in Biological Taxonomy // Proceedings of 1993 International Joint Conference on Neural Networks, Nagoya, Japan, October 25-29, 1993.- Nagoya, 1993.- V.1.- P.33-36.

# НЕЙРОСЕТЕВОЙ АНАЛИЗ ЗНАЧИМОСТИ ВХОДНЫХ ПАРАМЕТРОВ МОДЕЛИ ПРЕДСКАЗАНИЯ ПОСЛЕДУЮЩЕЙ УСПЕВАЕМОСТИ СТУ- ДЕНТОВ, ЗАЧИСЛЕННЫХ В УНИВЕРСИТЕТ ПО ИТОГАМ ВСТУПИ- ТЕЛЬНОГО ОНЛАЙН-ЭКЗАМЕНА

М.В. Гунер<sup>1,2</sup>

<sup>1</sup> ФГАОУ ВО «Сибирский федеральный университет»,  
институт космических и информационных технологий,  
каф. систем искусственного интеллекта

<sup>2</sup> ФГБОУ ВО «Алтайский государственный технический университет  
им. И.И. Ползунова», факультет информационных технологий,  
каф. информационных систем в экономике, *horyzont1@mail.ru*

Процесс зачисления в университет требует проведения вступительных испытаний, целью которых является отбор наиболее подготовленных студентов. Настоящая работа посвящена проблемам онлайн-экзамена как инструмента такого отбора: насколько сильно коррелируют рейтинги поступающих по итогам вступительного экзамена и по итогам экзаменационных сессий на первом курсе, возможно ли предсказать показатели последующей успеваемости студентов, зачисленных по итогам онлайн-экзамена.

**Исходные данные.** В качестве исходных данных в работе были взяты сведения о поступлении и последующем обучении 553 студентов, зачисленных в 2020 г. (период пандемии COVID-19) на программы бакалавриата и специалитета в один из российских университетов в том числе по итогам вступительного онлайн-экзамена по математике.

Входные параметры модели предсказания последующей успеваемости лиц, зачисленных в университет, включали время прохождения теста, социально-демографические факторы, входной рейтинг поступающего по математике, средний входной рейтинг поступающего по итогам сдачи других вступительных экзаменов, сведения о конкурсной ситуации и сведения о зачислении.

К числу социально-демографических факторов были отнесены возраст и

пол поступающего, уровень предыдущего образования, сколько лет прошло с момента получения предыдущего образования, страна и регион проживания, поступающий из городской или сельской местности. Сведения о конкурсной ситуации: средний входной рейтинг по математике всех зачисленных; средний входной рейтинг по математике лиц, зачисленных в университет из числа выпускников образовательного учреждения, которое заканчивал поступающий (бывших одноклассников или одногруппников); средний входной рейтинг по математике лиц, зачисленных в университет на ту же специальность и ту же форму обучения (одногогруппников). Сведения о зачислении: форма обучения и категория зачисления, укрупненная группа направлений подготовки и специальностей (УГНС).

В качестве метрики самостоятельности прохождения онлайн-тестирования и оценки последующей успеваемости по математике была взята разница в рейтингах до и после зачисления (выходной параметр). Положительное значение разницы свидетельствует о том, что студент показывает в ходе обучения в университете лучшие результаты по математике и вероятно не пользовался сторонней помощью на вступительном экзамене. Отрицательное значение разницы может говорить об особенностях шкалирования, о более сложной программе математических дисциплин в университете, о трудностях адаптации первокурсника к образовательному процессу, а может указывать на мошеннические действия поступающего на онлайн-экзамене.

Все качественные параметры были закодированы. Пол поступающего: 0 – женский, 1 – мужской. Уровень предыдущего образования: 1 – среднее (полное) общее, 2 – среднее профессиональное, 3 – высшее. Населенный пункт местожительства поступающего: 0 – относится к сельской местности, 1 – относится к городской местности. Форма обучения: 0 – заочная, 0.5 – очно-заочная, 1 – очная. Страна и регион проживания поступающего, категория зачисления, укрупненная группа направлений подготовки и специальностей (УГНС) были закодированы посредством метода 1-из-N.

**Анализ распределения выходного параметра модели.** Распределение

разницы в рейтингах поступающих по математике до и после зачисления показано на рис. 1. Как видно из гистограммы, в абсолютном большинстве случаев значение этой разницы было отрицательным, т.е. в ходе обучения университета студенты чаще демонстрируют результаты хуже, чем те, что были по итогам вступительного онлайн-экзамена.



Рис. 1. Гистограмма распределения разницы в рейтингах поступающих по математике

по итогам вступительного онлайн-экзамена (до зачисления)

и по итогам экзаменационных сессий на 1-ом курсе (после зачисления)

В статье [1] приводились возможные причины такой значимой разницы в рейтингах, а также давалась оценка степени влияния этих причин:

- особенности шкалирования, личные проблемы поступающих (сложность адаптации к образовательному процессу в университете, нехватка времени, смена интересов) (37%, в баллах: 16.9 из 45.6);

- дистанционный (частично-дистанционный) формат обучения на первом курсе (17%, в баллах: 7.7 из 45.6);

- онлайн-формат проведения вступительного экзамена (46%, в баллах: 21 из 45.6).

Проблема выявления мошеннических действий со стороны поступающих на онлайн-экзамене представляет большой интерес.

**Анализ значимости входных параметров модели посредством обучения и тестирования нейронных сетей на подвыборках с различным набором входов.** Коэффициенты корреляции – хороший инструмент поиска зависимостей между параметрами, но он позволяет выявлять лишь линейные зависимости. С целью поиска нелинейных зависимостей были проведены множественные эксперименты по обучению и тестированию нейронных сетей (многослойных перцептронов) [2] на подвыборках с различным набором входов.

Прежде всего, исходная выборка была поделена на обучающее и тестовое множества численностью примеров 80% и 20% соответственно.

Далее были определены наборы параметров предобработки данных и обучения нейронных сетей, значения которых экспериментально подбирались в целях минимизации средней ошибки на тестовом множестве (см. таблица 1).

Таблица 1

Оптимизируемые параметры предобработки данных и обучения  
нейронных сетей

Наименование параметра	Варианты значений
Нормализация данных	да (Z-нормализация) (на основе среднего значения и стандартного отклонения) [3] / нет
Метод главных компонент (количество главных компонент)	да (3) / да (7) / нет
Обучение по батчам (пакетам) (размер батча)	32 / 64 / 128 / нет (вся выборка целиком)
Структура нейронной сети	(5), (5, 5), (5, 5, 5),

(многослойного персептрона) (количество нейронов на скрытых слоях)	(10), (10, 10), (10, 10, 10), (20), (20, 20), (20, 20, 20), (50), (50, 50), (50, 50, 50), (100), (100, 100), (100, 100, 100)
Функция активации нейронов	Sigmoid (сигмоида) / ReLU (с батч-нормализацией)
Скорость обучения	0.001 постоянная / 0.01 постоянная / 0.01 на старте с уменьшением каждые 500 эпох (умножение на коэффициент 0.9) / 0.01 на старте с уменьшением каждые 500 эпох (умножение на коэффициент 0.5) 0.01 на старте с уменьшением каждые 1000 эпох (умножение на коэффициент 0.9) / 0.01 на старте с уменьшением каждые 1000 эпох (умножение на коэффициент 0.5)
Максимальное количество эпох	3000

Метод анализа значимости входных параметров модели посредством применения нейросетевых технологий основан на идее, что добавление или удаление значимого входа должно привести к значимому изменению ошибки. Для апробации этого подхода было обучено большое количество нейронных сетей с различными параметрами, после чего отобраны 100 наилучших из них (таблица 2). Основным критерий успешности обучения сети – как можно меньшая средняя ошибка на тестовых данных.

В таблице 2 в колонке «Скорость обучения» в скобках приводятся параметры корректировки скорости обучения (каждые N эпох выполняется умножение текущей скорости обучения на коэффициент K). «Номер эпохи» в последней колонке сообщает, когда была достигнута наилучшая (минимальная) средняя ошибка на тестовых данных.



Таблица 2

Фрагмент таблицы с результатами 100 наилучших экспериментов по обучению нейронных сетей решению задачи предсказания последующей успеваемости лиц, зачисленных в университет (разницы в рейтинге по математике до и после зачисления)

№ п/п	Нормализация данных	Количество главных компонент	Размер батча	Количество нейронов на скрытых слоях	Функция активации нейронов	Скорость обучения	Средняя ошибка на обучающих данных	Наилучшая (минимальная) средняя ошибка на тестовых данных	Номер эпохи <sup>2</sup>
1	да	-	64	(20, 20, 20)	ReLU	0.001 постоянная	5.6642	14.5421	697
2	да	-	64	(200)	Sigmoid	0.01 (1000, 0.9)	13.512 8	14.5932	1463
...									
9	да	-	128	(50, 50, 50)	Sigmoid	0.01 постоянная	10.550 1	14.8917	178
...									
19	да	-	128	(20)	ReLU	0.001 постоянная	10.600 9	14.9449	1817
...									

44	да	3	-	(10, 10, 10)	ReLU	0.01 (1000, 0.9)	9.5416	15.2217	1253
...									
10 0	да	-	32	(10)	ReLU	0.01 (500, 0.5)	14.482 1	15.3685	581

Как видно из таблицы 2, наилучшая (минимальная) средняя ошибка на тестовых данных составила 14.5421. В этом эксперименте использовались Z-нормализация данных, обучение по батчам, размер батча 64 примера, структура нейронной сети: 3 скрытых слоя по 20 нейронов, функция активации ReLU, скорость обучения 0.001.

Отобранные 100 нейронных сетей с минимальной ошибкой на тестовых данных обучались и тестировались повторно, но уже на подвыборках, в каждой из которых был удален один из входов модели. Результаты проводимых экспериментов приведены на рис. 2.

Все входные параметры оказались достаточно значимыми, поскольку при их удалении демонстрировались ошибки выше, чем достигнутые на полной выборке.

По значимости входные параметры располагаются следующим образом: время прохождения теста, мин.; форма обучения; входной рейтинг поступающего по математике; средний входной рейтинг по математике бывших одноклассников (одногогруппников); средний входной рейтинг поступающего по итогам сдачи других вступительных экзаменов; уровень предыдущего образования; пол поступающего; средний входной рейтинг по математике одногогруппников; УГНС; страна и регион проживания поступающего; возраст поступающего (на момент зачисления); поступающий из городской или сельской местности; сколько лет прошло с момента получения предыдущего образования; категория зачисления; средний входной рейтинг всех зачисленных.

Ввиду того, что избыточное количество входных параметров модели может приводить к нахождению ложных зависимостей, к переобучению модели, целесообразным видится нахождение взаимных корреляций входных параметров, а также поиск оптимального набора входов (достаточного и не избыточного).

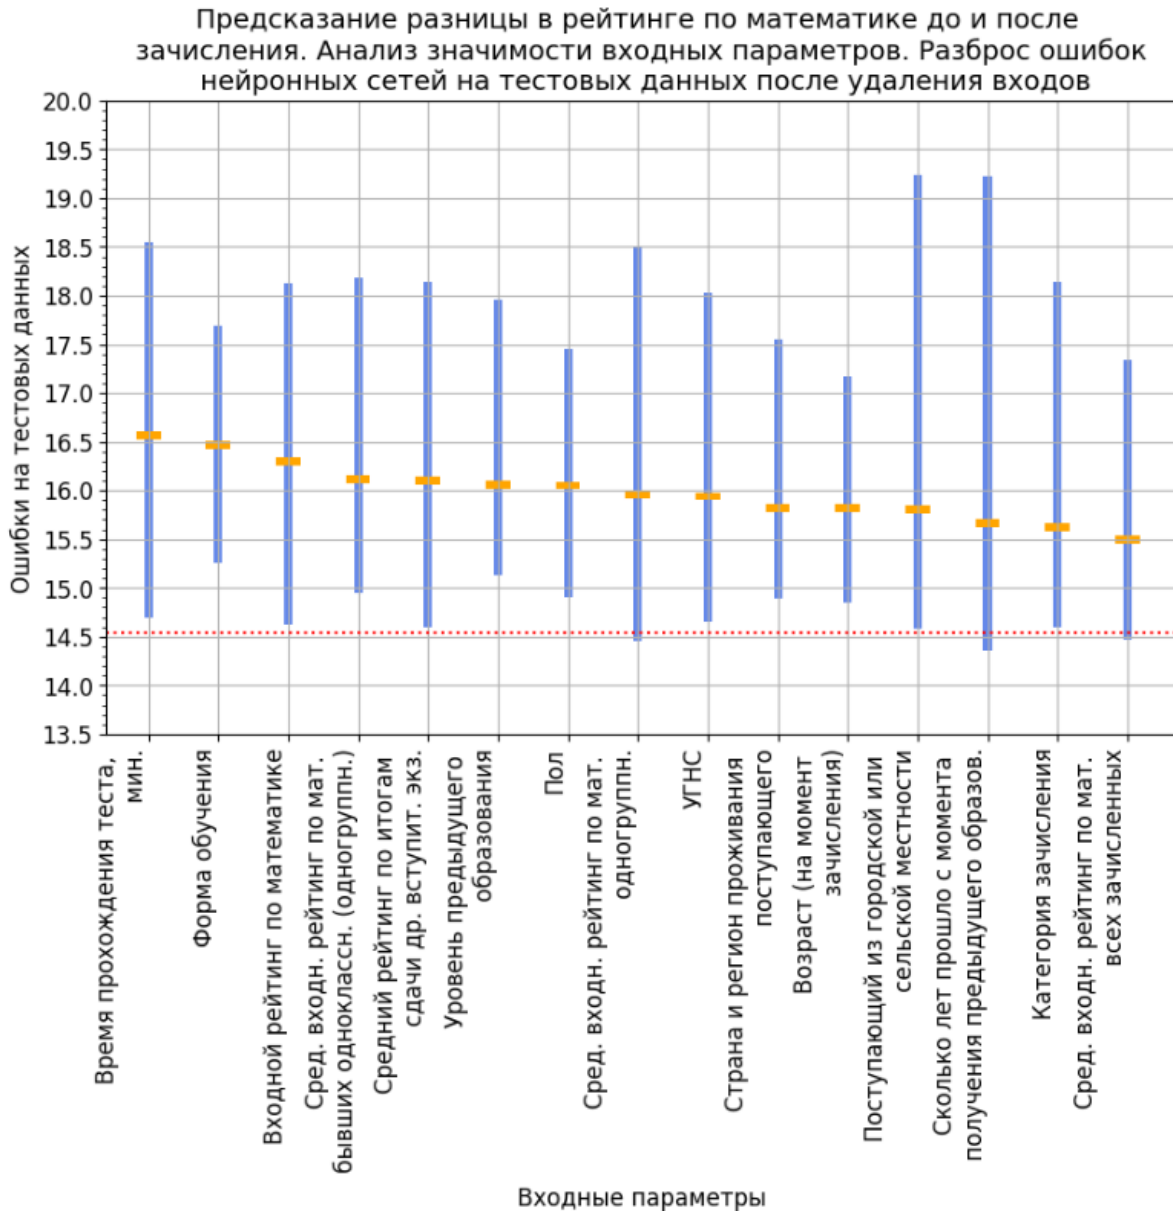


Рис. 2. Анализ значимости входных параметров модели предсказания последующей успеваемости студентов по математике (разницы в рейтинге до и после зачисления)

Исследование планируется продолжить в части построения самой модели

предсказания последующей успеваемости студентов, а также анализа изображений с камер поступающих во время сдачи ими онлайн-экзамена.

#### Список литературы

1 Safonova A.N., Guner M.V. Factor Analysis of Students' Knowledge Assessment Based on the Results of Online Entrance Testing in Mathematics to the University under the Conditions of COVID-19 (статья Scopus, Q2) // MDPI Education Science 2023, 13(1), 46. - Режим доступа: <https://www.mdpi.com/2227-7102/13/1/46>, <https://doi.org/10.3390/educsci13010046>

2 Хайкин Саймон Нейронные сети: полный курс, 2-е из.: Пер. с англ. - М.: ООО "И.Д. Вильямс, 2016. - 1104 с.: ил.

3           Нормализация           данных.           Режим           доступа:  
<https://wiki.loginom.ru/articles/data-normalization.html>

# МОДУЛЬНЫЙ ПОДХОД К ГИБРИДИЗАЦИИ ЭВРИСТИЧЕСКИХ АЛГОРИТМОВ ПРОСТРАНСТВЕННОЙ ОПТИМИЗАЦИИ РАЗМЕЩЕНИЯ ПОЖАРНЫХ ПОДРАЗДЕЛЕНИЙ

О.С.Малютин<sup>1</sup>, Р.Ш. Хабибулин<sup>2</sup>

<sup>1</sup>Сибирская пожарно-спасательная академия ГПС МЧС России,  
Научно-технический центр, отдел информационных технологий и компьютерного моделирования, *obsidian-pb@mail.ru*

<sup>2</sup> Академия Государственной противопожарной службы МЧС России,  
*kh-r@yandex.ru*

Задача определения оптимального размещения для создаваемых пожарных подразделений, проистекает как из экономических, так и из политических соображений. Для обеспечения одного и того же уровня защищенности населения от пожаров может потребоваться два или три пожарных подразделений, размещенных оптимальным образом или же вдвое большее количество размещенных менее рационально. Пожарные подразделения, размещенные так, чтобы обеспечить максимально быстрое прибытие сил и средств к любому возможному мету пожара на территории населенных пунктов, обеспечивают большую вероятность спасения людей при пожарах, нежели то же количество подразделений, размещенных в неподходящих местах.

В настоящее время крупные города России активно развиваются, происходит освоение новых территорий, реновация существующей застройки. Это приводит к тому, что потребность в защищенности отдельных территорий изменяется, требуется создание новых пожарных подразделений. Актуальность задач пространственной оптимизации размещения создаваемых пожарных подразделений подчеркивается как отечественными [1–5], так и зарубежными исследователями [6–9].

В России на сегодняшний день основным способом расчетной оценки требуемой численности пожарных подразделений является математическое моделирование [2,10,11]. Основным же подходом к выбору мест размещения пожарных подразделений является пространственная оценка удаленности объектов защиты,

описанная в работах [12,13] и закреплённая в СП 11.13130.2009 «Места дислокации подразделений пожарной охраны».

Подход, описанный в СП 11.13130.2009, заключается в определении такого места на территории населённого пункта размещение пожарного депо, в котором потенциально позволит обеспечить соблюдение требуемого времени прибытия первого пожарного подразделения для как можно большего количества объектов защиты. Места определяются последовательно – сначала первое подразделение, которое обеспечит максимальное прикрытие, затем второе, которое обеспечит максимальное прикрытие оставшихся зданий, затем третье и т.д. до тех пор, пока не будут защищены все объекты на территории населенного пункта. В теории алгоритмов он называется «Жадным добавлением» (англ. *Greedy Adding*) и не позволяет получить точного ответа при количестве подразделений более 2. А на больших количествах объектов и вовсе дает серьезную погрешность [14].

Использование же алгоритмов, которые позволили бы получить более рациональное размещение любого количества пожарных подразделений, могло бы позволить существенно снизить оценочное количество пожарных подразделений, требуемых для защиты населенных пунктов и промышленных предприятий.

В работах [9,15–22] приводятся различные подходы к решению этой задачи основанные на применении современных ГИС, методов теории графов и эвристических оптимизационных алгоритмов. Преимущественно используется генетический алгоритм (далее – GA от англ. *Genetic Algorithm*) и алгоритм имитации отжига (далее SAA от англ. *Simulated Annealing Algorithm*).

Проведенный анализ работ позволили составить иерархию задач пространственной оптимизации размещения пожарных подразделений (рис. 1) (пригодную, впрочем, и для других направлений)




Рис. 1. Иерархия задач пространственной оптимизации размещения пожарных подразделений

BLP (от англ. *Best Location Problem*) – задача оптимального размещения

единственного подразделения.

MCLP (от англ. *Maximum Covering Location Problem*) – задача оптимального размещения множества подразделений для достижения максимального покрытия.

LSCP (от англ. *Location Set Covering Problem*) – задача оптимального размещения такого количества подразделений, чтобы достичь целевого значения покрытия.

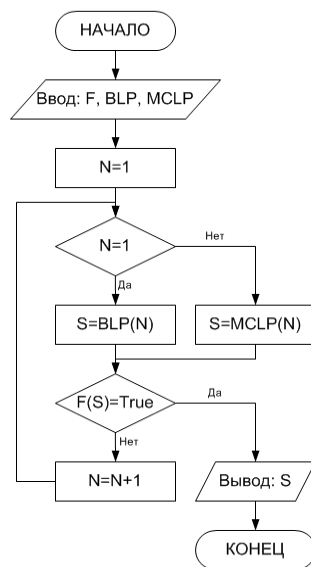


Рис.2. Укрупненная блок-схема алгоритма Генезис

Суть иерархической связи заключается в следующем: задача BLP является частным случаем задачи MCLP, для единственного подразделения; в свою очередь MCLP является частным случаем задачи LSCP для заранее известного количества количества подразделений. Частные случаи могут решаться методами отличными от основных задач, что делает возможным их решение более простыми методами. С другой стороны задачи более высокого уровня могут включать в себя решение задач более низкого как этап решения или как часть алгоритма, решающего задачу.

Из этого соображения родилась идея гибридного эвристического алгоритма решения задачи LSCP, названного «Генезис». Основная его идея заключается в пошаговом решении задачи MCLP для увеличивающегося на каждом шаге расчета количества подразделений, до тех пор, пока не будет достигнута цель расчета (например, требуемый уровень защищенности территории населенного пункта

в соответствии с федеральным законодательством). При этом, для первого и единственного на первом шагу расчета подразделения решение MCLP сводится к решению BLP (рис. 2).

На рисунке 2 обозначены: S – текущее размещение N подразделений, F – функция возвращающее булево значение Истина/Ложь в зависимости от того, достигнуто ли такое S при котором выполняется некоторое целевое условие задачи LSCP, BLP, MCLP – функции решения одноименных задач.

Конкретные реализации алгоритмов решения задач BLP и MCLP могут быть разными, не нарушая при этом логики работы алгоритма Генезис в целом. Комбинируя различные реализации алгоритмов и их гиперпараметров, становится возможным гибкая настройка алгоритма в целом для решения задачи LSCP в различных условиях, для различных прикладных задач и целей.

Для выбора наиболее подходящих алгоритмов решения задач пространственной оптимизации размещения пожарных подразделений были рассмотрены следующие алгоритмы:

- алгоритм восхождения (далее - HC от англ. *Hill Climbing*) [23,24];
- алгоритм имитации отжига (далее – SAA от англ. *Simulation Annealing Algorithm*) [23,24];
- генетический алгоритм (далее – GA от англ. *Genetic Algorithm*) [23,24].

Для эмпирической оценки принципиальной пригодности и качества алгоритмов была проведена серия вычислительных экспериментов с ГДС семи районов города Красноярск. Для каждого из ГДС было проведено решение задач BLP, MCLP и LSCP с применением перечисленных выше алгоритмов (табл. 1, 2, 3).

Метрикой, используемой при оценке качества размещения пожарных подразделений выбрана оценка удовлетворенности спроса на услуги пожарной охраны:

$$M_{cnp} = \frac{1}{n} \sum_{i=1}^n \frac{W_i}{t_{cл}}$$

где,  $W_i$  - спрос на обеспечение услуг пожарной охраны для i-го здания;  $t_i$  - время



следования из ближайшего пожарного депо к  $i$ -му зданию,  $n$  – количество зданий в районе выезда.

Полученные результаты показали, что алгоритмы в чистом виде, плохо справляются с поставленной задачей. Так, наилучший результат при решении задачи BLP показал алгоритм SAA (99,2% точность и качество определения лучшего узла), однако времени на расчет при помощи SAA потребовалось всего в 3 раза меньше, чем для поиска решения полным перебором. При решении задачи MCLP лучшие результаты были получены при помощи GA, однако, исследования показывают, что в большинстве случаев GA не позволяет получить точное решение за практически приемлемое время – его результат в значительной мере зависит от количества эпох и особей в популяции [23,25].

Причиной сложности расчета, как показало изучение топологии улично-дорожной сети крупных населенных пунктов, является наличие большого количества локальных оптимумов. Ключевой причиной появления локальных оптимумов является тот факт, что реальный ГДС является направленный мультиграфом, с наличием петель и компонентов слабой связности (продиктованных наличием улиц с односторонним движением).

Таким образом потребовалось подобрать такие алгоритмы, которые позволили бы эффективно избегать локальных оптимумов и при этом, в отличие от SAA не требовали бы большого запаса времени. Исходя из этих соображений были дополнительно рассмотрены следующие, являющиеся усложненной версией HC алгоритмы:

- алгоритм пулеметного подъема (далее – SHC от англ. *Shotgun Hill Climbing*) [26];

- алгоритм обезьяньего поиска (далее – MSA от англ. *Monkey Search Algorithm*) [23];

- алгоритм пчелиной колонии (далее – ABC от англ. *Artificial Bee Colony Optimization*) [23];

Исходя из того соображения, что центр графа как правило находится далеко от его периферии, был также предложен подход начала поиска с использованием

алгоритмов BLP от центра диаметра графа (далее – BNHD от англ. Best Node Half Diameter).

Для решения задачи MCLP был дополнительно предложен алгоритм k-средних, адаптированный для графового пространства. В такой адаптации в качестве функции поиска k центров выступает один из названных выше алгоритмов BLP.

Наконец было предложено дополнить алгоритм GA алгоритмом MCLP. В таком гибриде алгоритм GA выполняет «черновой» подбор наиболее точного размещения подразделений, после чего один из алгоритмов MCLP, выполняет «чистовой» подбор окончательной расстановки. Такой подход приемлем как при решении задач MCLP, так и при решении задач LSCP.

Предложенные подходы также были подвергнуты эмпирической оценке с использованием вычислительных экспериментов.

Средние результаты для каждого из алгоритмов полученные в ходе вычислительных экспериментов приведены в таблицах 1, 2 и 3.

Таблица 1

Результаты вычислительных экспериментов для BLP

Показатель	Перебор	HC	MSA	HC + BNHD	MSA + BNHD	ABC	SHS	SAA
Время, сек.	1431,9	10,3	124,3	7,2	234,5	51,9	104,1	514,6
Доля точных результатов*, %	100	11,2	72,3	85,9	100	79,8	57,3	99,2
Отношение результата к точному*, %	100	85,9	98,6	85,9	100	99,8	99,4	99,2

\* - здесь в качестве точного результата рассматривается результат, полученный с использованием полного перебора.

Таблица 2

## Результаты вычислительных экспериментов для MCLP

Показатель	SA	GA	k-средн. + НС+BNHD	GA+k-средн. + НС+BNHD
Время, сек	1133,45	468,83	16,72	474,05
Точность**, %	94,0%	97,7%	86,1%	100,0%

\*\* - здесь точность оценивается как отношение к наилучшему показателю.

Таблица 3

## Результаты вычислительных экспериментов для LSCP

Показатель	Генезис (k-средн.+НС+BNHD)	GA+Генезис
Время, сек	612,8	4189,4
Метрика***, %	99,9	96,8
Кол-во подразделений***, ед.	92,4	98,4

\*\*\* - отношение к лучшему полученному значению.

Полученные результаты продемонстрировали, что одним из наилучших рассмотренных гибридов является алгоритм «Генезис». Он позволяет получить приемлемый результат за относительно небольшое время.

Основным результатом работы является полученный модульный подход к гибридизации эвристических алгоритмов пространственной оптимизации размещения пожарных подразделений (рис. 3).

Описанный выше подход позволяет за счет модульности гибко настраивать гиперпараметры алгоритмов, и комбинировать их части. Так, алгоритм «Генезис», был сконструирован следующим образом:

В качестве алгоритма MCLP выбран k-средних использующий алгоритм VLP НС с предварительным определением узла по BNHD, метрикой оптимизации являлась метрика удовлетворенности спроса на услуги пожарной охраны, условием остановки для MCLP – 3 итерации, без улучшения значения, условием

остановки для LSCP – достижение доли зданий, время прибытия в которые составляет менее 10 минут – 90%. На выходе алгоритм возвращает количество и места размещения пожарных подразделений, а также значение целевой метрики для этого размещения.

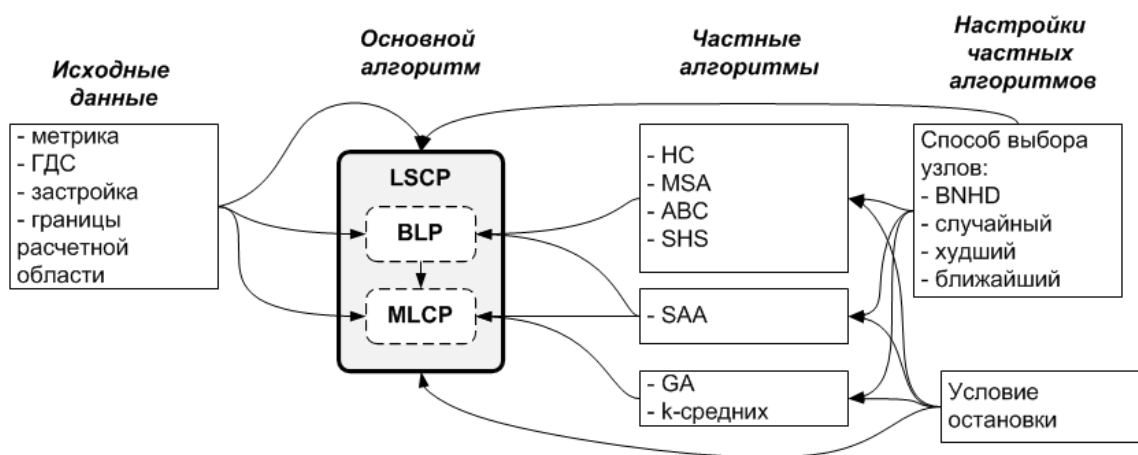


Рис.3. Схема модульного подхода к гибридизации

Модульный подход и перечисленные алгоритмы были реализованы с использованием языка программирования Python.

Полученный подход в ходе проведения вычислительных экспериментов продемонстрировал высокую гибкость и устойчивость работы.

В качестве направления дальнейших исследований видится:

- углубленное изучение возможных гибридных алгоритмов пространственной оптимизации;
- подбор наилучших гиперпараметров алгоритмов;
- оценка применимости данного подхода к решению иных задач;
- оценка связи оптимальных гиперпараметров алгоритмов с качествами исходных данных;
- оценка возможности и необходимости применения других эвристических алгоритмов.

#### Список литературы

1. Брушлинский Н.Н., Соколов С.В. Основы теории организации, функционирования и управления экстренными и аварийно-спасательными службами. М: Академия ГПС МЧС России – 2018 – 92 стр.

2. Брушлинский Н.Н., Соколов С.В. Математические методы и модели управления в Государственной противопожарной службе: Учебник. Издание второе, исправленное и дополненное. М: Академия ГПС МЧС России – 2019 – 194 стр.
3. Порошин А.А. Определение мест дислокации подразделений пожарной охраны для защиты от пожаров социально значимых объектов // Технологии техносферной безопасности – 2022 – № 4(98) – С. 68–78.
4. Порошин А.А. et al. Вопросы расчета ресурсной потребности пожарной охраны поселений и городских округов // Пожарная безопасность – 2018 – стр. 93–96.
5. Буйневич М.В., Пелех М.Т. Моделирование развития сети пожарных депо на территории мегаполиса. Казань: ООО «Конверт» – 2019 – стр. 62–64.
6. Jiang Y. et al. A GIS-Based Multi-Criterion Decision-Making Method to Select City Fire Brigade: A Case Study of Wuhan, China // IJGI. 2021. Vol. 10, № 11. P. 777.
7. Han B. et al. Site Selection of Fire Stations in Large Cities Based on Actual Spatiotemporal Demands: A Case Study of Nanjing City // IJGI. 2021. Vol. 10, № 8. P. 542.
8. Bolouri S. et al. The Ordered Capacitated Multi-Objective Location-Allocation Problem for Fire Stations Using Spatial Optimization // IJGI. 2018. Vol. 7, № 2. P. 44.
9. Murray A.T. Optimising the spatial location of urban fire stations // Fire Safety Journal. 2013. Vol. 62. P. 64–71.
10. Брушлинский Н.Н., Соколов С.В. О нормировании времени прибытия пожарных подразделений к месту пожара // Пожаровзрывобезопасность – 2011 – № 9(20).
11. Брушлинский Н.Н., Соколов С.В., Григорьева М.П. Организация пожарно-спасательных служб в городах мира // Пожары и чрезвычайные ситуации: предотвращение, ликвидация – 2017 – №1 – С. 49–55.
12. Матюшин А.В. et al. Проектирование размещения подразделений пожарной охраны в населенных пунктах с использованием геоинформационных технологий // Bezpieczenstwo i Technika Pożarnicza – 2013 – № 3(31) – С. 81–86.
13. Матюшин А.В. et al. Современные геоинформационные технологии в проектировании гарнизонов пожарной охраны // Пожарная безопасность. 2012. – №3. С. 107–119.

14. DeVore R.A., Temlyakov V.N. Some remarks on greedy algorithms // *Adv Comput Math*. 1996. Vol. 5, № 1. P. 173–187.
15. Alexandris G., Giannikos I. A new model for maximal coverage exploiting GIS capabilities // *European Journal of Operational Research*. 2010. Vol. 202, № 2. P. 328–338.
16. Atsuyuki Okabe, Kokichi, Sugihara. *Spatial analysis along networks : statistical and computational methods*. Tokyo, 2012. 300 p.
17. Boeing G. OSMnx: New methods for acquiring, constructing, analyzing, and visualizing complex street networks // *Computers, Environment and Urban Systems*. 2017. Vol. 65. P. 126–139.
18. Boeing G., Ha J. Resilient by design: Simulating street network disruptions across every urban area in the world // *Transportation Research Part A: Policy and Practice*. 2024. Vol. 182. P. 104–116.
19. Liu N., Huang B., Chandramouli M. Optimal Siting of Fire Stations Using GIS and ANT Algorithm // *J. Comput. Civ. Eng.* 2006. Vol. 20, № 5. P. 361–369.
20. Nyimbili P., Erden T. A combined model of GIS and fuzzy logic evaluation for locating emergency facilities: a case study of Istanbul. 2020.
21. Wang W. Site Selection of Fire Stations in Cities Based on Geographic Information System (GIS) and Fuzzy Analytic Hierarchy Process (FAHP) // *ISI*. 2019. Vol. 24, № 6. P. 619–626.
22. Yu Z. et al. Research on Urban Fire Station Layout Planning Based on a Combined Model Method // *IJGI*. 2023. Vol. 12, № 3. P. 135.
23. Курейчик В.В., Родзин С.И. Вычислительные модели эволюционных и ровых биоэвристик (обзор) // *ИТ*. – 2021 – № 10(27) – С. 507–520.
24. Курейчик В.В., Родзин С.И. Вычислительные модели биоэвристик, основанных на физических и когнитивных процессах (обзор) // *ИТ*. – 2021 – № 11(27) – С. 563–574.
25. Курейчик В.М. Модифицированные генетические операторы // *Перспективные информационные технологии и интеллектуальные системы*. – 2006 – №1 – С. 4–13.
26. Stuart J. Russell, Peter Norvig. *Iterative improvement algorithms* // *Artificial Intelligence: A Modern Approach*. NJ: PrenticeHall, 1995. P. 111–114.

# ПРЕДЕЛЬНО ПРОСТО НЕ ЗНАЧИТ ПРЕДЕЛЬНО ЯСНО: О ПОВЕДЕНИИ ПРОСТЕЙШИХ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ НА РЕФЛЕКСИЮ<sup>3</sup>

Г.М. Маркова<sup>1,2</sup>, С.И. Барцев<sup>1,2</sup>

<sup>1</sup>Институт биофизики СО РАН, *markova-g-m@yandex.ru*

<sup>2</sup> Сибирский федеральный университет,  
Институт фундаментальной биологии и биотехнологии, каф.биофизики  
*bartsev@yandex.ru*

## Введение

Рефлексия (в широком смысле) – феномен наличия у субъекта внутренних представлений о внешнем мире. Сохранение в памяти и своевременное извлечение из нее таких представлений, или образов, обуславливает прогностическую обработку поступающей информации [1, 2], на основании чего возможно принятие решений относительно ожидаемых событий. Рефлексивное поведение демонстрируют не только люди, но и многие животные, в том числе, с чрезвычайно малым мозгом по сравнению с человеческим, например, шмели [3]. Исходя из этого, мы полагаем, что рефлексия может быть воспроизведена и на простых объектах необязательно биологической природы, например, искусственных нейронных сетях. Такие модельные объекты являются значительно более простыми по сравнению с биологическими прототипами в связи с малым количеством элементов (15-30 нейронов) и ограниченным набором взаимодействий, которые могут быть описаны в виде простых нелинейных зависимостей. Тем не менее, такие системы способны решать ряд задач на рефлексии, что мы показали ранее [4], следовательно, они могут быть использованы для исследования механизмов рефлексии.

Мы рассмотрели дискретные полносвязные рекуррентные нейронные сети (РНС) без отдельных слоев для входа и выхода. Рекуррентная структура вместо

---

<sup>3</sup> Работа поддержана грантом РНФ №23-21-10041, Красноярского краевого фонда науки.

прямого распространения выбрана в связи с превосходством РНС над слоистыми сетями в задачах на рефлексию [5]. Функционирование задавалось формулами:

$$\alpha_i^{n+1} = \frac{\rho_i^n}{a + |\rho_i^n|}, \quad \rho_i^n = \sum_j w_{ij} \alpha_j^n + A_i^n, \quad (1)$$

где  $w_{ij}$  – матрица весовых коэффициентов,  $A_i^n$  – входные сигналы,  $\alpha_i^n$  – выходной сигнал  $j$ -го нейрона в  $n$ -ый момент времени,  $a$  – константа, задающая крутизну активационной функции нейрона. Отклик РНС определялся по соотношению сигналов двух выходных нейронов, внешние стимулы поступали также на два входа. Обучение РНС проводилось по алгоритму backpropagation, с квадратичной функцией потерь.

Мы провели ряд экспериментов и обнаружили, что, несмотря на сравнительную простоту устройства, данные модельные объекты демонстрируют труднопредсказуемое, контринтуитивное поведение при решении простейших задач на рефлексию. Статья посвящена рассмотрению некоторых обнаруженных нами неожиданностей.

### 1. Асимметрия позиций в рефлексивной игре чет-нечет

По литературным данным [6], в рефлексивной игре чет-нечет наблюдается смещение побед в пользу игрока за позицию «чет», т.е. того, кто должен «угадать» ход противника на каждом шаге игры. Это смещение связано с фреймингом – особенностями восприятия своей позиции у игроков. Игроки, не обладающие сложной психикой (например, РНС), не подвержены фреймингу. **Мы предположили**, что смещение в пользу РНС-игрока за «чет» всё равно может присутствовать, поскольку его задача – только «угадать» ход противника, в то время как игрок за «нечет» должен ещё заменить ход на противоположный, что является более сложной вычислительной процедурой.

Мы использовали РНС, функционирующие в дискретном режиме согласно уравнениям (1), в нескольких вариантах модификаций: 1) рекуррентная полносвязная сеть, без отдельных слоев входа и выхода, размер 15 нейронов (SRN15); 2) аналогичная предыдущей, но с дополнительным входом, куда в виде сигнала



+1/-1 поступают сведения о победе/поражении на предыдущем шаге игры (SRN+15); 3) аналогичная первой, но из 30 нейронов (SRN30); 4) аналогичная второй, но из 30 нейронов (SRN+30).

В эксперименте РНС играли против себе подобных. Весовые коэффициенты перед началом партии задавались случайным образом в диапазоне (-0.025; 0.025) и модифицировались после каждого хода по алгоритму backpropagation. В партиях длиной 1000 ходов регистрировалось количество баллов, набранных РНС при игре за «чет» и за «нечет», и количество побед РНС при игре за «чет» и за «нечет», везде 1500 партий за позицию. Значимые различия между средними значениями показателей были зарегистрированы только для SRN15 (двухвыборочный *t*-тест с различными дисперсиями).

Таким образом, асимметрия позиций в игре чет-нечет наблюдается, если вычислительные возможности игрока ограничены, однако даже небольшая модификация РНС (введение дополнительного входа или увеличение количества нейронов) позволяет устранить этот эффект или, по крайней мере, сделать его малозаметным.

## 2. Эффективность гомогенных и гетерогенных РНС в разных задачах

Помимо игры чет-нечет для моделирования рефлексии мы использовали и другие задачи, например, реагирование РНС на фиксированные временные ряды стимулов. Эта задача была введена как упрощение или имитация рефлексивной игры, где вместо противника используется набор из четырех временных рядов (см. таблицу), сменяющих друг друга по истечении определенного количества игровых шагов. РНС нужно как можно быстрее распознать ряд, который начал подаваться, и сформировать отклик. Правильность отклика определялась также по правилам игры чет-нечет.

Таблица

Фиксированные последовательности стимулов в имитации игры чет-нечет

Ряд 1	Ряд2	Ряд3	Ряд4
110011001100	101100101100	010011010011	111000111000

В данном эксперименте помимо описанных выше гомогенных РНС, т.е. состоящих из одного функционального модуля, мы использовали гетерогенные, состоящие из двух модулей – рекуррентных полносвязных 15-нейронных РНС: 1) «медленный» модуль функционирует по тактам игры, а «быстрый» имеет 3 внутренних такта между получением стимула и требованием отклика («Dual Time RNN» – DTRNN); 2) «играющий» модуль функционирует как SRN15, а «рефлексивный» помимо стимулов получает также отклик «играющего», который может изменить на противоположный («Reflexive Net» – RefNet). *Мы предположили*, что гетерогенные РНС будут обладать преимуществом над гомогенными того же размера (30 нейронов).

РНС, по 500 шт. каждой модификации, обучались в течение 1200 ходов. Ряды подавались по порядку, каждый в течение 60 ходов (режим обучения). Далее весовые коэффициенты обученных РНС фиксировались, и на вход подавались те же ряды, каждый в течение 50 ходов, в случайном порядке (режим теста). РНС функционировали в позиции «чет». В обоих режимах регистрировалась доля правильных откликов.




Рис.1. А) Эффективность РНС в реагировании на ряды; Б) эффективность РНС в игре чет-нечет против референсных РНС. В качестве погрешностей – ошибки среднего.

Результаты представлены на Рис.1А. Наилучшие показатели при обучении продемонстрировали гомогенные SRN ( $>0,88$ ) и SRN+ ( $>0,83$ ). Для них же характерно наибольшее падение доли правильных ответов при тестировании. В режиме теста наибольшая доля правильных ответов у гетерогенных RefNet ( $>0,81$ ). В целом, РНС с дополнительным входом в данной задаче показали результат хуже, чем без нее.

Однако если сопоставлять эффективность тех же модификаций в игре чет-нечет против референсных РНС с гомогенной структурой (SRN), то наличие дополнительного входа, наоборот, способствует большему выигрышу (см. Рис.1Б). В этой задаче выигрыш всех гетерогенных РНС превысил таковой у контроля (SRN против SRN),  $p < 0,001$  для всех конфигураций по  $t$ -тесту Уэлча. Но гомогенная модификация SRN+ также показала значимый выигрыш, превышающий результаты гетерогенных DTRNN и RefNet. Весовые коэффициенты РНС здесь изменялись (игра в режиме обучения).

Таким образом, предположение о преимуществе гетерогенных РНС над гомогенными в двух приведенных здесь задачах, несмотря на их формальное сходство, подтвердилось только частично.

### **3. Декодирование нейронной активности РНС, соответствующей различным стимулам**

Внутренние представления внешнего мира, который для РНС сводится к получаемым стимулам, можно представить как соответствующие этим стимулам паттерны нейронной активности. В этом случае возможно декодировать нейронную активность РНС, т.е. по виду паттерна распознать обрабатываемый в данный момент стимул. В вышеописанной задаче реагирования на фиксированные временные ряды стимулов, например, возможно распознать, какой ряд подается на РНС [7]. *Мы предположили*, что декодирование нейронной активности возможно только для тех РНС, которые хорошо освоили задачу реагирования, т.к. формальный успех в данном случае свидетельствует о сформированности точных и правильных представлений о рядах.

РНС всех перечисленных выше гомогенных и гетерогенных модификаций обучались задаче реагирования на ряды (см. раздел 2). Мы выбрали РНС каждой модификации, игравших за «чет» и за «нечет», показавших наибольшую («лучшие») и наименьшую («худшие») доли правильных ответов в режиме теста. Также мы рассмотрели РНС, получавшие в режиме обучения каждый ряд всего по одному разу в течение 24 шагов («one-shot») и не обучавшихся вообще («zero-shot»). Распознавание рядов по нейронной активности проводилось с помощью нейросетевого декодера (однослойной сети прямого распространения) и методом  $k$ -ближайших соседей ( $k = 3$ , исходя из предварительных измерений). При декодировании, которое, в сущности, является задачей классификации, помимо соответствующих рядам классов мы использовали класс «всё остальное». В обучении ему соответствовала нейронная активность РНС при подаче стимулов, не совпадающих с рядами. Декодирование производилось по отдельности для каждой РНС, т.к. паттерны нейронной активности чрезвычайно вариативны.

Декодирование нейронной активности, соответствующей четырем временным рядам стимулов, оказалось возможным для всех перечисленных выборок РНС («лучшие», «худшие», «one-shot», «zero-shot»), среднее качество декодирования около 0,8. У обученных РНС («лучшие» и «худшие») декодеры лучше выявляли класс «всё остальное», к которому относится, в частности, нейронная активность РНС на первых тактах после смены одного ряда на другой. Декодеры, распознававшие нейронную активность РНС из выборок «one-» и «zero-shot», в режиме теста почти не выделяли данный класс.

Данный результат соотносится с полученным ранее на другой задаче – тесте отложенного сравнения с образцом [8]: РНС формируют декодируемые динамические паттерны нейронной активности, соответствующие стимулам, даже при отсутствии обучения, что обусловлено различиями в самих стимулах. Обучение же позволяет РНС генерировать нужный отклик. Паттерны, соответствующие рядам, у обученных РНС сформированы более «четко», что позволяет декодерам уловить разницу между представлением рядов и «промежуточными» состояниями при переключении.

#### 4. Аттракторы внутреннего состояния РНС

Паттерн нейронной активности в текущий момент времени характеризует внутреннее состояние РНС, которое можно также рассматривать как точку в многомерном фазовом пространстве. Тогда динамика внутреннего состояния РНС представима как траектория на аттракторе. В литературе была представлена гипотеза, что оптимальным состоянием для эффективных вычислений является нахождение между порядком и хаосом [9], исходя из чего *мы предположили*, что эффективность РНС в задачах на рефлексию может быть связана с преобладанием квазихаотических (странных) аттракторов нейронной активности.

Мы проанализировали аттракторы, возникающие у РНС гомогенной и гетерогенной структуры (1500 шт. на каждую), в задаче реагирования на временные ряды. При реагировании на временные ряды наблюдались преимущественно циклические траектории (Рис.2А), что ожидаемо исходя из вида рядов (см. таблицу). Однако был зафиксирован случай, когда у SRN15 при подаче ряда 1 сформировался квазихаотический аттрактор (Рис.2Б), при этом генерировался правильный отклик. Наличие хаотической компоненты также подтвердилось при расчете корреляционной размерности аттрактора [10]. При подаче рядов 2-4 на эту SRN15 траектории были циклическими.

Далее мы рассмотрели аттракторы, возникающие у РНС (1500 шт. каждой модификации), обученных задаче реагирования на ряды, после инициации активности одиночным стимулом. В таком режиме внешнее воздействие, индуцирующее ту или иную форму аттрактора, сведено к минимуму. Доли РНС с различными типами аттракторов после инициации приведены на Рис.2В. Также в этом режиме мы исследовали нейронную активность РНС, обученных игре чет-нечет с себе подобными (см. раздел 1), соответствующие доли РНС приведены на Рис.2Г. В соответствии с условием Липшица, если якобиан РНС имеет собственные значения, превышающие 1 по модулю, то нулевое решение данной системы неустойчиво и в системе могут существовать аттракторы типа ненулевая точка, цикл либо квазихаос. Максимальные по модулю собственные значения якобианов также показаны на Рис.2В-Г.

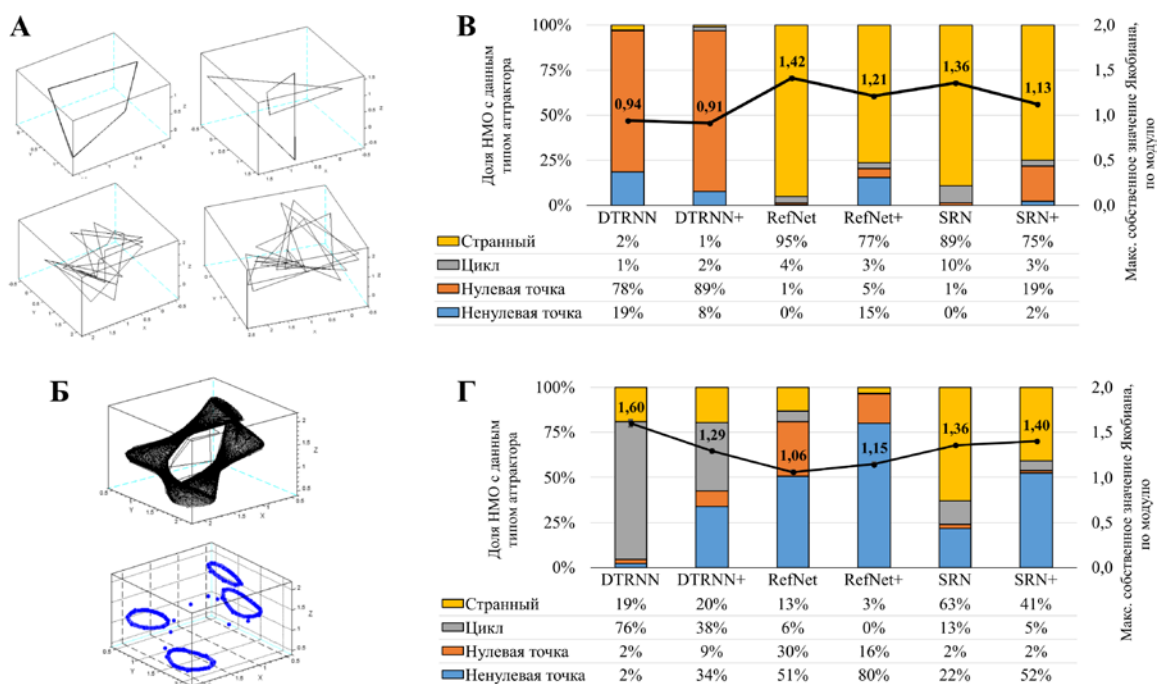


Рис.2. А) Пример циклических траекторий нейронной активности РНС при обработке рядов; Б) квазихаотический аттрактор у одной SRN15 при подаче ряда 1; В) доли РНС с различными типами аттракторов после обучения реагированию на ряды, режим инициации одиночным стимулом; Г) доли РНС с различными типами аттракторов после обучения игре чет-нечет, режим инициации одиночным стимулом. Траектории А и Б приведены в фазовом пространстве лагированных переменных.

Можно видеть, что для двух рассмотренных задач частота появления аттракторов разных типов различается, а квазихаотические аттракторы встречаются преимущественно в задаче реагирования на ряды. Значимых корреляций между типом аттрактора в режиме инициации одиночным стимулом и эффективностью РНС обнаружено не было, поэтому рассматриваемая в данном разделе гипотеза не подтвердилась.

## Заключение

В статье показаны примеры контринтуитивных эффектов, наблюдаемых нами при моделировании рефлексии на простейших нейронных сетях. Из четырех наших гипотез, связанных с эффективностью и внутренними состояниями

нейронных сетей, ни одна не подтвердилась полностью, несмотря на малые размеры и «прозрачное» устройство объектов, а также простоту решаемых ими задач.

С одной стороны, описанные эффекты можно рассматривать в одном ряду, например, с отображением Фейгенбаума – дискретной формой уравнения Ферхюльста, которое, являясь простым нелинейным уравнением вида  $f(x_{n+1}) = rx_n(1 - x_n)$ , в зависимости от величины параметра  $r$  может описывать динамический хаос из-за возникновения каскада бифуркаций [11]. Точки бифуркации, в свою очередь, представляют особый интерес, поскольку, согласно предположению В.А. Лефевра [12, с.10-18], в них поведение одушевленных (обладающих сознанием) тел физически недетерминировано, и наличие таких точек как раз может являться свидетельством наличия сознания. Рассматриваемые нами РНС сами по себе являются модельными объектами, чье поведение детерминировано уравнениями функционирования (1), однако отклик РНС интерпретируется как «0» или «1» в зависимости от того, на каком из двух выходных нейронов сигнал больше, причем различие между сигналами на этих нейронах может быть сколь угодно малым. Такое различие и может являться источником *«бесконечно малых толчков, направляющих эволюцию состояния тела»* [12, с. 15].

С другой стороны, описанное здесь может служить предостережением для тех исследователей, кто, как и мы, в рамках биофизического подхода использует предельно простые модельные объекты для воспроизведения реальных феноменов и ожидает предельно ясных результатов, а также для всех использующих в исследовательской практике искусственные нейронные сети.

#### Список литературы

1. Clark A. Whatever next? Predictive brains, situated agents, and the future of cognitive science / A.Clark // Behavioral and Brain Sciences. — 2013. — Vol.36. — №3. — P.181 – 204.
2. Millidge B. Predictive coding: a theoretical and experimental review / B.Millidge, A.Seth, C. L. Buckley // arXiv preprint. — 2021. — arXiv:2107.12979.
3. Bridges A.D. Bumblebees socially learn behaviour too complex to innovate alone / A.D.Bridges, A.Royka, T.Wilson, C.Lockwood, J.Richter, M.Juusola, L.Chittka // Nature. — 2024. — Vol.627. — №8004. — P. 572 – 578.

4. Барцев С.И. Биофизический подход к моделированию рефлексии: обоснование, методы, результаты / С.И.Барцев, Г.М.Маркова, А.И.Матвеева // Философские проблемы информационных технологий и киберпространства. — 2023. — №.2. — С.120 – 139.
5. Bartsev S. Recurrent and multi-layer neural networks playing “Even-Odd”: reflection against regression / S.Bartsev, G.Markova // IOP Conference Series: Materials Science and Engineering. — 2020. — Vol.734. — №1. — P.012109.
6. Eliaz K. Edgar Allan Poe's riddle: Framing effects in repeated matching pennies games / K.Eliaz, A.Rubinstein // Games and Economic Behavior. — 2011. — Vol.71 — №1. — P.88 – 99.
7. Markova G.M. Does a Recurrent Neural Network Form Recognizable Representations of a Fixed Event Series? / G.M.Markova, S.I.Bartsev // International Conference on Neuroinformatics. — Cham, Springer Nature Switzerland. — 2023. — P. 206 – 213.
8. Маркова Г.М. Кодирование внешних стимулов простыми рекуррентными нейронными сетями в ходе отложенного теста сравнения / Г.М. Маркова, С.И. Барцев // Сборник научных трудов XXIII Международной научно-технической конференции, Москва, 18-22 октября 2021 года. — Москва: НИЯУ МИФИ. — 2021. — С. 39 – 48.
9. Bertschinger N. Real-time computation at the edge of chaos in recurrent neural networks / N.Bertschinger, T.Natschläger // Neural computation. — 2004. — Vol. 16. — №. 7. — P. 1413 – 1436.
10. Grassberger P. Measuring the strangeness of strange attractors / P.Grassberger, I.Procaccia // Psysica D. — 1983. — Vol.9. — №1. — P.189 – 208.
11. May R. Simple mathematical models with very complicated dynamics // R.May // Nature. — 1976. — Vol.261. — P.459 – 467.
12. Лефевр В.А. Что такое одушевленность? / В.А.Лефевр. — Москва: Когито-Центр, 2017. — 123 с.



## ТАКСОНОМИЯ ГЕНОМОВ ОСПЫ И СХОЖЕСТЬ ГЕНОВ, ВЫЧИСЛЕННАЯ ПРИ ПОМОЩИ БЫСТРОГО ПРЕОБРАЗОВАНИЯ ФУРЬЕ

М.Ю.Сенашова<sup>1</sup>, М.Г. Садовский<sup>1,2,3</sup>, А.А. Шехова<sup>1</sup>

<sup>1</sup>Институт вычислительного моделирования СО РАН, *msen@icm.krasn.ru*,

*msad@icm.krasn.ru*, *annamo@icm.krasn.ru*

<sup>2</sup>ФСНКЦ ФМБА России, 660037, Красноярск, Россия

<sup>3</sup>СФУ, Красноярск, Россия

**Введение.** Взрывной рост накопленных генетических данных ставит перед исследователями задачу разработки и внедрения новых и более эффективных методов анализа последовательностей символов, соответствующих молекулам ДНК. Классическая задача поиска общей подпоследовательности в двух (или нескольких) последовательностях символов все еще далека от завершения, несмотря на долгую историю. Здесь мы предлагаем новый подход к проблеме, основанный на сочетании техники параллельных вычислений, реализации свертки двух функций и быстрого преобразования Фурье. Далее мы рассматриваем только четырехбуквенный алфавит  $\aleph = \{A, C, G, T\}$ , поскольку анализируем генетические последовательности.

Перейдем к постановке задачи. Рассмотрим две последовательности  $T_1, T_2$  из конечного алфавита  $\aleph$ . Найдём все достаточно длинные строки  $S_j, 1 \leq j \leq K$ , которые встречаются хотя бы один раз в  $T_1$  и  $T_2$ ; индекс  $j$  перечисляет такие строки. Очевидно, что ответ зависит от длины  $L = |S_j|$ : более длинные строки встречаются реже, чем более короткие. Мы будем искать подстроки с некоторыми допустимыми несовпадениями, так как для биоинформатики это часто встречающаяся задача. Поиск точно совпадающих подстрок является частным случаем и его можно рассматривать как решенную задачу. Конечно, появляются некоторые новые и продвинутые алгоритмы [1,2], что обеспечивает ускорение и рост эффективности решения задачи точного соответствия. В настоящее время самым популярным инструментом для сравнения последовательностей с (незначительными) несовпадениями является BLAST [2]. Метод очень популярный, но про-

блема состоит в том, что он расходится и приходится с этим бороться. Это делает выравнивание неприменимым для сравнения длинных (длиннее  $\sim 10^3$  символов) последовательностей. Более того, ни одна современная версия BLAST не свободна от произвольности в определении штрафной функции, что делает полученные результаты неоднозначными.

Мы предлагаем новый метод, не основанный на выравнивании, устойчивый к ошибкам и обеспечивающий сравнение по всему геному. Он особенно чувствителен при поиске вставок/удалений. Метод основан на реализации свертки набора полиномов, полученных из сравниваемых последовательностей, которые сопровождаются быстрым преобразованием Фурье (БПФ). Идея реализации БПФ для анализа последовательностей имеет довольно давнюю историю [3–8], начиная с классической работы [9]. Чтобы уменьшить количество арифметических операций, обычно реализуют обернутые свертки и относительное БПФ. Мы считаем, что регулярная (не обернутая) свертка более эффективна по двум причинам. Во-первых, вычисления проводятся с двоичными последовательностями; такие вычисления ожидаемо более эффективны, поскольку в регулярной свертке умножаются целые числа [10–12]. Во-вторых, БПФ реагирует на несовпадения в сравниваемых последовательностях, но не позволяет их локализовать.

**Материалы и методы.** Пусть  $L$  будет последовательностью длины  $N$  из конечного алфавита  $\aleph$ ; далее везде мы используем  $\aleph = \{A, C, G, T\}$ . Обычно  $N$  составляет от  $10^{10}$  до  $10^{11}$ . Обозначим через  $T$  последовательность длины  $N_T < N$  (называемой шаблоном) из того же алфавита. Найдем все вложения  $T$  в  $L$  при условии, что каждое вложение может иметь не более  $\delta$  несовпадений,  $0 \leq \delta < l$ . Очевидно,  $\delta = 0$  означает точное совпадение. На первом шаге последовательность символов  $L$  из алфавита  $\aleph$  емкостью  $|\aleph| = 4$  преобразуется в набор из четырех двоичных последовательностей. Это преобразование играет ключевую роль в алгоритме, обеспечивая алгоритмическое распараллеливание за  $|\aleph|$  раз. Аналогично шаблон  $T$  должен быть преобразован в  $|\aleph|$  двоичных последовательностей.

Для преобразования исходной последовательности символов необходимо выполнить следующее: заменяем все символы  $A$  в  $L$  на 1, а все остальные на 0,

получаем преобразованную последовательность  $L_A$  той же длины  $N$ . Аналогично получаем последовательности  $L_C$ ,  $L_G$  и  $L_T$  длины  $N$ . Точно так же получаем последовательности  $T_A$ ,  $T_C$ ,  $T_G$  и  $T_T$

Возьмем последовательности  $T_A = \{v_0, v_1, v_2, \dots, v_{N_T-1}\}$  и  $L_A = \{t_0, t_1, t_2, \dots, t_{N-1}\}$  для определенности. Определим индекс сходства для двух последовательностей. Сначала инвертируем  $T_A$ :

$$\bar{T}_A = \{z_0, z_1, z_2, \dots, z_{N_T-1}\} = \{v_{N_T-1}, \dots, v_2, v_1, v_0\}.$$

Далее рассмотрим двоичные последовательности  $\bar{T}_A$  и  $L_A$  как коэффициенты полиномов степени  $N_T - 1$  и  $N - 1$  соответственно:

$$p_A(x) = \sum_{i=0}^{N_T-1} z_i x^i \text{ и } q_A(x) = \sum_{i=0}^{N-1} t_i x^i.$$

Перемножение этих полиномов дает полином

$$r_A(x) = \sum_{j=0}^L w_j^A x^j$$

степени  $L = N + N_T - 2$ . Коэффициенты  $r(x)$  являются следующими скалярными произведениями:

$$w_j^A = \sum_{0 \leq s \leq j} t_s z_{j-s} = \sum_{0 \leq s \leq j} t_s v_{s-j+N_T-1}, \text{ если } 0 \leq j \leq N_T - 1, \quad (1)$$

$$w_j^A = \sum_{s=j-N_T+1}^{N_T-1} t_{s-N+1} z_{j-s} = \sum_{s=j-N_T+1}^{N_T-1} t_{s-N+1} v_{s-j+N_T-1}, \text{ если } N_T \leq j \leq L. \quad (2)$$

Тогда две идентичные подпоследовательности (включающие только символ  $A$ ) проявятся в явно выраженном выбросе некоторого коэффициента  $w_j^A$ , отчетливо видимом на фоне возможного случайного совпадения для  $j \neq J$ .

Быстрое умножение двух полиномов обеспечивается быстрым преобразованием Фурье [10,14,15]. Ради оптимальности требуется, чтобы число элементов как в  $\bar{T}_A$ , так и в  $L_A$  было равно степени 2. Чтобы избежать этого ограничения, добавляем нули к обеим последовательностям в позициях, больше чем  $N_T - 1$  и  $N - 1$ , соответственно, до ближайшей степени 2.

Алгоритмически это означает, что  $N_T = N = 2^m$ , для некоторого целого

числа  $m$ , для расширенных последовательностей. Затем должно быть выполнено быстрое преобразование Фурье, подразумевающее корни степени  $2^{m+1}$  из  $-1$  для расширенных последовательностей.

Перемножаем соответствующие результаты обоих преобразований и получаем последовательность длины  $2^{m+1}$ , поскольку полученный в результате перемножения полином имеет вдвое больший порядок. Наконец, обратное быстрое преобразование Фурье дает нам коэффициенты полинома  $r(x)$ .

Обратите внимание, что первый коэффициент дискретного преобразования Фурье равен сумме единиц в последовательностях. Это упрощает расчет вероятности  $p_A^T$  и  $p_A^L$  для символа  $A$  путем деления этой суммы на общее количество элементов в последовательности. Очевидно, что вычисления с комплексными числами приводят к округлению и ошибкам вычислений. Между тем, имея в виду целочисленный результат вычислений, на последнем этапе округление до ближайшего целого применяется для устранения накопленной ошибки.

Далее, применяя этот алгоритм к каждой букве  $A$ ,  $C$ ,  $G$  и  $T$  и суммируя, получаем

$$w_j = w_j^A + w_j^C + w_j^G + w_j^T. \quad (3)$$

Сумма (3) дает достаточно точную оценку для  $w_j$  относительно возможного случайного совпадения для  $j \neq J$ , по сравнению с каждым отдельным  $w_j^*$  из-за меньшего влияния возможных случайных совпадений.

Математическое ожидание совпадения описывается формулой

$$p = p_A^T p_A^L + p_C^T p_C^L + p_G^T p_G^L + p_T^T p_T^L. \quad (4)$$

Таким образом, коэффициенты, вычисленные по (1–3), характеризуют уровень несоответствия между двумя последовательностями символов, включая вставки или пропуски. Кроме того, нет теоретических ограничений на длину сравниваемых последовательностей. Вычислительные мощности обеспечивают основное ограничение на осуществимость метода: например, оперативная память, необходимая для вычислений.

**Результаты.** Были рассмотрены 70 геномов, относящихся к семейству *Roxviridae*, размещенных в GenBank. Для полных геномов была проведена кла-

стеризация на основе условной энтропии, вычисленной для этих геномов [13]. Здесь мы рассмотрим распределение по группам схожих генов из этих геномов.

Были выделены гены из 70 геномов оспы. Изложенным выше методом проводилось сравнение каждого гена с каждым. Отбирались только те гены, индекс схожести которых превышал 80%. Далее был проведен анализ, гены каких геномов оказались наиболее схожими. Были получены следующие группы схожих геномов.

Оспа насекомых. В геноме HF679134 *Mythimna separata entomopoxvirus 'L'* 15 генов схожи с генами HF679133 *Choristoneura rosaceana entomopoxvirus 'L'*, 12 генов с генами HF679132 *Choristoneura biennis entomopoxvirus 'L'*, 4 гена с генами *Adoxophyes honmai entomopoxvirus L*. В геноме HF679133 *Choristoneura rosaceana entomopoxvirus 'L'* 14 генов схожи с генами HF679131 *Adoxophyes honmai entomopoxvirus L*, 256 схожи с генами HF679132 *Choristoneura biennis entomopoxvirus 'L'*.

Оспа птиц. Наблюдается сильное сходство генов оспы птиц. Большинство указанных ниже генов имеют сходство больше 0,9 и совпадают по длине. В эту же группу попали гены оспы черепах MT799800 *Cheloniid poxvirus 1*. В геноме AY318871 *Canarypox virus strain ATCC VR-111* 226 генов схожи с генами MW485973 *Magpiepox virus 2 isolate 62-11-06-2000-ANU*, 276 генов схожи с генами MW365933 *Albatrosspox virus strain SAN97-0665NZ*, 261 ген схож с генами MT799800 *Cheloniid poxvirus 1*, 316 генов схожи с генами MK903864 *Magpiepox virus*. Гены MT799800 *Cheloniid poxvirus 1* кроме AY318871 *Canarypox virus strain ATCC VR-111* имеют так же сходство с 237 генами MW365933 *Albatrosspox virus strain SAN97-0665NZ*, 158 генами MW485973 *Magpiepox virus 2 isolate 62-11-06-2000-ANU*, 236 генов с генами MK903864 *Magpiepox virus*. В геноме AF198100 *Fowlpox virus* 166 генов схожи с KJ801920 *Pigeonpox virus isolate FeP2*, 186 генов с генами KJ859677 *Penguinpox virus isolate PSan92*, 161 ген схож с генами MF678796 *Flamingopox virus FGPVKD09*. В геноме KJ801920 *Pigeonpox virus isolate FeP2* 191 ген схож с генами KJ859677 *Penguinpox virus isolate PSan92*, 191 ген схож с генами MF678796 *Flamingopox virus FGPVKD09*. В геноме MF678796 *Flamingopox virus FGPVKD09* 205 генов схожи с генами KJ859677 *Penguinpox virus isolate PSan92*, 10 генов схожи с генами AY318871 *Canarypox*

*virus strain ATCC VR-111*, 8 генов схожи с генами MK903864 *Magpiepox virus*, 9 генов схожи с генами MT799800 *Cheloniid poxvirus 1*, 9 генов схожи с генами MW365933 *Albatrosspox virus strain SAN97-0665NZ*, 245 генов схожи с генами MW485973 *Magpiepox virus 2 isolate 62-11-06-2000-ANU*.

Геномы, относящиеся к роду *Orthopoxvirus* (AF482758 *Cowpox virus strain Brighton Red*, AY009089 *Camelpox virus CMS*, DQ437594 *Taterapox virus strain Dahomey 1968*, HM172544 *Monkeypox virus strain Zaire 1979-005*, KP143769 *Raccoonpox virus*, KU749310 *Skunkpox virus strain WA*, KU749311 *Volepox virus strain CA*, L22579 *Variola major virus strain Bangladesh-1975*, MH607141 *Akhmeta virus isolate Akhmeta 2013-88*, MH816996 *Orthopoxvirus Abatino*, MN240300 *Borealpox virus*, OP526861 *Monkeypox virus isolate MPXV USA 2022 FL0019*, X69198 *Variola virus DNA*, Y16780 *Variola minor virus*). В этой группе геномов так же наблюдается сильное сходство генов. Большинство генов имеет сходство больше 0,9 и совпадают по длине. В геноме MN240300 *Borealpox virus* 104 гена схожи с генами AF380138 *Monkeypox virus Zaire-96-I-16*, 116 генов схожи с генами AF482758 *Cowpox virus strain Brighton Red*, 88 генов схожи с генами L22579 *Variola major virus strain Bangladesh-1975*, 109 генов схожи с генами X69198 *Variola virus DNA*. В геноме MH816996 *Orthopoxvirus Abatino* 136 генов схожи с генами AF380138 *Monkeypox virus Zaire-96-I-16*, 177 генов схожи с генами AF482758 *Cowpox virus strain Brighton Red*, 201 ген схож с генами AY009089 *Camelpox virus CMS*, 133 гена схожи с генами L22579 *Variola major virus strain Bangladesh-1975*, 117 генов схожи с генами MN240300 *Borealpox virus*, 155 гена схожи с генами X69198 *Variola virus DNA*. В геноме MH607141 *Akhmeta virus isolate Akhmeta 2013-88* 136 гена схожи с генами AF380138 *Monkeypox virus Zaire-96-I-16*, 166 генов схожи с генами AF482758 *Cowpox virus strain Brighton Red*, 191 гена схожи с генами AY009089 *Camelpox virus CMS*, 122 гена схожи с генами L22579 *Variola major virus strain Bangladesh-1975*, 153 гена схожи с генами MH816996 *Orthopoxvirus Abatino*, 115 генов схожи с генами MN240300 *Borealpox virus*, 146 генов схожи с генами X69198 *Variola virus DNA*. В геноме AF482758 *Cowpox virus strain Brighton Red* 211 генов схожи с генами AY009089 *Camelpox virus CMS*, 136 генов схожи с генами L22579 *Variola major virus strain Bangladesh-1975*, 161 ген схож с генами X69198 *Variola virus DNA*, 145 генов схожи с генами HM172544 *Monkey-*

*pox virus strain Zaire 1979-005*. В геноме AY009089 *Camelpox virus CMS* 178 генов схожи с генами L22579 *Variola major virus strain Bangladesh-1975*, 203 гена схожи с генами X69198 *Variola virus DNA*, при этом 113 генов совпадает по длине со степенью схожести больше 0,97, 186 генов схожи с генами HM172544 *Monkeypox virus strain Zaire 1979-005*. В геноме DQ437594 *Taterapox virus strain Dahomey 1968* 270 генов схожи с генами AF380138 *Monkeypox virus Zaire-96-I-16*, 178 генов схожи с генами AF482758 *Cowpox virus strain Brighton Red*, 229 генов схожи с генами AY009089 *Camelpox virus CMS*, 225 генов схожи с генами EU410304 *Synthetic Vaccinia virus clone GLV-1h68*, 90 генов схожих с генами KP143769 *Raccoonpox virus*, 97 генов схожи с генами KU749310 *Skunkpox virus strain WA*, 88 генов схожи с генами KU749311 *Volepox virus strain CA*, 150 генов схожи с генами L22579 *Variola major virus strain Bangladesh-1975*, 158 генов схожи с генами MH607141 *Akhmeta virus isolate Akhmeta 2013-88*, 168 генов схожи с генами MH816996 *Orthopoxvirus Abatino*, 121 ген схож с генами MN240300 *Borealpox virus*, 177 генов схожи с генами X69198 *Variola virus DNA*. В геноме KP143769 *Raccoonpox virus* 85 генов схожи с генами AF380138 *Monkeypox virus Zaire-96-I-16*, 92 гена схожи с генами AF482758 *Cowpox virus strain Brighton Red*, 119 генов схожи с генами AY009089 *Camelpox virus CMS*, 127 генов схожи с генами KU749310 *Skunkpox virus strain WA*, 116 генов схожи с генами KU749311 *Volepox virus strain CA*, 71 ген схож с генами L22579 *Variola major virus strain Bangladesh-1975*, 89 генов схожи с генами MH607141 *Akhmeta virus isolate Akhmeta 2013-88*, 92 гена схожи с генами MH816996 *Orthopoxvirus Abatino*, 85 генов схожи с генами X69198 *Variola virus DNA*, 71 ген схож с генами MN240300 *Borealpox virus*. В геноме KU749310 *Skunkpox virus strain WA* 87 генов схожи с генами AF380138 *Monkeypox virus Zaire-96-I-16*, 90 генов схожи с генами AF482758 *Cowpox virus strain Brighton Red*, 122 гена схожи с генами AY009089 *Camelpox virus CMS*, 133 гена схожи с генами KU749311 *Volepox virus strain CA*, 76 генов схожи с генами L22579 *Variola major virus strain Bangladesh-1975*, 18 генов схожи с генами MF001304 *Murmansk poxvirus strain LEIV-11411*, 89 генов схожи с генами MH607141 *Akhmeta virus isolate Akhmeta 2013-88*, 88 генов схожи с генами MH816996 *Orthopoxvirus Abatino*, 75 генов схожи с генами MN240300 *Borealpox virus*, 89 генов схожи с генами X69198 *Variola virus DNA*. В

геноме L22579 *Variola major virus strain Bangladesh-1975* 120 генов схожи с генами HM172544 *Monkeypox virus strain Zaire 1979-005*, 166 генов включают друг друга с генами X69198 *Variola virus DNA* со степенью схожести для большинства генов от 0,99 до 1. Часть генов совпадают по длине, часть сильно отличаются.

Геномы вирусов оспы парнокопытных (AF325528 *Lumpy skin disease virus NI-2490 isolate Neethling 2490*, AF410153 *Swinpox virus isolate 17077-99*, AY077832 *Sheeppox virus 10700-99 strain TU-V02127*, AY077835 *Goatpox virus Pellor*, AY689436 *Deerpox virus W-848-83*, AY689437 *Deerpox virus W-1170-84*, MF966153 *White-tailed deer poxvirus isolate OV179*, MG751778 *Moosepox virus GoldyGopher14*) и геномы вирусов AJ293568 *Yaba-like disease virus YLDV*, EF420156 *Tanapox virus isolate TPV-Kenya*, HQ849551 *Yoka poxvirus strain Da-kArB 4268*. В этой группе обнаружено сходство у следующих генов. В геноме AY689436 *Deerpox virus W-848-83* 148 генов схожи с генами AY689437 *Deerpox virus W-1170-84*. В геноме MF966153 *White-tailed deer poxvirus isolate OV179* 144 гена схожи с генами AY689436 *Deerpox virus W-848-83*, 161 ген схож с генами AY689437 *Deerpox virus W-1170-84*, 145 генов схожи с генами MG751778 *Moosepox virus GoldyGopher14*. В геноме MG751778 *Moosepox virus GoldyGopher14* 132 гена схожи с генами AY689436 *Deerpox virus W-848-83*, 150 генов схожи с генами AY689437 *Deerpox virus W-1170-84*. Все эти гены имеют схожесть от 0,81 до 1. Большая часть больше 0,9. Большинство генов совпадают по длине.

Геномы оспы летучих мышей, дикобраза и мышей (HQ647181 *Cotia virus SPAn232*, KY747497 *Eptesipox virus strain Washington*, MK860688 *Hypsugopox virus strain 251170-23 2017*, MN692191 *Brazilian porcupinepox virus 1 strain UFU USP001*). В геноме HQ647181 *Cotia virus SPAn232* 185 генов схожи с KM595078 *Cotia virus strain SPAn880*, 14 генов схожи с MN692191 *Brazilian porcupinepox virus 1 strain UFU USP001*. В геноме KY747497 *Eptesipox virus strain Washington* 55 генов схожи с генами MK860688 *Hypsugopox virus strain 251170-23 2017*.

Геномы оспы подсемейства *Chordopoxvirinae* с GC-составом больше 0,6 (AY386265 *Bovine papular stomatitis virus strain BV-AR02*, GQ329670 *Pseudo-cowpox virus strain VR634*, HE601899 *Squirrel poxvirus strain Red squirrel UK*, KM502564 *Parapoxvirus red deer HL953 strain HL953*, MN339351 *Equine mol-*



*luscum contagiosum-like virus strain Tanzania 2016*, U60315 *Molluscum contagiosum virus subtype 1*). В геноме MN339351 *Equine molluscum contagiosum-like virus strain Tanzania 2016* 19 генов схожи с генами U60315 *Molluscum contagiosum virus subtype 1*. В геноме AY386265 *Bovine papular stomatitis virus strain BV-AR02* 22 гена схожи с GQ329669 *Pseudocowpox virus*, 23 гена схожи с KM502564 *Parapoxvirus red deer HL953 strain HL953*, 15 генов схожи с генами KY382358 *Seal parapoxvirus isolate AFK76s1*. В геноме GQ329670 *Pseudocowpox virus strain VR634* 21 ген схож с генами KM502564 *Parapoxvirus red deer HL953 strain HL953*.

Пары геномов оспы близкородственных видов: DQ356948 *Nile crocodilepox virus* и MG450915 *Saltwater crocodilepox virus subtype 1*, MF467280 *Western grey kangaropox virus strain Western Australia* и MF467281 *Eastern grey kangaropox virus strain Sunshine Coast*, MF001304 *Murmansk poxvirus strain LEIV-11411* и MF001305 *NY 014 poxvirus strain 2013*. В геноме MG450915 *Saltwater crocodilepox virus subtype 1* 77 генов схожи с генами DQ356948 *Nile crocodilepox virus*. В геноме MF467280 *Western grey kangaropox virus strain Western Australia* 104 гена схожи с генами MF467281 *Eastern grey kangaropox virus strain Sunshine Coast*. В геноме MF001304 *Murmansk poxvirus strain LEIV-11411* 159 генов схожи с генами MF001305 *NY 014 poxvirus strain 2013*.

**Выводы.** Полученные результаты анализа схожести генов оспы хорошо согласуются с кластеризацией полных геномов оспы с использованием условной энтропии. Схожие гены по большей части соответствуют таксономии полных геномов, особенно явно это наблюдается для генов оспы птиц и генов из группы геномов, включающих геном оспы человека.

#### Список литературы

1. Tsarev, S.P., Sadovsky, M.G.: New error tolerant method for search of long repeats in DNA sequences. In: Botón-Fernández, M., Martín-Vide, C., Santander-Jiménez, S., Vega-Rodríguez, M.A. (eds.) AICoB 2016. LNCS, vol. 9702, pp. 171–182. Springer, Cham (2016).
2. Altschul, S.F., Gish, W., Miller, W., Myers, E.W., Lipman, D.J.: Basic local alignment search tool. *J. Mol. Biol.* 215(3), 403–410 (1990)
3. Freschi, V., Bogliolo, A.: A faster algorithm for the computation of string convolutions using lz78 parsing. *Inform. Process. Lett.* 110(14), 609–613 (2010)

4. Freschi, V., Bogliolo, A.: Longest common subsequence between run-lengthencoded strings: a new algorithm with improved parallelism. *Inform. Process. Lett.* 90(4), 167–173 (2004)
5. Keogh, E., Chakrabarti, K., Pazzani, M., Mehrotra, S.: Dimensionality reduction for fast similarity search in large time series databases. *Knowl. Inf. Syst.* 3(3), 263–286 (2001)
6. Katoh, K., Misawa, K., Kuma, K.I., Miyata, T.: MAFFT: a novel method for rapid multiple sequence alignment based on fast Fourier transform. *Nucleic Acids Res.* 30(14), 3059–3066 (2002) Convolution in DNA Search and Comparison 481
7. Janacek, G.J., Bagnall, A.J., Powell, M.: A likelihood ratio distance measure for the similarity between the Fourier transform of time series. In: Ho, T.B., Cheung, D., Liu, H. (eds.) *PAKDD 2005. LNCS (LNAI)*, vol. 3518, pp. 737–743. Springer, Heidelberg (2005). [https://doi.org/10.1007/11430919\\_85](https://doi.org/10.1007/11430919_85)
8. Hetland, M.L.: A survey of recent methods for efficient retrieval of similar time sequences. In: *Data Mining in Time Series Databases*, pp. 23–42. World Scientific (2004)
9. Benson, D.C.: Fourier methods for biosequence analysis. *Nucleic Acids Res.* 18(21), 6305–6310 (1990)
10. Aho, A.V., Hopcroft, J.E.: *The Design and Analysis of Computer Algorithms*. Pearson Education India, Bengaluru (1974)
11. Baase, S.: *Computer Algorithms: Introduction to Design and Analysis*. Pearson Education India, Bengaluru (2009)
12. Kozen, D.C.: *The Design and Analysis of Algorithms*. Springer, Heidleberg (2012)
13. Сенашова М., Садовский М. Связь информационной емкости и таксономии геномов оспы // Сборник тезисов 14-й Международной мультikonференции «Биоинформатика регуляции и структуры геномов / системная биология» / 14th International Multiconference on “Bioinformatics of Genome Regulation and Structure/Systems Biology”, BGRS/SB-2024, Новосибирск, 5-10 августа 2024, doi 10.18699/bgrs2024-1.1-09

# МУЛЬТИМОДАЛЬНЫЙ КЛАССИФИКАТОР МЕДИЦИНСКОГО РИСКА НА ОСНОВЕ БИОИМПЕДАНСНОГО АНАЛИЗА

А.В. Серебровский, Н.А. Корсунский, А.В. Лях, И.А. Халин,

О.В. Шаталова

Юго-Западный государственный университет,

кафедра биомедицинской инженерии, *ShatOlg@mail.ru*

Рак молочной железы (РМЖ) является наиболее распространенной злокачественной опухолью среди женщин. Раннее выявление РМЖ играет ведущую роль в снижении уровня смертности. В настоящее время рентгеновская маммография является стандартным методом скрининга для выявления РМЖ [1]. Однако она имеет ряд ограничений, включая снижение способности выявлять карциному у женщин с плотной тканью молочной железы (МЖ). [2, 3, 4].

В последнее время использование методов биоимпедансного анализа для обнаружения рака МЖ стало новым направлением, поскольку было найдено больше доказательств того, что злокачественные опухоли МЖ имеют значительно отличающийся импеданс от нормальных тканей [3, 4, 5]. Электрический импеданс можно использовать для разделения доброкачественных и злокачественных опухолей и, следовательно, уменьшить количество доброкачественных биопсий [3]. Однако существует ряд проблем, которые ограничивают их клиническое применение, включая выявление РМЖ [5]. Ключевым ограничением биоимпедансным методам диагностики РМЖ является их низкое пространственное разрешение. Основными причинами этого являются неточное моделирование системы, изменяющийся импеданс контакта электрода с кожей, ограниченное количество независимых измерений и низкое соотношение сигнал/шум [6, 7, 8].

За основу метода классификации риска РМЖ принят мультимодальный подход, основанный на методе биоимпедансной спектроскопии. Согласно этому подходу необходимо построить несколько моделей классификаторов, которые основаны на различных методах классификации и на различных методах формирования дескрипторов, с последующей агрегацией их решений [9, 10, 11, 12, 13].

Для получения сырых данных биоимпедансного анализа используется матрица электродов [14]. Блок формирования дескрипторов является по существу блоком построения параметрической модели биоимпеданса МЖ. После формирования параметрических моделей биоимпеданса их параметры используются в качестве дескрипторов двухуровневого классификатора со структурой, представленной на рисунке 1. Этот классификатор может выдавать показатели риска РМЖ как дифференцированно по электродам матрицы (NET1), так и интегрально по всей матрицы (NET2). Так как лицу, принимающему решение (ЛПР) весьма трудно оценить показания во всех отведениях матрицы электродов, то эти показания желательно представить в виде изображения.

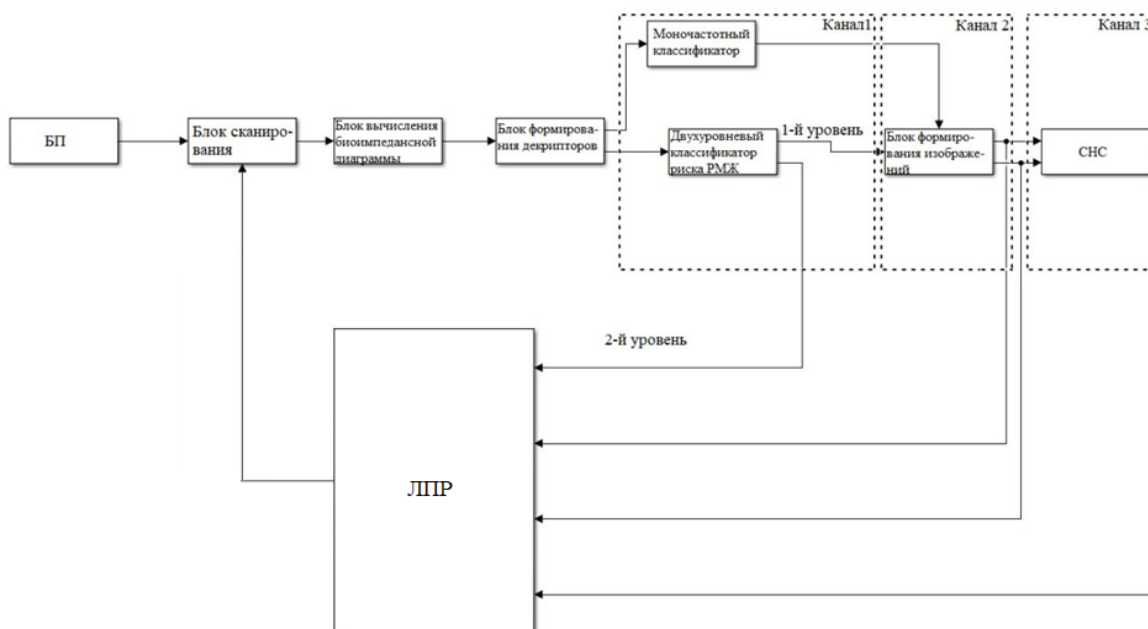


Рис. 1. Структурная схема мультимодального классификатора риска рака молочной железы

Кроме двухуровневого классификатора в мультимодальный классификатор введен моночастотный классификатор. В его задачу входит получить отсчеты биоимпеданса в отведениях на фиксированной частоте. Это непараметрический классификатор в котором в качестве дескрипторов используются отсчеты действительных и мнимых составляющих биоимпеданса  $ReZ$  и  $ImZ$  на определенных частотах.

Полученные изображения анализируются ЛПР субъективно или объективно посредством сверточной нейронной сети (СНС). Анализируя данные о риске РМЖ с трех каналов, ЛПР может проводить повторные исследования путем смены дислокации матрицы электродов относительно МЖ, получая тем самым наиболее информативное изображение и наиболее стабильные показания объективного контроля риска РМЖ.

Биоимпедансный преобразователь накладывается на области интереса МЖ. При этом в качестве сигнальных электродов используются электроды матрицы электродов, которые непосредственно контактируют с поверхностью кожи МЖ. Индифферентный электрод может быть прикреплен к любой конечности, как это показано на рисунке 2 [14].




Рис. 2. Схема измерения биоимпеданса молочной железы

Во время измерения между индифферентным электродом и измерительными электродами матрицы электродов на биоимпедансном преобразователе, прикладывается переменное напряжение. Ток проходит от руки пациента к высокопроводящей грудной мышце, которую можно рассматривать как изопотенциальную плоскость. Таким образом, между грудной мышцей и зондом, прижатым к груди лежащего пациента, создается примерно параллельная электрическая конфигурация, представленная на рисунке 3.

Эквивалентная схема рисунок 3 соответствует импедансу  $Z_2$ , показанному на рисунке 2 б. В соответствии с законами электротехники выражение для эквивалентного импеданса, приведенного на рисунке 3, имеет вид:

$$Z_2 = \frac{R_1}{j\omega C_1 \left( R_1 + \frac{1}{j\omega C_1} \right)} + R_2 + \frac{R_3}{j\omega C_3 \left( R_3 + \frac{1}{j\omega C_3} \right)}. \quad (1)$$

После выделения активной  $a(\omega)$  и реактивной  $b(\omega)$  составляющих импеданса имеем:

$$a(\omega) = \left( R_2 + \frac{R_1}{1 + \omega^2 R_1^2 C_1^2} + \frac{R_3}{1 + \omega^2 R_3^2 C_3^2} \right). \quad (2)$$

$$b(\omega) = -\omega \left( \frac{R_1^2 C_1}{1 + \omega^2 R_1^2 C_1^2} + \frac{R_3^2 C_3}{1 + \omega^2 R_3^2 C_3^2} \right). \quad (3)$$




Рис. 3. Эквивалентная электрическая схема взаимодействия электродов и биоматериала молочной железы

Выбирается линейка исследуемых частот  $M$ . На каждой из  $M$  выбранных частот определяется импеданс биоматериала. На каждой частоте выполняется 10 измерений биоимпеданса с последующим усреднением. Действительные и мнимые части биоимпеданса определяются по методике, приведенной в [5, 6, 7, 8, 9].

После получения  $a(\omega)$  и  $b(\omega)$  для всех электродов матрицы электродов рисунок 2а приступаем к определению параметров модели  $Z_2$  для каждого из этих электродов. Алгоритм для определения параметров моделей рисунок 3 рассмотрен в [15, 16, 17].

Так как матричный электрод и индифферентный электрод имеют разную конструкцию, то очевидно, что в модели импеданса (2) и (3) параметры модели C1R1 и C3R3 существенно отличаются. В этом случае целесообразно сначала определить параметры первого двухполюсника, соответствующего матричному электроду, а затем параметры второго двухполюсника, соответствующего индифферентному электроду.

Для понимания такого подхода рассмотрим рисунок 2б. Между парой матричных электродов включаем эквивалентное сопротивление Z1. Его также, как и Z2, можно представить в виде двух последовательно соединенных двухполюсников. Но, в отличие от Z2, параметры этих двухполюсников можно принять идентичными, так как они расположены на малом расстоянии друг от друга. При этом активным сопротивлением R2 в уравнении (2) можем пренебречь по той же причине.

При определении параметров модели Z1 уравнения (2) и (3) запишутся следующим образом:

$$a(\omega) = \left( \frac{2R_1}{1 + \omega^2 R_1^2 C_1^2} \right). \quad (4)$$

$$b(\omega) = -\omega \left( \frac{2R_1^2 C_1}{1 + \omega^2 R_1^2 C_1^2} \right). \quad (5)$$

Анализируя уравнения (4) и (5) приходим к выводу, что для построения параметрической модели Z1 необходимо определить только C1, которое может быть определено из квадратных алгебраических уравнений, полученных из уравнений (4) и (5). Однако эти решения нуждаются в оптимизации, так как каждая частота анализа в общем случае даст свое значение емкости C1. Для оптимизации ее значений существуют множество методов, в том числе и статистических. В данной работе для оптимизации значений C1 используем многослойную нейронную сеть прямого распространения сигнала (ИНС) [18, 19, 20, 21].

Динамический диапазон C1 вычисляем путем решения алгебраических квадратных уравнений (4), (5) относительно C1. Например, из (4) на i-й частоте имеем

$$C_1 = -\frac{1}{\omega_i^2 R_1^2} + \sqrt{\frac{2}{a(\omega_i) \omega_i^2 R_1}}. \quad (6)$$

Формируя РС двухполюсники со случайными параметрами, выбранными из установленных динамических диапазонов независимых переменных, определяются их параметры  $a(\omega_i)$   $b(\omega_i)$ , которые в данном случае так же являются независимыми переменными, и строятся таблицы объект-признак, в которых в качестве цели выступает значение емкости  $C1$ .

Для обучения ИНС используется алгоритм обучение с учителем. Для управляемого обучения пользователю требуется самостоятельно подготовить набор требуемых обучающих данных. Они являют собой входные данные и соответствующие им выход (значение  $C1$ ). Сама сеть устанавливается связь между первыми и вторыми. Затем ИНС обучается с помощью алгоритма управляемого обучения, при котором используются данные для корректировки весов сети и ее пороговые значения для того, чтобы максимально уменьшить ошибку прогноза на обучающем множестве.

Если же ИНС успешно обучается, то следом она приобретает возможность моделировать функцию, которая связывает значения входных и выходных переменных, а впоследствии эту сеть можно использовать для прогнозирования ситуации, когда выходные значения неизвестны.

Для построения модели  $Z2$  напряжение подается на биоматериал с импедансом  $Z2$ , эквивалентное сопротивление которого соответствует уравнениям (2) и (2). Учитывая, что параметры первого двухполюсника были определены в процессе эксперимента, то необходимо только определить параметры модели  $R2$ ,  $R3$ ,  $C3$ .

Однако, если рассмотреть эквивалентную схему рисунок 3, можно увидеть, что здесь, так же как, и при определении параметров эквивалентной схемы импеданса  $Z2$ , можно экспериментально определить сопротивление двухполюсника на постоянном токе. Это сопротивление согласно эквивалентной схеме равно  $R_{общ} = R1 + R2 + R3$ . Если  $R_{общ}$  определяется экспериментально, то в качестве априорной информации используем значение  $R^* = R_{общ} - R1$ .

Параметры  $C3$  и  $R3$  определяем по способу, аналогичному определению параметра  $C1$ . Таким образом, используем алгоритм, аналогичный алгоритму для определения  $Z1$  и ИНС прямого распространения сигнала, в которой для опреде-



ления параметров двухполюсника  $Z_2$  будет два выхода, а вектор Цель будет двухкомпонентный.

Получив соответствующие параметры модели импеданса, можем построить структуру ИНС, предназначенную для классификации риска РМЖ, пример которой представлен на рисунке 4.

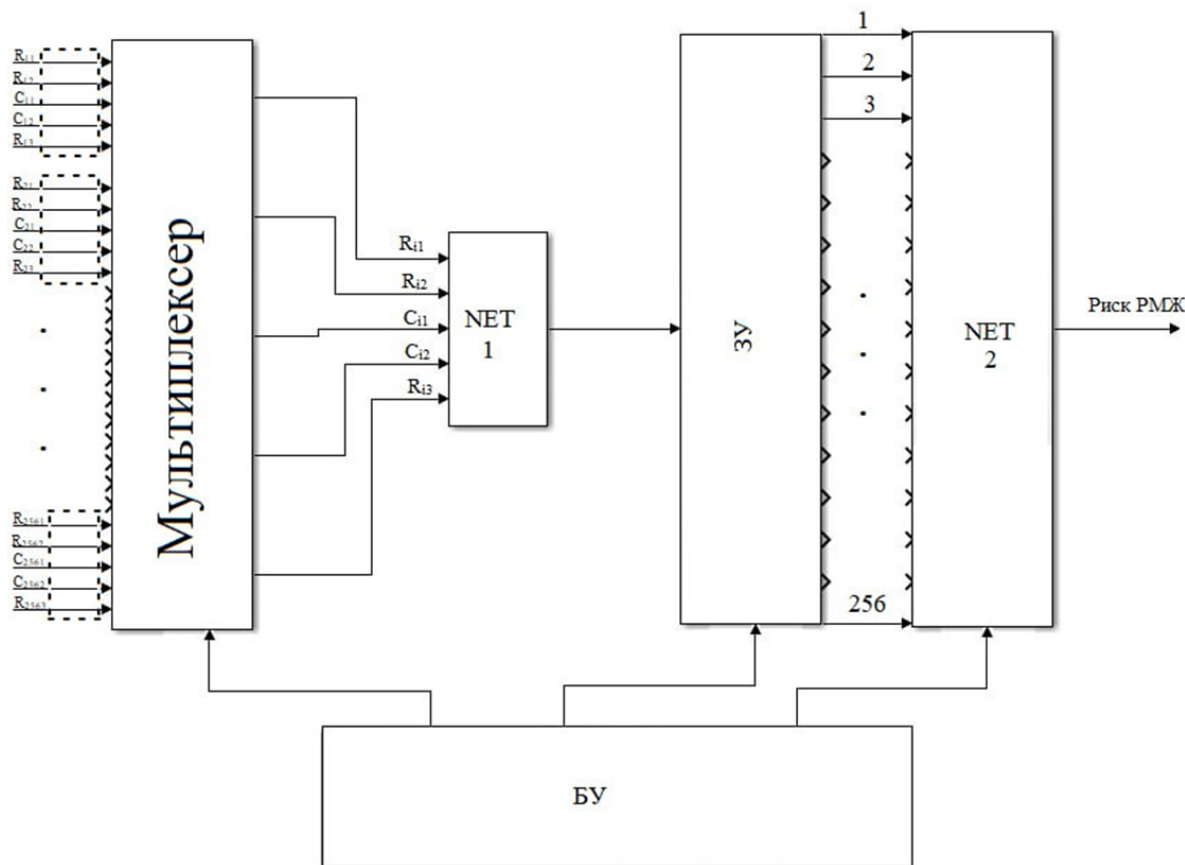


Рис. 4. Структура искусственной нейронной для оценки риска рака молочной железы на основе данных биоимпедансных исследований

В данную структуру входят две ИНС NET1 и NET2. NET1 определяет риски РМЖ по импедансу  $Z_2$  для каждого электрода электродной матрицы. Обычно используется матрица  $16 \times 16$  электродов, поэтому структура ИНС представлена для 256 электродов. После определения параметров эквивалентных двухполюсников для всех электродов матрицы, они последовательно через мультиплексор подаются на входы NET1, которая принимает решение по риску РМЖ на основе данных, поступающих с одного электрода матрицы. Обобщает показатели риска РМЖ по всем электродам матрицы ИНС NET2. На ее входы из запоминающего

устройства (ЗУ) поступают риски РМЖ, вычисленные ИНС NET1 по всем электродам матрицы, а на ее выходе имеем интегральный риск РМЖ. Координацию работы блоков и синхронизацию данных в такой ИНС осуществляет блок управления (БУ).

Диагностическая чувствительность предложенного мультимодального классификатора составила 0,60. Диагностическая специфичность – 0,70. Это несколько ниже показателей УЗИ по чувствительности, и несколько выше по специфичности, получаемых на опухолях, сопоставимых по размеру и по глубине.

Показатели качества диагностики цифровой рентгеновской маммографии составляют по диагностической чувствительности 0,89 и по диагностической специфичности 0,71. Это выше показателей УЗИ и биоимпедансного анализа. Однако при размере поражения МЖ менее 10 мм в диаметре, диагностическая чувствительность при высокой плотности МЖ падает до 40%, а при низкой плотности молочной железы до 70%.

Таким образом, представленный классификатор риска РМЖ позволяет определить риск онкологического заболевания по результатам спектроскопии биоимпеданса в области дислокации матрицы электродов. Мультимодальный классификатор также позволяет контролировать реакции организма на лечебно-оздоровительные процедуры, следовательно, позволяет осуществлять управление планом лечения [21, 22].

#### Список литературы

1. Алиева Г. С., Корженкова Г. П., Колядина И. В. Анализ ключевых рентгенологических характеристик раннего инвазивного рака молочной железы стадий T<sub>1a</sub>-bN<sub>0</sub>M<sub>0</sub> и DCIS // Онкологический журнал: лучевая диагностика, лучевая терапия. 2021. Т. 4, № 1. С. 9-19. <https://doi.org/10.37174/2587-7593-2021-4-1-9-19>
2. Объективизация топографо-анатомических показателей злокачественной опухоли молочной железы при ультразвуковом исследовании / А. Р. Хамитов, А. Х. Исмагилов, Н. А. Савельева, И. А. Киясов // Поволжский онкологический вестник. 2017. Т. 1, № 28. С. 59-64.

3. Zou Y., Guo Z. A review of electrical impedance techniques for breast cancer detection // *Medical Engineering & Physics*. 2003. Vol. 25, No. 2. Pp. 79–90. DOI: 10.1016/s1350-4533(02)00194-7.
4. Пат. 2504328 Российская Федерация. Устройство для контроля анизотропии электрической проводимости биотканей / Томакова Р. А., Филист С. А., Кузьмин А. А., Кузьмина М. Н., Алексенко В. А., Волков И. И. № 2012128471/14; заявл. 06.07.12; опубл. 20.01.14.
5. Шаталова О. В. Интеллектуальные системы мониторинга медицинских рисков с учетом биоимпедансных исследований: монография. Курск: Юго-Западный государственный университет, 2020. 356 с.
6. Технологии биоимпедансной спектроскопии в системах поддержки принятия решений при диагностике социально значимых заболеваний / О. В. Шаталова, Н. С. Стадниченко, М. А. Ефремов, И. А. Башмакова, А. В. Лях, А. В. Серебровский // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2023. Т. 13, № 4. С. 148–174. <https://doi.org/10.21869/2223-1536-2023-13-4-148-174>.
7. Биомедицинская спектроскопия в классификаторах функционального состояния органов и систем человека, построенных на основе гибридных технологий искусственного интеллекта / О. В. Шаталова, А. В. Серебровский, Н. С. Стадниченко, А. Ю. Новоселов, А. В. Лях // *Системный анализ и управление в биомедицинских системах*. 2023. Т. 22, № 2. С. 100-113. DOI 10.36622/VSTU.2023.22.2.015.
8. Модели импеданса биоматериала для формирования дескрипторов в интеллектуальных системах диагностики инфекционных заболеваний / А. В. Мирошников, Н. С. Стадниченко, О. В. Шаталова, С. А. Филист // *Моделирование, оптимизация и информационные технологии*. 2020. Т. 8, № 4. С. 1–14. <https://doi.org/10.26102/2310-6018/2020.31.4.018>.
9. Филист С. А., Кассим К. Д. А., Рущкой Р. В. Гибридные решающие системы для прогнозирования послеоперационных осложнений у больных с доброкачественной гиперплазией предстательной железы // *Известия Юго-Западного*

- государственного университета. 2013. № 5 (50). С. 40-49. URL: [https://www.elibrary.ru/download/elibrary\\_21064627\\_27658822.pdf](https://www.elibrary.ru/download/elibrary_21064627_27658822.pdf)
10. Гибридные интеллектуальные модели для сегментации изображений рентгенограмм грудной клетки / С. А. Филист, Р. А. Томакова, С. В. Дегтярев, А. Ф. Рыбочкин // Медицинская техника. 2017. № 5 (305). С. 41-45. URL: <http://www.mtjournal.ru/upload/iblock/e29/e29ef5959399676f4ee91e2d1b12d4cf.pdf>.
  11. Филист С. А., Томакова Р. А., Насер А. А. Нечеткие нейросетевые технологии для выделения сегментов с патологическими образованиями и морфологическими структурами на медицинских изображениях // Биомедицинская радиоэлектроника. 2012. № 4. С. 43-50.
  12. Филист С. А., Емельянов С. Г., Рыбочкин А. Ф. Нейросетевой решающий модуль для исследования живых систем // Известия Курского государственного технического университета. 2008. №2 (23). С. 77-82.
  13. A method for creating fuzzy neural-network models using the MATLAB package for biomedical applications / V. V. Zhilin, S. A. Filist, Kh. A. Rakhim, O. V. Shatalova // Biomedical Engineering. 2008. No. 42(2). Pp. 64-66. DOI: 10.1007/s10527-008-9019-y.
  14. Серебровский А.В., Шаталова О.В., Лях А.В., Халин И.А., Башмакова И.А., Протасова З.У. Мультимодальный классификатор риска рака молочной железы на основе анализа импеданса биоматериала. Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024;14(2):142-159. <https://doi.org/10.21869/2223-1536-2024-14-2-142-159>.
  15. Алгоритм оптимизации модели Войта в классификаторах функционального состояния живых систем / А. В. Мирошников, О. В. Шаталова, М. А. Ефремов, Н. С. Стадниченко, А. Ю. Новоселов, А. В. Павленко // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. Т. 12, № 2. С. 59–75. <https://doi.org/10.21869/2223-1536-2022-12-2-59-75>.
  16. Классификации биологических объектов на основе многомерного биоимпедансного анализа / А. В. Мирошников, О. В. Шаталова, Н. С. Стадниченко,

- Л. В. Шуль-га // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2020. Т. 10, № 3/4. С. 29–49. URL: [https://www.elibrary.ru/download/elibrary\\_44735222\\_30107400.pdf](https://www.elibrary.ru/download/elibrary_44735222_30107400.pdf)
17. Филист С. А., Шаталова О. В., Богданов А. С. Модели биоимпеданса при нелинейной вольтамперной характеристике и обратимом пробое диэлектрической составляющей биоматериала // Бюллетень сибирской медицины. 2014. Т. 13, № 4. С. 129-135. URL: [https://elibrary.ru/download/elibrary\\_22469891\\_20101601.pdf](https://elibrary.ru/download/elibrary_22469891_20101601.pdf)
  18. Использование гибридных нейросетевых моделей для многоагентных систем классификации в гетерогенном пространстве информативных признаков / А. Г. Курочкин, В. В. Жилин, С. А. Суржикова, С. А. Филист // Прикаспийский журнал: управление и высокие технологии. 2015. № 3(31). С. 85–95. URL: [https://hi-tech.asu.edu.ru/files/3\(31\)/85-95.pdf](https://hi-tech.asu.edu.ru/files/3(31)/85-95.pdf).
  19. Курочкин А. Г., Протасова В. В., Филист С. А., Шуткин А. Н. Нейросетевые модели для метаанализа медико-экологических данных // Нейрокомпьютеры. Разработка, применение. 2015. № 6. С. 42–48.
  20. Филист С. А., Шаталова О. В., Ефремов М. А. Гибридная нейронная сеть с макрослоями для медицинских приложений // Нейрокомпьютеры. Разработка и применение. 2014. №6. С. 35-39.
  21. Распределенные автономные интеллектуальные агенты для мониторинга и мета-анализа эффективности управления живыми системами / Т. В. Петрова, А. А. Кузьмин, Д. Ю. Савинов, В. В. Серебровский // Прикаспийский журнал: управление и высокие технологии. 2017. №40(4). С. 61–73. URL: [https://hi-tech.asu.edu.ru/files/4\(40\)/61-73.pdf](https://hi-tech.asu.edu.ru/files/4(40)/61-73.pdf).
  22. Структурно-функциональная модель для мониторинга влияния управляющих воздействий на функциональное состояние самоорганизующихся систем / П. С. Кудрявцев, А. Н. Шуткин, В. В. Протасова, С. А. Филист // Прикаспийский журнал: управление и высокие технологии. 2015. № 2 (30). С. 105-118. URL: [https://hi-tech.asu.edu.ru/files/2\(30\)/105-118.pdf](https://hi-tech.asu.edu.ru/files/2(30)/105-118.pdf)

## ОТОБРАЖЕНИЕ ДИНАМИКИ УЧЕБНОГО ПРОЦЕССА С ПОМОЩЬЮ КОГНИТИВНОЙ КАРТЫ ДИАГНОСТИКИ ЗНАНИЙ

В.А. Углеv, Г.А. Смирнов

Сибирский федеральный университет,

лаборатория прикладных интеллектуальных систем, [vauglev@sfu-kras.ru](mailto:vauglev@sfu-kras.ru)

В современных кибер-социальных системах востребованы средства Data Visualization (раздел Data Mining) для анализа цифрового следа. Это нужно не только для свёртки больших массивов данных в виде легко воспринимаемого графического образа, но и для возможности результативного пояснения решений интеллектуальных систем [1], делая акценты на самых актуальных элементах модели сложившейся ситуации. Особенно это важно для организации работы планировщиков современных интеллектуальных автоматизированных обучающих систем (ИАОС), где диагностики учёной ситуации происходит на базе образовательного цифрового следа (ОЦС).

Свёртка информации в Data Visualization может базироваться на широком перечне методов [2]: кластеризация, лица Чернова, кубы данных, пр. Мы подробно исследовали этот вопрос в [3] и пришли к выводу, что наибольшим потенциалом по разнообразию выразительных средств и степени обобщения обладает метод картирования. В работах [4-6] приводятся различные графические нотации карт, используемые для визуализации содержания цифрового образовательного следа. Мы далее рассмотрим метод когнитивных карт диагностики знаний (ККДЗ или СМКД), который позволяет отображать не только статическую обстановку, но и может быть адаптирован для отображения динамики учебной ситуации.

ККДЗ – это метод составления когнитивных карт (картирования), осуществляющий компактное представление (визуализацию) семиотических структур (данных о синтактике, семантике и прагматике) в приложении к диагностике знаний об экземпляре какого-либо объекта или выполняемого им процесса (де-нотат) с целью повышения качества процесса принятия решений и их аргументированности [7]. Примеры карт приведены на рис. 1. Каждый элемент карты (квадрат  $u_i$ ) соответствует дидактической единице, а его раскраска – оценке степени её освоения в знаниевом или одном из компетентностных аспектов [8] (в зависимости от выбранного): зелёный – полностью освоен, красный – совсем не

освоен, белый – граница неопределённости, серый – не укомплектован измерительными материалами. За счёт того, что в этой графической нотации совмещена синтаксическая (структурная) составляющая (дидактический материал  $u_i$  расположен по кругу в соответствии с исходной образовательной траекторией) и семантическая (соответствующие причинно-следственные связи внутри круга) такое представление позволяет сформировать целостный образ сложившейся учебной ситуации. Для дополнения этой конструкции элементами прагматики (для довершения построения сущности по квадрату Пospелова из подхода прикладной семиотики [9]) используется другая нотация – сквозная карта, о которой можно подробнее прочитать в [10] (далее для иллюстрации данной статьи нам эти нотации ККДЗ не понадобятся).




Рис. 1. Примеры ККДЗ одного из учащихся на различных этапах изучения дисциплины (индивидуализированная карта, знаниевый аспект)

На рис. 1 приведены примеры трех индивидуализированных ККДЗ, которые построены для одного учащегося (магистрант первого курса специальности «Информатика и вычислительная техника» при изучении дисциплины «Системный анализ и синтез» в весеннем семестре 2024 учебного года в результате работы в экспериментальной ИАОС AESU). Первая карта построена в самом начале изучения дисциплины, вторая – в середине семестра, а третья – ближе к его завершению. Из них видно, что проблемные  $u_i$  не всегда могут быть освоены только при повторном их изучении: в ряде случаев потребуется повторно поработать и с тем материалом, который напрямую влиял на него (см, например, связку  $u_{19}$  с  $u_{20}$  на центральной карте). Но достаточно ли в таком виде отображать динамику, обращаясь к реальным данным из цифрового образовательного следа? Очевидно, что нет, т.к., во-первых, не в каждый момент времени целесообразно проводить контрольно-измерительные мероприятия по всему учебному материалу (включая тот, который ещё не изучен) и, во-вторых, упор в контроле следует де-

лать на том материале, который был только-что изучен (включая непосредственно связанный с ним) для закрепления знаний и оперативного выявления затруднений. По этой причине пересмотрим подход к процессу формирования карты.

Охват данных, которые будут учитываться при отрисовке ККДЗ для дисциплины из примера приведены на схеме с рис. 2. По оси абсцисс (горизонтали) показан номер дидактической единицы, а по оси ординат (вертикали) – шаг обучения относительно базовой траектории обучения (исключая повторное обращение к учебному материалу): очевидно, что на этапе входного и итогового контроля в проверке участвовал материал всего курса, в середине семестра аналогичный срез делался в качестве фиксации промежуточных результатов изучения дисциплины. Цвета обозначают три режима актуализации (охвата контролируемого материала):

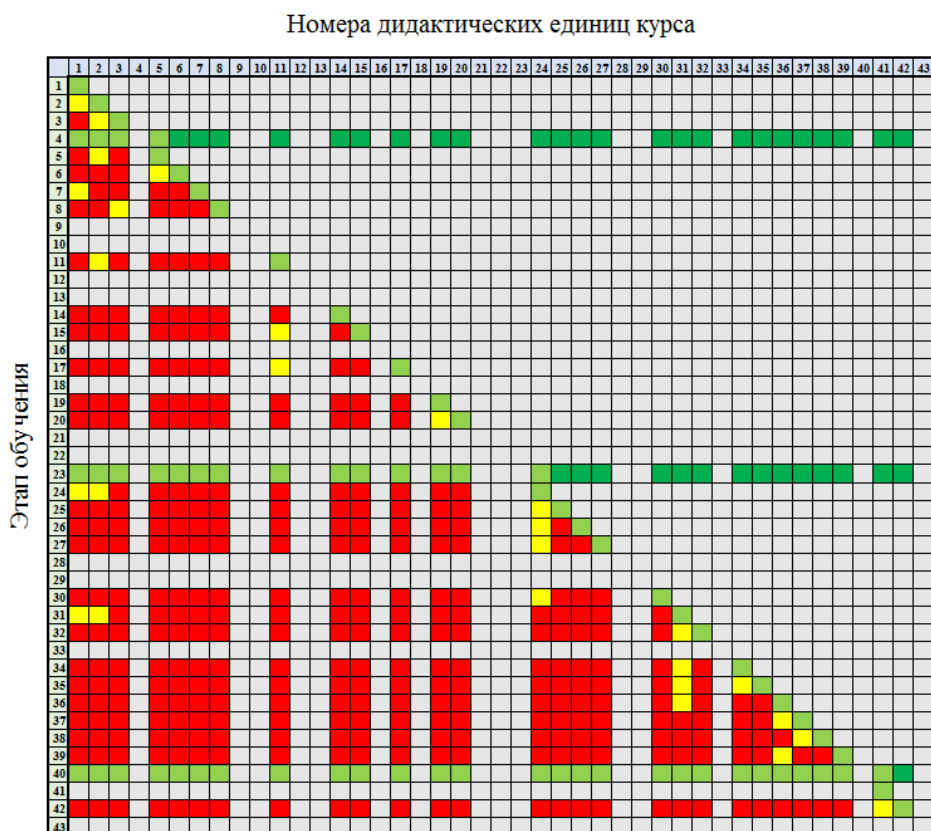


Рис. 2. Схема динамики проверки дидактического материала в процессе его изучения

- зеленый – все задания к текущей дидактической единице (оценки определяются впервые);
- желтый – часть заданий, связанных с дидактическими единицами, которые связаны с текущей родительскими связями (оценки обновляются);



- красный – результаты оценки заданий, которые прямо и косвенно не принимающих участвующие в изучении текущей дидактической единицы (загружаются последние сохраненные оценки из ОЦС).

При таком подходе к фиксации и обновлению исходных данных для карты появляется возможность формировать карту на определённую дату, обозначая отдельным цветом тот материал, к изучению которого учащийся ещё не приступал. На рисунке 3. Приведен пример такой карты на те же даты, что и для рис. 1. Здесь неизученный материал из модели курса на момент его фиксации в ОЦС окрашен желтым цветом.




Рис. 3. Примеры ККДЗ учащегося на различных этапах изучения дисциплины с исключением из визуализации оценок ещё не изученного материала (индивидуализированная карта, знаниевый аспект)

Очевидно, что приведённый пример, не смотря на достижение более реалистичной картины текущих знаний (или уровня развития компетентностей, если выбран соответствующий аспект), достаточно сложен для восприятия. Для повышения концентрации данных на карте и расстановке акцентов используем нотацию упрощённой карты. Для примера выведем те же три карты, что и на рис 3, но в упрощенном режиме отрисовки ККДЗ (см. рис. 4). Теперь более наглядно показано то, к какому учебному материалу ИАОС рекомендует обратиться в первую очередь: например, для центральной карты это  $u_1$  и  $u_{19}$ . При необходимости исключить рассеивания внимания на «лишних» элементах карты, элементы учебного курса, окрашенные желтым, также можно «спрятать».

Как видно из приведённого выше иллюстративного материала, метод ККДЗ может не только повысить концентрацию отображаемых данных, но и сделать отображение синхронным с процессом обучения, т.е. адекватно отражать динамику успехов учащегося при работе с ИАОС. Наши эксперименты показы-

вают, что согласование содержимого карт с текстом рекомендаций/подсказок ускоряют восприятие учащимся сложившейся ситуации и способствуют развитию его инициативы по выяснению причин предъявляемых оценок со стороны обучающей системы.

В качестве завершения хотелось бы порассуждать о перспективах дальнейшего повышения уровня концентрации данных из ОЦС, выводимых с помощью карт, для демонстрации динамики показателей. Мы можем выделить по меньшей мере три такие возможности:

1. Закодировать приращения значений данных текущей карты за счёт внесение в карту условных обозначений на уже имеющиеся элементы. Мы эту возможность изначально привязывали к начертанию текстовой метки: прямой шрифт – оценка существенно не изменилась (например, определять через фазификацию по методу нечёткой логики [11]) или выставлена впервые; курсив – оценка имеет значительно меньшее значение, чем та, которая была получена при предыдущем этапе проверки; жирность – значение оценки возросло по сравнению с предыдущим этапом контроля. Пример реализации такой карты можно увидеть на рис. 2 из работы [10];

2. Предусмотреть изменение заливки каждого элемента курса на карте в виде градиента значений той оценки, которая имела для каждого элемента относительно предыдущего этапа контроля;

3. Реализовать последовательную анимацию карты в соответствии с изменениями оценок

Все три возможности одновременно могут быть реализованы в рамках ИАОС как альтернативные варианты отображения. Преимущества последнего – это возможность дополнительно выводить в анимации данные о траектории работы учащегося с курсом. Ещё большие возможности по концентрации данных позволяет получить путём комбинирования предложенных идей со сквозной нотацией ККДЗ, подробней о которой можно узнать из [7].

#### Список литературы

1. Uglev V. Explanatory didactic dialogue in the Intelligent Tutoring Systems based on the cross-cutting approach // Intelligent Tutoring Systems. LNCS. Springer, Cham. – 2023. - Vol 13891. – pp. 371-380. [https://doi.org/10.1007/978-3-031-32883-1\\_34](https://doi.org/10.1007/978-3-031-32883-1_34).
2. Han J., Kamber M., Pei J. Data mining concepts and techniques // The Morgan Kaufmann Series in Data Management Systems. – 2011. – Vol. 5. – №4. – pp. 83–124.

3. Углев В.А. Сравнительный анализ методов когнитивной визуализации данных из образовательного цифрового следа // Информатизация образования и методика электронного обучения: цифровые технологии в образовании: Материалы VIII Международной научной конференции. - Красноярск: КГПУ, 2024. – (в печати).
4. Gorban A., Zinovyev A. Fast and user-friendly non-linear principal manifold learning by method of elastic maps // IEEE International Conference on Data Science and Advanced Analytics (DSAA). – 2015. – pp. 1–9. <https://doi.org/10.1109/DSAA.2015.7344818>.
5. Uglev V., Sychev O. Evaluation, Comparison and Monitoring of Multiparametric Systems by Unified Graphic Visualization of Activity Method on the Example of Learning Pro-cess. // Algorithms. – 2022. – №15. <https://doi.org/10.3390/a15120468y>.
6. Qian J., Nguyen N., Oya Y., Kikugawa G., Okabe T., Huang Y., Ohuchi F. Introducing self-organized maps (SOM) as a visualization tool for materials research and education. Results in Materials 4. – 2019. – №100020. <https://doi.org/10.1016/j.rinma.2019.100020>.
7. Uglev V. Cognitive Maps of Knowledge Diagnosis (CMKD): the essence of the method, classification, characteristics and synthesis principles // Novel & Intelligent Digital Systems Conferences. Springer. – 2024 (in press).
8. Смирнов Г.А. Сервис автоматического построения когнитивных карт диагностики знаний // Робототехника и искусственный интеллект: Материалы XV Всероссийской научно-технической конференции с международным участием. – Красноярск: ЛИТЕРА-принт, 2023. – С. 67-73.
9. Осипов Г.С. От ситуационного управления к прикладной семиотике // Новости искусственного интеллекта. – 2002. – № 6. – С. 3-7.
10. Uglev V., Smirnov G. Combined maps as a tool of concentration and visualization of knowledge in the logic of operation of the Intelligent Tutoring Systems // Intelligent Tutoring Systems. LNCS, Springer, Cham. 2024. – Vol. 14798. – pp. 27-39. [https://doi.org/10.1007/978-3-031-63028-6\\_3](https://doi.org/10.1007/978-3-031-63028-6_3).
11. Zadeh L.A., Aliev R.A. Fuzzy logic theory and applications: part I and part II. World Scientific Publishing, New Jersey, USA. 2018.

# СТРАТЕГИИ ГЛУБОКОГО ОБУЧЕНИЯ НА ОГРАНИЧЕННЫХ НАБОРАХ ДАННЫХ

М.Н.Фаворская

Сибирский государственный университет науки и технологий имени  
академика М.Ф. Решетнева,  
Институт информатики и телекоммуникаций, каф. информатики  
и вычислительной техники, *favorskaya@sibsau.ru*

Глубокое обучение, успешно применяемое во многих задачах компьютерного зрения, робототехники, обработки естественных языков, генеративного искусственного интеллекта, автоматизированного машинного обучения и т.д., имеет ограничения, связанные с необходимостью наличия больших наборов данных и соответственно с дорогостоящим и длительным процессом обучения. Такое ограничение делает применение моделей глубокого обучения проблематичным для многих реальных приложений с ограниченными наборами данных. В последние годы наблюдается значительный интерес к разработке стратегий для преодоления указанных ограничений, в частности, стратегии обучения на нескольких примерах. В англоязычной литературе используется обобщенный термин Few-Shot Learning (FSL). Методы FSL обеспечивают быструю адаптацию к новым задачам обучения на основе ранее накопленных знаний. Данная стратегия является незаменимой в медицинской диагностике, при переводе текстов, представленных на естественных языках, или при распознавании объектов, принадлежащих новым классам.

Методы FSL являются перспективным направлением с точки зрения преодоления разрыва между машинным и человеческим обучением. Люди способны обучаться на небольшом количестве примеров, а сталкиваясь с новой для себя ситуацией, используют накопленные знания об окружающем мире. Методы FSL направлены на разработку моделей, которые могут обобщаться в рамках конкретной задачи даже при ограниченном количестве доступных обучающих примеров. Обычно это достигается путем использования предыдущих знаний,

накопленных при решении аналогичных задач. Такие модели могут адаптироваться к новым задачам, для которых существуют небольшие наборы данных, что сложно для классических моделей машинного обучения без риска переобучения. Помимо этого, устраняется необходимость сбора и предварительной обработки больших наборов данных для обучения, а также сокращается время, необходимое для адаптации к новым данным. Более того, методы FSL имеют решающее значение для задач с редкими случаями, например, исследование новых лекарственных препаратов.

Предшественниками современных методов FSL считаются такие методы, как самореферентное обучение [1], применение биологически правдоподобных правил [2], распознавание объектов по одному изображению с использованием байесовских моделей [3], аугментацию данных [4] и метрическое обучение [5]. Следует отметить, что эти методы, разработанные в 1980-2000 годах, внесли определенный вклад в развитие современных FSL решений.

Приведем формальную постановку задачи машинного обучения. Пусть имеется задача  $T$  и заданная производительность  $P$ . Требуется обучить модель за счет использования опыта  $E$ , полученного от решения близкой задачи (например, с использованием обучающих данных). Говорят, что модель обучается, если ее производительность  $P$  улучшается при решении задачи  $T$ .

Наиболее часто опыт  $E$  приобретается с помощью набора данных  $D = \{(x_i, y_i)\}$ , где  $x_i \in \mathbb{R}^l$  – входной вектор признаков,  $y_i \in \mathbb{R}^o$  – соответствующая метка выхода,  $i = 1, \dots, K$ ,  $K$  – количество обучающих примеров. В общем случае выполняется условие  $(x_i, y_i) \sim p(x, y)$ , которое означает, что существует совместное распределение  $p$ , генерирующее экземпляры данных в рамках рассматриваемой задачи. Цель заключается в построении параметризованной модели  $f_\theta : \mathbb{R}^l \rightarrow \mathbb{R}^o$ , где  $\theta$  – параметры модели, которая оптимизируется по функции потерь  $L : \mathbb{R}^o \times \mathbb{R}^o \rightarrow \mathbb{R}$ . Это приводит к оптимальному набору параметров модели  $\theta^*$ , для которых выполняется выражение (1):

$$\theta^* = \arg \min_{\theta} E_{(x,y) \sim p(x,y)} [L(f_\theta(x), y)] . \quad (1)$$

Поскольку распределение  $p(x, y)$  неизвестно, параметры  $\theta$  оптимизируются

посредством минимизации эмпирического риска путем аппроксимации ожидаемых потерь средними потерями по выборкам обучающего набора данных:

$$\theta^* = \arg \min_{\theta} \left[ \frac{1}{K} \sum_{i=1}^K L(f_{\theta}(x_i), y_i) \right]. \quad (2)$$

Модель FSL существенно отличается от контролируемого машинного обучения тем, что имеется недостаточное для обучения и приобретения опыта количество обучающих примеров. В этом случае типичная модель машинного обучения переобучается и теряет способность к обобщению. Стандартный подход методов FSL основан на извлечении знаний из множества похожих задач, каждая из которых имеет ограниченное количество обучающих примеров. Таким образом, вместо одной задачи  $T$  формируется множество задач  $\{T_j\}$ , где  $j = 1, \dots, M$ , имеющее распределение  $q(T)$ . Вывод задач из одного и того же распределения подразумевает существование общей структуры с разделяемыми параметрами, которую можно использовать для быстрой адаптации к новой задаче. В результате цель обучения переопределяется и состоит в том, чтобы найти оптимальный набор параметров  $\theta^*$ , который минимизирует потери по всем заданным задачам:

$$\theta^* = \arg \min_{\theta} E_{T \sim q(T)} \left[ E_{(x,y) \sim p(x,y)} L(f_{\theta}(x), y) \right]. \quad (3)$$

Два вида математических ожиданий по распределению задач и процессу генерации данных в каждой задаче в выражении (3) накладывает дополнительный уровень сложности: необходима дополнительная аппроксимация ожидаемой ошибки по распределению задач. Каждая задача  $T_j$  имеет свой набор данных  $\{D_j\}$ , а ожидаемые потери по всем задачам аппроксимируются средними потерями по тем задачам, которые использовались во время обучения. Такой набор данных называется набором мета-обучения (meta-training set) или набором поддержки (support set), а для оценки модели FSL на новых задачах используется набор мета-тестирования (meta-test set) или набор запросов (query set). Таким образом, исходный набор данных разделяется на два непересекающихся подмножества:  $D_j = (D_j^S, D_j^Q)$ . При этом параметры модели уточняются в каждой задаче на основе набора поддержки  $D_j^S$ , а для оценки модели с использованием уточненных параметров используется набор запросов  $D_j^Q$ . При этом параметры моде-

ли  $\theta$  уточняются по набору поддержки  $D_j^S$  для каждой задачи, а оптимизируются по набору запросов  $D_j^Q$  для каждой задачи. Это позволяет поддерживать способность методов FSL к обобщению.

Исторически первые исследования методов FSL были связаны с классификацией изображений по принципу  $N$  классов –  $K$  примеров ( $N$ -way- $K$ -shot classification), когда каждый набор поддержки  $D_j^S$  содержал экземпляры из  $N$  различных классов, а каждый класс включал  $K$  различных примеров. Аналогичные формулировки возможны и для других задач обучения, например, семантической сегментации.

Далее приведем краткую характеристику видов обучения и их связь с методами FSL:

– мета-обучение (Meta-Learning). Основная цель мета-обучения состоит в том, чтобы обеспечить быструю адаптацию к новым задачам за счет использования ранее приобретенных знаний. Для этого методы мета-обучения извлекают общую структуру из решенных задач и используют ее в качестве индуктивного смещения для быстрой адаптации к новым задачам с ограниченными данными. Мета-обучение широко используется для решения задач FSL, но при этом предположение об ограниченных обучающих данных может не выполняться;

– слабо контролируемое обучение (Weakly Supervised Learning, WSL). Этот вид обучения основан на неполном наблюдении, когда во время обучения используются как размеченные, так и неразмеченные данные. Методы FSL и WSL основаны на индуктивных смещениях, но индуктивные смещения в методах WSL появляются из-за неразмеченных данных;

– полуконтролируемое обучение (Semi-Supervised Learning, SemiSL). При полуконтролируемом обучении модель обучается на небольшом количестве размеченных данных и большом количестве неразмеченных данных. Методы SemiSL стремятся вывести общую структуру из неразмеченных данных, которую затем используют для работы с размеченными данными. Методы FSL применяют близкую стратегию, но при этом используют размеченные данные из других задач для накопления знаний;

– самоконтролируемое обучение (Self-Supervised Learning, SelfSL). В отличие от методов FSL, когда задачи предварительно определены, а данные размечены, при самоконтролируемом обучении предварительные задачи генерируются автоматически и состоят из неразмеченных данных. Также в методах SelfSL отсутствует ограничение на количество экземпляров. Однако эти две парадигмы тесно связаны, а контрастное обучение как разновидность SelfSL в настоящее время используется и в структурах FSL [6];

– трансферное обучение (Transfer Learning, TL). Методы TL широко применяются в глубоком обучении. Они основаны на передаче знаний из исходной области с большими обучающими данными в целевую область, где данные ограничены. Методы же FSL имеют дело с несколькими задачами, каждая из которых содержит небольшое количество обучающих данных, извлекая знания из базовой структуры, общей для всех задач

– адаптация/обобщение домена (Domain Adaptation/Generalization). Адаптация домена направлена на обучение моделей, способных поддерживать производительность при оценке экземпляров, не входящих в базовое распределение, в то время как обобщение домена расширяет эту структуру для создания моделей, которые работают при любом сдвиге распределения. Эта стратегия может использоваться методами FSL для специальных задач, когда обучающие данные нельзя представить одним распределением;

– многозадачное обучение (Multi-Task Learning, MTL). В многозадачном обучении модели оптимизируются совместно на предопределенном наборе задач, повышая общую производительность модели. Этот тип обучения похож на обучение FSL, однако методы FSL стремятся обобщить новые задачи, не встречавшиеся во время обучения;

– обучение на одном примере (Zero-Shot Learning, ZSL). Основное различие между стратегиями обучения FSL и ZSL заключается в количестве доступных обучающих экземпляров в каждой задаче. В результате методы ZSL, как правило, используют данные из разных модальностей. Оба подхода основаны на индуктивных смещениях, однако их источники существенно различаются;



– непрерывное обучение (Continual Learning, CL). Цель обучения CL состоит в разработке моделей, которые могут постепенно приобретать новые знания из разных новых задач без ухудшения производительности. Однако при этом методы FSL обучаются офлайн, фокусируясь на использовании предшествующей информации, а методы CL используют онлайн-обучение, постепенно накапливая новые знания.

На рисунке приведена классификация методов FSL, которые можно определить как основные (мета-обучение, трансферное обучение и аугментация данных) и вспомогательные (междисциплинарные) (гибридные методы и нейронные процессы).



Рис. Классификация методов FSL.

Более подробную информацию о методах FSL можно найти в ряде обзорных статей [7–11].

Отметим ряд направлений для дальнейших исследований методов FSL:

– развитие теории. Требуется дальнейшее повышение эффективности методов FSL с учетом факторов производительности и сложности. Также следует улучшать методики тестирования для получения более точных оценок производительности как на дополнительных задачах, так и на основном наборе данных. Так, широко используемая метрика средней точности не учитывает проблему несбалансированности базовых классов и данных новых классов [12];

– снятие ограничений. Следует разрабатывать новые алгоритмы, близкие к реальным приложениям, например, снятие ограничений на количество новых классов и экземпляров в каждом классе. Более эффективное изучение мета-знаний позволит комплексно подходить к одновременному решению задач классификации, обнаружения и прогнозирования;

– тонкая настройка. Методы FSL имеют ряд ограничений для кросс-доменного обучения. Их устранение может выполняться по разным направлениям, например, более сложная настройка гиперпараметров, формирование вспомогательных наборов данных и извлечение нерелевантных для домена признаков. Тем не менее, интеграция методов обучения и выполнение тонкой настройки для максимизации производительности модели при одновременном снижении вычислительной сложности является направлением, достойным изучения;

– мультимодальное обучение. Мультимодальное обучение на небольших выборочных задачах демонстрирует хорошую способность к обобщению. Предварительная подготовка и тонкая настройка в сценариях мультимодального обучения позволяет формировать единообразное представление признаков в разных задачах. Для многих реальных приложений важно обеспечить слияние трех и более модальностей;

– подготовка эталонных тестовых наборов. Наборы данных поддержки, как правило, не достаточны для оценки истинного распределения данных. С одной стороны, возникает идея коррекции распределения для максимизации оценки истинного распределения данных с использованием ограниченного числа экземпляров. Сначала среднее значение и ковариация базового класса корректируются, а затем используется линейный классификатор. С другой стороны, возможно создание набора эталонных тестов для оценки обобщения модели;

– подготовка дополнительных наборов данных. К дополнительным наборам данных при применении методов FSL предъявляются требования не только достаточного количества размеченных экземпляров, но и поддержки того же распределения данных, что и для основного набора данных. Однако данное условие не всегда выполнимо, поэтому принципиальное решение этой проблемы заключается в уменьшении зависимости от дополнительных данных и получение потенциальных знаний другим способом, например, за счет учета композиционных отношений или структурных соответствий между компонентами данных;

– сложные сценарии реальных приложений. В настоящее время методы FSL применяются для решения относительно простых задач с небольшим количеством классов и большими размеченными данными. Однако в реальных приложениях возникают более сложные сценарии, например, задачи с большим количеством классов, наличие распределений данных с длинными хвостами, динамичность классов задач, недоступность размеченных дополнительных данных или даже смесь сценариев;

– расширение сфер применения. Применение методов FSL является многообещающим направлением для исследований в различных междисциплинарных областях. Можно указать ряд сложных мультимодальных задач, например, автоматическое распознавание модуляции радара, обнаружение вторжений, медицинская классификация временных рядов и т.д. В настоящее время такие методы не обладают свойствами масштабируемости и обобщения, но, возможно, в будущем будут получены соответствующие результаты.

#### Список литературы

1. Schmidhuber J. Evolutionary Principles in Self-Referential Learning, or on Learning How to Learn: The Metameta-...Hook / J. Schmidhuber // Ph.D. Dissertation. Technische Universität München. — 1987. — 64 p.
2. Bengio Y., Bengio S., Cloutier J. 1990. Learning a Synaptic Learning Rule / Y. Bengio, S. Bengio, J. Cloutier // Seattle International Joint Conference on Neural Networks (IJCNN-91). — 1990. — P.1 – 6.
3. Fei-Fei L., Fergus R., Perona P. One-Shot Learning of Object Categories. / L. Fei-Fei, R. Fergus, P. Perona // IEEE Transactions on Pattern Analysis and Machine Intelligence. — 2006. — Vol.28. — No.4. — P.594 – 611.

4. Miller E.G., Matsakis N.E., Viola P.A. Learning from One Example through Shared Densities on Transforms / E.G. Miller, N.E. Matsakis, P.A. Viola // Proceedings IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2000). — 2000. — Vol.1. — P.464 – 471.
5. Fink M. Object Classification from a Single Example Utilizing Class Relevance Metrics. / M. Fink // Advances in Neural Information Processing Systems (NIPS 2004). — 2004. — Vol.17. — P.449 – 456.
6. Guo X., Ma L., Luo X., Xie S. DP-DDCL: A Discriminative Prototype with Dual Decoupled Contrast Learning Method for Few-Shot Object Detection / X. Guo, L. Ma, X. Luo, S. Xie // Knowledge-Based Systems. – 2024. – Vol.297. – P.111964.1 – 111964.14.
7. Wang Y., Yao Q., Kwok J.T., Ni L.M. 2020. Generalizing from a Few Examples: A Survey on Few-Shot Learning / Y. Wang, Q. Yao, J.T. Kwok, L.M. Ni // ACM computing surveys (CSUR). — 2020. — Vol.53. — No.3. — P.63.1 – 63.34.
8. Huang G., Laradji I., Vazquez D., Lacoste-Julien S., Rodriguez P. A Survey of Self-Supervised and Few-Shot Object Detection / G. Huang, I. Laradji, D. Vazquez, S. Lacoste-Julien, P. Rodriguez // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2023. — Vol.45. — P.4071 – 4089.
9. Lu J., Gong P., Ye J., Zhang J., Zhang C. A Survey on Machine Learning from Few Samples / J. Lu, P. Gong, J. Ye, J. Zhang, C. Zhang // Pattern Recognition. — 2023. — Vol.139. — P.109480.1 – 109480.18.
10. Song Y., Wang T., Cai P., Mondal S.K., Sahoo J.P. A Comprehensive Survey of Few-Shot Learning: Evolution, Applications, Challenges, and Opportunities / Y. Song, T. Wang, P. Cai, S.K. Mondal, J.P. Sahoo // ACM Computing Surveys. — 2023. — Vol.55. — No.13s. — P.271.1 – 271.40.
11. Tian S., Li L., Li W., Ran H., Ning X., Tiwari P. A Survey on Few-Shot Class-Incremental Learning / S. Tian, L. Li, W. Li, H. Ran, X. Ning, P. Tiwari // Neural Networks. — 2024. — Vol.169. — P.307 – 324.
12. Ochal M., Patacchiola M., Vazquez J., Storkey A., Wang S. Few-Shot Learning with Class Imbalance / M. Ochal, M. Patacchiola, J. Vazquez, A. Storkey, S. Wang // IEEE Transactions on Artificial Intelligence. — 2023. — Vol.4. — No.5. — P.1348 – 1358.

## НЕЙРОСЕТИ КАК ИНСТРУМЕНТ ОПТИМИЗАЦИИ УПРАВЛЕНИЯ БОЕВЫМИ ДЕЙСТВИЯМИ НА ПОЖАРЕ

В.Ю. Яровой<sup>1</sup>, Я.В. Гребнев<sup>2</sup>

<sup>1</sup>Сибирская пожарно-спасательная академия, [yarovoiviacheslav@yandex.ru](mailto:yarovoiviacheslav@yandex.ru)

<sup>2</sup> Сибирский федеральный университет, [yaroslav.grebnev@gmail.com](mailto:yaroslav.grebnev@gmail.com)

В условиях чрезвычайных ситуаций, связанных с пожарами, скорость и точность принятия решений имеют критическое значение. В динамике пожара даже небольшие промедления могут привести к значительным потерям, как материальным, так и человеческим. Зачастую задержки в оперативности введения боевых действий связаны с несвоевременностью и скудностью собираемой информации. Традиционные методы управления боевыми действиями пожарных подразделений, несмотря на доказанную временем эффективность, все чаще сталкиваются с вызовами современной урбанизации, сложностью объектов и непредсказуемостью развития пожаров. В ответ на эти вызовы появляются новые технологические решения, среди которых нейросетевые системы занимают особое место.

Нейросети, благодаря своим уникальным способностям к обработке больших объемов данных и обучению на реальных сценариях, открывают новые горизонты в оптимизации управления боевыми действиями на пожаре. Они позволяют не только анализировать текущую обстановку в реальном времени, но и предсказывать развитие событий, предлагать оптимальные тактические решения и координировать действия многочисленных подразделений. Внедрение нейросетевых технологий в практику пожаротушения становится важным шагом на пути к повышению безопасности, оперативности и эффективности работы пожарных служб.

Однако с учетом ограниченности использования цифровых устройств для сбора информации, имеющихся на вооружении в подразделениях пожарной охраны, сбор информации в цифровом виде в непригодной для дыхания среде (далее НДС) осложнен плохой видимостью за счет распространения продуктов

неполного сгорания [1]. Ввиду этого использование нейросетевых технологий без внедрения аппаратных платформ сбора информации невозможно. Системы и аппаратные платформы, имеющиеся на вооружении в большей степени предназначены для сбора информации о состоянии внешней оперативной обстановке, сложившейся на объекте.

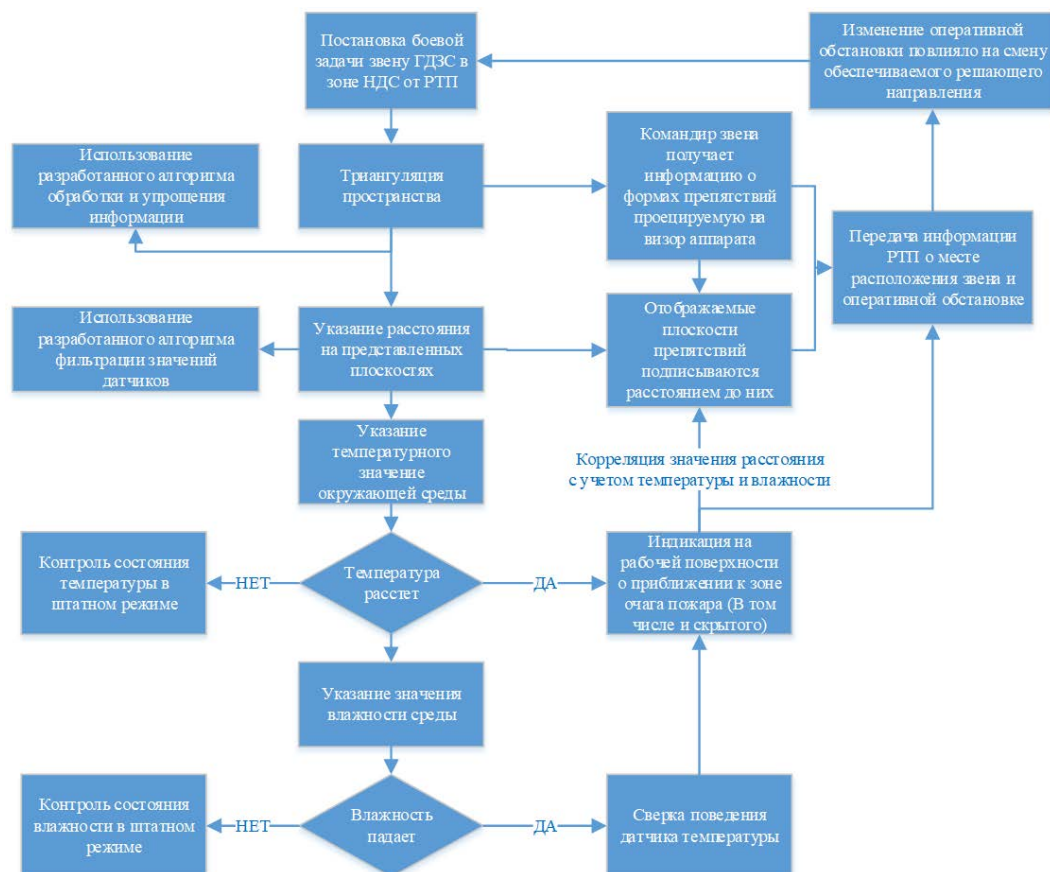


Рис.1. Блок схема поддержки принятия решений командиром звена ГДЗС с помощью данных поступаемых от предлагаемой приборной базы

В работах авторов [2-7] подробно освещены способы повышения скорости и качества принятия управленческих решений при введении боевых действий по тушению пожаров на различных экономических отраслях, однако не одна из работ не затрагивает тему оперативного управления и поддержки принятия решений в задымленном пространстве, а также сбора информации при разведке объекта звеньями газодымозащитной службы (далее ГДЗС) для принятия управленческих решений руководителем тушения пожара (далее РТП).

Авторами предлагается использования запатентованной авторской аппаратно-программной платформы [8], как первоначальной базы формирования нейросетевой экспертной системы (далее НЭС). Предложенная аппаратная база собирает данные для обработки с помощью следующих датчиков: лидар, ультразвуковая фазированная решетка, датчик температуры, датчик влажности. Собираемая информация в оперативном отношении может использоваться составом звена газодымозащитной службы по следующей блок схеме (рис.1).

Опираясь на данную блок схему была составлена нейросетевая модель экспертной системы поддержки принятия управленческих решений по ведению боевых действий на месте тушения пожара (рис.2).

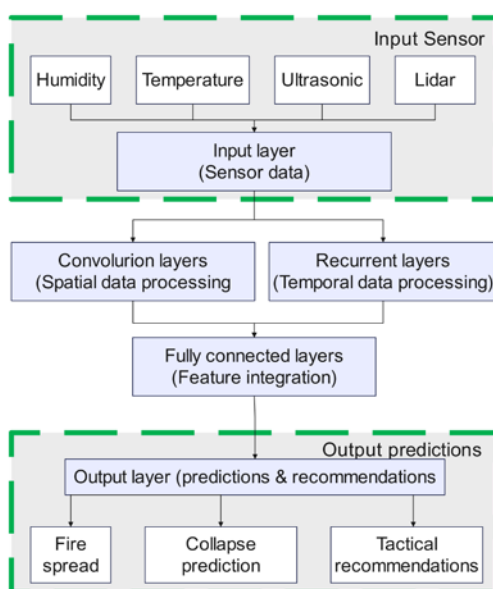


Рис.2. Структура НЭС поддержки принятия управленческих решений по ведению боевых действий на месте тушения пожара

Экспертная нейросетевая система для поддержки принятия управленческих решений на месте тушения пожара основана на интеграции данных с аппаратной платформы, содержащей несколько датчиков. Основная цель системы — обработка и анализ этих данных для формирования 3D модели пространства, прогнозирования опасностей, и координации действий пожарных команд в режиме реального времени.

## 1. Сбор и интеграция данных

Данные собираются с четырех типов датчиков:

1.1. Лидар (LIDAR): обеспечивает трёхмерное картирование пространства, измеряя расстояние до различных объектов.

1.2. Ультразвуковая фазированная решетка: анализирует структуры, уточняя данные лидарного сканирования.

1.3. Датчик температуры: определяет температурные аномалии и помогает выявлять местоположения очага пожара.

1.4. Датчик влажности: фиксирует уровень влажности воздуха.

Данные каждого типа обрабатываются с учетом временной и пространственной синхронизации, чтобы гарантировать точность и согласованность данных в модели. Для этого используются фильтры Калмана, что позволяет уменьшить шумы и компенсировать неточности в измерениях.

$$\begin{aligned}x_t &= Ax_{t-1} + Bu_t + w_t . \\z_t &= Hx_t + v_t .\end{aligned}\tag{1}$$

Где:

$x_t$  — состояние системы на момент времени  $t$ ,

$A$  — матрица перехода состояний,

$u_t$  — управляющие воздействия,

$w_t$  — гауссовский шум процесса,

$z_t$  — измерения (данные с датчиков),

$H$  — матрица наблюдения,

$v_t$  — гауссовский шум измерений.

## 2. Анализ данных с использованием нейросетей

После сбора и интеграции данные поступают на вход нейросетевой модели, которая состоит из нескольких уровней обработки:

### 2.1. Сверточные нейронные сети (CNN):

- Обработывают данные лидарного сканирования для создания 3D моде-



ли помещения.

- Применяются для извлечения признаков (например, форма и размеры объектов).

- Функция активации: ReLU (Rectified Linear Unit).

$$\text{ReLU}(x) = \max(0, x) . \quad (2)$$

## 2.2. Рекуррентные нейронные сети (RNN/LSTM):

- Анализируют временные ряды данных с датчиков температуры и влажности.

- Позволяют моделировать изменение температуры и влажности во времени, что помогает прогнозировать поведение пожара.

Обновление состояния LSTM-ячейки:

$$\begin{aligned} f_t &= \sigma(W_f \bullet [h_{t-1}, x_t] + b_f) . \\ i_t &= \sigma(W_i \bullet [h_{t-1}, x_t] + b_i) . \\ \tilde{C}_t &= \tanh(W_c \bullet [h_{t-1}, x_t] + b_c) . \\ C_t &= f_t * C_{t-1} + i_t * \tilde{C}_t . \\ o_t &= \sigma(W_o \bullet [h_{t-1}, x_t] + b_o) . \\ h_t &= o_t * \tanh(C_t) . \end{aligned} \quad (3)$$

Где:

$f_t, i_t, o_t$  — векторы забывания, входа и выхода,

$C_t, \tilde{C}_t$  — текущая и обновленная ячейки памяти,

$h_t$  — выходной вектор.

## 2.3. Полносвязные слои (Fully Connected Layers):

- Интегрируют извлеченные признаки, чтобы сформировать рекомендации.

- Формируют финальные выходы системы, такие как 3D карта, местоположение пожарных команд, прогнозы распространения пожара и т.д.

### 3. Прогнозирование и оценка рисков

Для оценки риска распространения пожара используется симуляция на основе методов Монте-Карло, которые позволяют учесть вероятностные изменения параметров, таких как температура, влажность и структура помещения.

$$P(\text{spread}) = \frac{1}{N} \sum_{i=1}^N f(\text{conditions}_i) . \quad (4)$$

Где  $f(\text{conditions}_i)$  — функция распространения пожара при условиях  $i$ , а  $N$  — количество симуляций.

### 4. Генерация рекомендаций

На основе анализа данных нейросеть формирует рекомендации для руководства по тушению пожара, включая:

- Оптимальные маршруты эвакуации.
- Приоритетные области тушения.
- Координацию команд в реальном времени, основываясь на данных о местоположении и расстояниях до препятствий, полученных от звеньев ГДЗС.

### 5. Визуализация и поддержка принятия решений

Система предоставляет руководству визуализацию полученной информации:

- 3D карта помещения с указанием места расположения очага пожара и потенциальных зон риска.
- Планировка сверху с отображением текущих позиций звеньев ГДЗС.
- Оперативные рекомендации, отображаемые на экране в реальном времени.

В заключение, разработанная нейросетевая экспертная система для поддержки принятия управленческих решений при тушении пожаров представляет собой интеграцию современных методов обработки данных с аппаратной платформы, включающей лидар, ультразвуковую фазированную решетку, датчики температуры и влажности. Система обеспечивает создание 3D моделей, прогнозирование поведения пожара и оперативную координацию действий пожарных команд. Применение нейронных сетей и алгоритмов симуляции, таких как мето-

ды Монте-Карло, позволяет достичь высокой точности прогнозов и рекомендаций, что значительно повышает эффективность и безопасность пожаротушения.

#### Список литературы

1. Яровой, В. Ю. Аналитический обзор подходов к информационной поддержке звеньев газодымозащитной службы при тушении пожаров и проведении аварийно-спасательных работ в зоне ограниченной видимости / В. Ю. Яровой, П. В. Ширинкин // Сибирский пожарно-спасательный вестник. – 2023. – № 1(28). – С. 136-144. – DOI 10.34987/vestnik.sibpsa.2023.95.54.011. – EDN QDNRWQ.
2. Кипер Александр Викторович, Станкевич Татьяна Сергеевна Разработка системы поддержки принятия решений руководителя тушения пожара на базе нечеткой нейронной сети ANFIS при пожаре на территории морского порта // Вестник АГТУ. Серия: Управление, вычислительная техника и информатика. 2013. №1. URL: [https://cyberleninka.ru/article/n/razrabotka-sistemy-podderzhki-prinyatiya-resheniy-rukovoditelya-tusheniya-pozhara-na-baze-nechetkoy-neyronnoy-seti-anfis-pri-pozhare-na](https://cyberleninka.ru/article/n/razrabotka-sistemy-podderzhki-prinyatiya-resheniy-rukovoditelya-tusheniya-pozhara-na-baze-nechetkoy-neyronnoy-seti-anfis-pri-pozhare-na-territorii-morskogo-porta) (дата обращения: 14.08.2024).
3. Использование нейросетевой модели обработки данных в системах обнаружения пожаров для определения места возгорания / А. И. Гусева, Г. Ф. Малыхина, В. Н. Круглеевский [и др.] // Морские интеллектуальные технологии. – 2019. – № 2-2(44). – С. 93-102. – EDN ZYZCCD.
4. Станкевич, Т. С. Анализ мирового и отечественного рынка программных средств, предназначенных для руководителя тушения пожара / Т. С. Станкевич // Безопасность жизнедеятельности. – 2014. – № 7(163). – С. 42-48. – EDN SIBLKL.
5. Чискидов Сергей Васильевич, Федин Федор Олегович, Петрова Алина Михайловна Определение подхода к повышению точности нейросетевых моделей прогнозирования лесных пожаров // Научные и образовательные проблемы гражданской защиты. 2017. №2 (33). URL: <https://cyberleninka.ru/article/n/opredelenie-podhoda-k-povysheniyu-tochnosti-neyrosetevyh-modeley-prognozirovaniya-lesnyh-pozharov> (дата обращения:

- 14.08.2024).
6. Аникин, С. Н. Особенности применения нейросетей при тушении подвижных железнодорожных составов / С. Н. Аникин // Проблемы техносферной безопасности: материалы международной научно-практической конференции молодых учёных и специалистов. – 2022. – № 11. – С. 271-276. – EDN FNUZEC.
  7. Денисов Алексей Николаевич, Данилов Михаил Михайлович, Аникин Сергей Николаевич, Цокурова Ирина Григорьевна Условия многозадачности управления пожарно-спасательными подразделениями при тушении подвижного железнодорожного состава на металлургических предприятиях // Computational nanotechnology. 2022. №1. URL: <https://cyberleninka.ru/article/n/usloviya-mnogozadachnosti-upravleniya-pozharno-spasatelnyimi-podrazdeleniyami-pri-tushenii-podvizhnogo-zheleznodorozhnogo-sostava-na> (дата обращения: 14.08.2024).
  8. Патент на полезную модель № 226706 U1 Российская Федерация, МПК А62С 99/00. Зондирующее пожарно-спасательное устройство : № 2023131029 : заявл. 27.11.2023 : опубл. 19.06.2024 / В. Ю. Яровой, П. В. Ширинкин. – EDN DGONYF.

## СПИСОК ДОКЛАДОВ

Х.С. Аль Уаттик, С.П. Пронин OPTIMIZED MODEL FOR GEARBOX FAULT DETECTION: A RANDOM FOREST APPROACH USING VIBRATION DATA	3
D.I. Antonov, S.V. Sukhov WEIGHT REGULARIZATION IN SPIKING NEURAL NETWORKS	10
Б.Б.Батуев, С.В.Сухов ПРЕДСКАЗАНИЕ ПОСЛЕДОВАТЕЛЬНОСТЕЙ С ПОМОЩЬЮ ИМПУЛЬСНЫХ НЕЙРОННЫХ СЕТЕЙ	18
Н.М. Богатов, А.Н. Богатова, А.Л. Еремин, С.А. Сухих ВЛИЯНИЕ ПСИХОЛОГИЧЕСКИХ ОСОБЕННОСТЕЙ СУБЪЕКТОВ НА РЕЗУЛЬТАТИВНОСТЬ ПРОЦЕССОВ САМОРЕГУЛЯЦИИ	27
С.Е.Головенкин МЕТОДЫ ПРОГНОЗИРОВАНИЯ ТЕЧЕНИЯ ЗАБОЛЕВАНИЙ СЕРДЕЧНО-СОСУДИСТОЙ СИСТЕМЫ	37
М.В. Гунер НЕЙРОСЕТЕВОЙ АНАЛИЗ ЗНАЧИМОСТИ ВХОДНЫХ ПАРАМЕТРОВ МОДЕЛИ ПРЕДСКАЗАНИЯ ПОСЛЕДУЮЩЕЙ УСПЕВАЕМОСТИ СТУДЕНТОВ, ЗАЧИСЛЕННЫХ В УНИВЕРСИТЕТ ПО ИТОГАМ ВСТУПИТЕЛЬНОГО ОНЛАЙН-ЭКЗАМЕНА	51
О.С. Малютин, Р.Ш. Хабибулин МОДУЛЬНЫЙ ПОДХОД К ГИБРИДИЗАЦИИ ЭВРИСТИЧЕСКИХ АЛГОРИТМОВ ПРОСТРАНСТВЕННОЙ ОПТИМИЗАЦИИ РАЗМЕЩЕНИЯ ПОЖАРНЫХ ПОДРАЗДЕЛЕНИЙ	60
Г.М. Маркова, С.И. Барцев	

ПРЕДЕЛЬНО ПРОСТО НЕ ЗНАЧИТ ПРЕДЕЛЬНО ЯСНО: О ПОВЕДЕНИИ ПРОСТЕЙШИХ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ НА РЕФЛЕКСИЮ	70
М.Ю.Сенашова, М.Г. Садовский, А.А. Шехова ТАКСОНОМИЯ ГЕНОМОВ ОСПЫ И СХОЖЕСТЬ ГЕНОВ, ВЫЧИСЛЕННАЯ ПРИ ПОМОЩИ БЫСТРОГО ПРЕОБРАЗОВАНИЯ ФУРЬЕ	80
А.В. Серебровский, Н.А. Корсунский, А.В. Лях, И.А. Халин, О.В. Шаталова МУЛЬТИМОДАЛЬНЫЙ КЛАССИФИКАТОР МЕДИЦИНСКОГО РИСКА НА ОСНОВЕ БИОИМПЕДАНСНОГО АНАЛИЗА	90
В.А. Углев, Г.А. Смирнов ОТОБРАЖЕНИЕ ДИНАМИКИ УЧЕБНОГО ПРОЦЕССА С ПОМОЩЬЮ КОГНИТИВНОЙ КАРТЫ ДИАГНОСТИКИ ЗНАНИЙ	101
М.Н.Фаворская СТРАТЕГИИ ГЛУБОКОГО ОБУЧЕНИЯ НА ОГРАНИЧЕННЫХ НАБОРАХ ДАННЫХ	107
В.Ю. Яровой, Я.В. Гребнев НЕЙРОСЕТИ КАК ИНСТРУМЕНТ ОПТИМИЗАЦИИ УПРАВЛЕНИЯ БОЕВЫМИ ДЕЙСТВИЯМИ НА ПОЖАРЕ	116

## СПИСОК АВТОРОВ

Ф.И.О.	Место работы	Стр.
Аль Уатик Хассан Саидович	656038, Российская Федерация, Алтайский край, г. Барнаул, пр. Ленина, 46, факультет информационных технологий E-mail: alh@dr.com	3
Антонов Дмитрий Иванович	432011, Ульяновск, ул. Гончарова, 48/2, Институт радиотехники и электроники им. В.А. Котельникова РАН, Ульяновский филиал E-mail: d.antonov@ulireran.ru	10
Барцев Сергей Игоревич	660036, Красноярск, ул. Академгородок, строение 50, Институт биофизики СО РАН E-mail: bartsev@yandex.ru	70
Батуев Булат Базаржапович	125009, г. Москва, ул. Моховая, 11, ИРЭ им. В.А. Котельникова РАН E-mail: buligarmouth@gmail.com	18
Богатов Николай Маркович	350040, г. Краснодар, ул. Ставропольская, 149 ФГБОУ ВО «Кубанский государственный университет» E-mail: bogatov@phys.kubsu.ru	27
Богатова Анна Николаевна	350040, г. Краснодар, ул. Ставропольская, 149 ФГБОУ ВО «Кубанский государственный университет» E-mail: anna_bogatova@mail.ru	27
Головенкин Сергей Евгеньевич	660022, Красноярск, ул. Партизана Железняка, 1, ФГБОУ ВО «Красноярский Государственный Медицинский Университет им. проф. В.Ф.Войно-Ясенецкого» МЗ РФ, E-mail: gse2008@mail.ru	37

Гребнев Ярослав Владимирович	Сибирский федеральный университет E-mail: yaroslav.grebnev@gmail.com	116
Гунер Михаил Викторович	660074 , Красноярск, ул. Академика Киренского, 26Б, Сибирский федеральный университет, институт космических и информационных технологий, кафедра систем искусственного интеллекта E-mail: horyzont1@mail.ru	51
Еремин Алексей Львович	350040, г. Краснодар, ул. Ставропольская, 149 ФГБОУ ВО «Кубанский государственный университет» E-mail: aereimin@yandex.ru	27
Корсунский Никита Александрович	305044, г. Курск, ул.50 лет Октября, 94, Юго-Западный государственный университет E-mail: cor.nick2013@yandex.ru	90
Лях Антон Викторович	305044, г. Курск, ул.50 лет Октября, 94, Юго-Западный государственный университет E-mail: kstu-bmi@yandex.ru	90
Малютин Олег Сергеевич	662972, Красноярский край, г. Железногорск, ул. Северная, 1, ФГБОУ ВО Сибирская пожарно-спасательная академия ГПС МЧС России E-mail: obsidian-pb@mail.ru	60
Пронин Сергей Петрович	656038, Российская Федерация, Алтайский край, г. Барнаул, пр. Ленина, 46, факультет информационных технологий E-mail: sppronin@mail.ru	3
Садовский Михаил Георгиевич	660036, Красноярск, Академгородок, Институт вычислительного моделирования СО РАН E-mail: msad@icm.krasn.ru	80
Сенашова Мария Юрьевна	660036, Красноярск, Академгородок, Институт вычислительного моделирования СО РАН	80



	E-mail: msen@icm.krasn.ru	
Серебровский Андрей Вадимович	305044, г. Курск, ул.50 лет Октября, 94, Юго- Западный государственный университет E-mail: grafjj@yandex.ru	90
Смирнов Георгий Артемович	662971, Железногорск, ул. Кирова, 12-а, Сибирский федеральный университет, филиал г. Железногорска E-mail: uglev-v@yandex.ru □	101
Сухих Станислав Алексеевич	350040, г. Краснодар, ФГБОУ ВО «Кубанский госу- дарственный университет», ул. Ставропольская, 149 E-mail: suhих_52@mail.ru	27
Сухов Сергей Вла- димирович	432011, Ульяновск, ул. Гончарова, 48/2, Институт ра- диотехники и электроники им. В.А. Котельникова РАН, Ульяновский филиал E-mail: s.sukhov@gmail.com	10, 18
Углев Виктор Александрович	662971, Железногорск, ул. Кирова, 12-а, Сибирский федеральный университет, филиал г. Железногорска E-mail: uglev-v@yandex.ru	101
Фаворская Марга- рита Николаевна	660014, Красноярск, пр. имени газеты «Красноярский рабочий», 31, Сибирский государственный универси- тет науки и технологий имени акад. М.Ф. Решетнева E-mail: favorskaya@sibsau.ru	107
Хабибулин Ренат Шамильевич	129366, г. Москва, ул. Бориса Галушкина, д. 4, Ака- демия Государственной противопожарной службы МЧС России E-mail: kh-r@yandex.ru	60
Халин Игорь Алексеевич	305044, г. Курск, ул.50 лет Октября, 94, Юго- Западный государственный университет E-mail: russianrocket1996@yandex.ru	90
Шаталова Ольга	305044, г. Курск, ул.50 лет Октября, 94, Юго-	90

Владимировна	Западный государственный университет E-mail: ShatOlg@mail.ru	
Шехова Анна Андреевна	660036, Красноярск, Академгородок, Институт вычислительного моделирования СО РАН E-mail: annamo@icm.krasn.ru	80
Яровой Вячеслав Юрьевич	662972, г. Железногорск, ул. Северная, 1 Сибирская пожарно-спасательная академия E-mail: yarovoiviacheslav@yandex.ru	116

*Научное издание*

**Нейроинформатика, её приложения и анализ данных**

Материалы XXXII Всероссийского семинара 27 сентября 2024 года

Редактор М.Ю. Сенашова  
Компьютерная верстка: М.Ю. Сенашова

Подписано в печать «15» августа 2024 г. Формат 60 × 90/8. (А4)  
Бумага офсетная. Печать плоская.  
Усл. печ. л. 11,0. Уч.-изд. л. 11,3.  
Тираж 300 экз. Заказ 12

---

Отпечатано в типографии ИВМ СО РАН  
660036, Красноярск, Академгородок