

ISSN 1684-8853 (print); ISSN 2541-8610 (online)

ИНФОРМАЦИОННО- УПРАВЛЯЮЩИЕ СИСТЕМЫ

НАУЧНЫЙ ЖУРНАЛ

1(104)/2020

1(104)/2020

PEER REVIEWED JOURNAL

INFORMATSIONNO- UPRAVLIAIUSHCHIE SISTEMY (INFORMATION AND CONTROL SYSTEMS)

Founder

«Information and Control Systems», Ltd.

PublisherSaint-Petersburg State University
of Aerospace Instrumentation**Editor-in-Chief**M. Sergeev
Dr. Sc., Professor, Saint-Petersburg, Russia**Deputy Editor-in-Chief**E. Krouk
Dr. Sc., Professor, Moscow, Russia**Executive secretary**

O. Muravtsova

Editorial Board

S. Andreev
Dr. Sc., Tampere, Finland

V. Anisimov
Dr. Sc., Professor, Saint-Petersburg, Russia

B. Bezruchko
Dr. Sc., Professor, Saratov, Russia

N. Blaunstein
Dr. Sc., Professor, Beer-Sheva, Israel

C. Christodoulou
PhD, Professor, Albuquerque, New Mexico, USA

A. Dudin
Dr. Sc., Professor, Minsk, Belarus

I. Dumer
PhD., Professor, Riverside, USA

M. Favorskaya
Dr. Sc., Professor, Krasnoyarsk, Russia

L. Fortuna
PhD, Professor, Catania, Italy

A. Fradkov
Dr. Sc., Professor, Saint-Petersburg, Russia

A. Hramov
Dr. Sc., Professor, Innopolis, Russia

L. Jain
PhD, Professor, Canberra, Australia

V. Khimenko
Dr. Sc., Professor, Saint-Petersburg, Russia

G. Maltsev
Dr. Sc., Professor, Saint-Petersburg, Russia

G. Matvienko
Dr. Sc., Professor, Tomsk, Russia

A. Myllari
PhD, Professor, Grenada, West Indies

Y. Podoplyokin
Dr. Sc., Professor, Saint-Petersburg, Russia

K. Samouylov
Dr. Sc., Professor, Moscow, Russia

J. Seberry
PhD, Professor, Wollongong, Australia

A. Shalyto
Dr. Sc., Professor, Saint-Petersburg, Russia

A. Shepeta
Dr. Sc., Professor, Saint-Petersburg, Russia

Yu. Shokin
RAS Academician, Dr. Sc., Novosibirsk, Russia

A. Smirnov
Dr. Sc., Professor, Saint-Petersburg, Russia

T. Sutikho
PhD, Associate Professor, Yogyakarta, Indonesia

Z. Yuldashev
Dr. Sc., Professor, Saint-Petersburg, Russia

R. Yusupov
RAS Corr. Member, Dr. Sc., Professor, Saint-Petersburg, Russia

A. Zeifman
Dr. Sc., Professor, Vologda, Russia

Editor: A. Larionova**Proofreader:** T. Zvertanovskaia**Design:** M. Chernenko, Y. Umnitsina**Layout and composition:** Y. Umnitsina**Contact information**

The Editorial and Publishing Center, SUAI
67, B. Morskaia, 190000, St. Petersburg, Russia
Website: <http://i-us.ru/en>, e-mail: i-us.spb@gmail.com
Tel.: +7 - 812 494 70 02

INFORMATION PROCESSING AND CONTROL

Polyakov E. V., Voskov L. S., Abramov P. S., Polyakov S. V. Generalized approach to sentiment analysis of short text messages in natural language processing 2

Iskhakova A. O., Alekhin M. D., Bogomolov A. V. Time-frequency transforms in analysis of non-stationary quasi-periodic biomedical signal patterns for acoustic anomaly detection 15

INFORMATION AND CONTROL SYSTEMS

Branitskiy A. A., Doynikova E. V., Kotenko I. V. Use of neural networks for forecasting of the exposure of social network users to destructive impacts 24

HARDWARE AND SOFTWARE RESOURCES

Grachev P. G., Muravyov S. B., Filchenkov A. A., Shalyto A. A. Automata generation based on recurrent neural networks and automated cauterization selection 34

INFORMATION CODING AND TRANSMISSION

Sharov S. N., Tolmachev S. G. Search for binary code sequences with low autocorrelation sidelobes by the evolutionary method 44

INFORMATION CHANNELS AND MEDIUM

Juwiler I., Bronfman I., Blaunstein N. Analysis of total signal decay and capacity of information data in wireless atmospheric communication links. Part 2 54

Dvornikov S. V., Konyukhovskiy V. S., Simonov A. N. Method of frequency-spatial selection of radio emissions using a triorthogonal antenna system 63

CONTROL IN MEDICAL AND BIOLOGICAL SYSTEMS

Kuc A. K., Maksimenko V. A., KHramova M. V., Hramov A. E. Study of sensory information processing depending on visual stimulus complexity based on multichannel EEG signals 73

CHRONICLES AND INFORMATION

In remembrance of N. N. Krasilnikov 81

INFORMATION ABOUT THE AUTHORS

83

1(104)/2020

ИНФОРМАЦИОННО-
УПРАВЛЯЮЩИЕ
СИСТЕМЫ

РЕЦЕНЗИРУЕМОЕ ИЗДАНИЕ

Учредитель
ООО «Информационно-управляющие системы»

Издатель
Санкт-Петербургский государственный университет
аэрокосмического приборостроения

Главный редактор
М. Б. Сергеев,
д-р техн. наук, проф., Санкт-Петербург, РФ

Зам. главного редактора
Е. А. Крук,
д-р техн. наук, проф., Москва, РФ

Ответственный секретарь
О. В. Муравцова

Редакционная коллегия:
С. Д. Андреев,
д-р техн. наук, Тампере, Финляндия
В. Г. Анисимов,
д-р техн. наук, проф., Санкт-Петербург, РФ
Б. П. Безручко,
д-р физ.-мат. наук, проф., Саратов, РФ
Н. Блаунштейн,
д-р физ.-мат. наук, проф., Беэр-Шева, Израиль
Л. С. Джайн,
д-р наук, проф., Канберра, Австралия
А. Н. Дудин,
д-р физ.-мат. наук, проф., Минск, Беларусь
И. И. Думер,
д-р наук, проф., Риверсайд, США
А. И. Зейфман,
д-р физ.-мат. наук, проф., Вологда, РФ
К. Кристодолу,
д-р наук, проф., Альбукерке, Нью-Мексико, США
Г. Н. Мальцев,
д-р техн. наук, проф., Санкт-Петербург, РФ
Г. Г. Матвиенко,
д-р физ.-мат. наук, проф., Томск, РФ
А. А. Мюллери,
д-р наук, профессор, Гренада, Вест-Индия
Ю. Ф. Подоплёкин,
д-р техн. наук, проф., Санкт-Петербург, РФ
К. Е. Самуилов,
д-р техн. наук, проф., Москва, РФ
Д. Себерри,
д-р наук, проф., Волонгонг, Австралия
А. В. Смирнов,
д-р техн. наук, проф., Санкт-Петербург, РФ
Т. Сутикнуоу,
д-р наук, доцент, Джокьякарта, Индонезия
М. Н. Фаворская,
д-р техн. наук, проф., Красноярск, РФ
Л. Фортуна,
д-р наук, проф., Катания, Италия
А. Л. Фрадков,
д-р техн. наук, проф., Санкт-Петербург, РФ
В. И. Хищенко,
д-р техн. наук, проф., Санкт-Петербург, РФ
А. Е. Храмов,
д-р физ.-мат. наук, Иннополис, РФ
А. А. Шальто,
д-р техн. наук, проф., Санкт-Петербург, РФ
А. П. Шепета,
д-р техн. наук, проф., Санкт-Петербург, РФ
Ю. И. Шокин,
акад. РАН, д-р физ.-мат. наук, проф., Новосибирск, РФ
З. М. Юлдашев,
д-р техн. наук, проф., Санкт-Петербург, РФ
Р. М. Юсупов,
чл.-корр. РАН, д-р техн. наук, проф., Санкт-Петербург, РФ

Редактор: А. Г. Ларионова
Корректор: Т. В. Звертановская
Дизайн: М. Л. Черненко, Ю. В. Умницына
Компьютерная верстка: Ю. В. Умницына

Адрес редакции: 190000, Санкт-Петербург,
Б. Морская ул., д. 67, ГУАП, РИЦ
Тел.: (812) 494-70-02, эл. адрес: ius.spb@gmail.com,
сайт: http://i-us.ru

ОБРАБОТКА ИНФОРМАЦИИ И УПРАВЛЕНИЕ

Polyakov E. V., Voskov L. S., Abramov P. S., Polyakov S. V. Generalized approach to sentiment analysis of short text messages in natural language processing 2

Iskhakova A. O., Alekhin M. D., Bogomolov A. V. Time-frequency transforms in analysis of non-stationary quasi-periodic biomedical signal patterns for acoustic anomaly detection 15

ИНФОРМАЦИОННО-УПРАВЛЯЮЩИЕ СИСТЕМЫ

Браницкий А. А., Дойникова Е. В., Котенко И. В. Использование нейросетей для прогнозирования подверженности пользователей социальных сетей деструктивным воздействиям 24

ПРОГРАММНЫЕ И АППАРАТНЫЕ СРЕДСТВА

Грачев П. Г., Муравьев С. Б., Фильченков А. А., Шальто А. А. Генерация автоматов на основе рекуррентных нейросетей и автоматического выбора кластеризации 34

КОДИРОВАНИЕ И ПЕРЕДАЧА ИНФОРМАЦИИ

Шаров С. Н., Толмачев С. Г. Поиск бинарных кодовых последовательностей с низким уровнем боковых лепестков эволюционным способом 44

ИНФОРМАЦИОННЫЕ КАНАЛЫ И СРЕДЫ

Juwiler I., Bronfman I., Blaunstein N. Analysis of total signal decay and capacity of information data in wireless atmospheric communication links. Part 2 54

Дворников С. В., Конюховский В. С., Симонов А. Н. Способ частотно-пространственной селекции радиоионизации с помощью триортогональной антенной системы 63

УПРАВЛЕНИЕ В МЕДИЦИНЕ И БИОЛОГИИ

Куц А. К., Максименко В. А., Храмова М. В., Храмов А. Е. Исследование процесса обработки зрительной информации в зависимости от ориентации стимулов по многоканальным записям ЭЭГ 73

ХРОНИКА И ИНФОРМАЦИЯ

Памяти Н. Н. Красильникова 81

СВЕДЕНИЯ ОБ АВТОРАХ

83

Журнал входит в БД SCOPUS, в RSCI на платформе Web of Science и в Перечень рецензируемых научных изданий, в которых должны быть опубликованы основные научные результаты диссертаций на соискание ученой степени кандидата наук, на соискание ученой степени доктора наук.

Сдано в набор 09.01.20. Подписано в печать 18.02.20. Формат 60×84^{1/8}.
Гарнитура SchoolBookС. Печать цифровая.

Усл. печ. л. 10,4. Уч.-изд. л. 14. Тираж 1000 экз (1-й завод 50 экз.). Заказ № 37.

Оригинал-макет изготовлен в редакционно-издательском центре ГУАП.
190000, Санкт-Петербург, Б. Морская ул., 67.

Отпечатано с готовых диапозитивов в редакционно-издательском центре ГУАП.
190000, Санкт-Петербург, Б. Морская ул., 67.

Журнал зарегистрирован в Министерстве РФ по делам печати, телерадиовещания и средств массовых коммуникаций.
Свидетельство о регистрации ПИ № 77-12412 от 19 апреля 2002 г.
Перерегистрирован в Роскомнадзоре.
Свидетельство о регистрации ПИ № ФС77-49181 от 30 марта 2012 г.

© Коллектив авторов, 2020

UDC 004.056

doi:10.31799/1684-8853-2020-1-2-14

Generalized approach to sentiment analysis of short text messages in natural language processing

E. V. Polyakov^a, Post-Graduate Student, orcid.org/0000-0002-6143-1408

L. S. Voskov^a, PhD, Tech., Professor, orcid.org/0000-0002-4008-8807, lvoskov@hse.ru

P. S. Abramov^a, Student, orcid.org/0000-0002-7079-0613

S. V. Polyakov^b, Post-Graduate Student, orcid.org/0000-0002-2151-6570

^aNational Research University «Higher School of Economics», 20, Myasnitskaya St., 101000, Moscow, Russian Federation

^bMoscow Aviation Institute (National Research University), 4, Volokolamskoe Sh., 125993, Moscow, Russian Federation

Introduction: Sentiment analysis is a complex problem whose solution essentially depends on the context, field of study and amount of text data. Analysis of publications shows that the authors often do not use the full range of possible data transformations and their combinations. Only a part of the transformations is used, limiting the ways to develop high-quality classification models.

Purpose: Developing and exploring a generalized approach to building a model, which consists in sequentially passing through the stages of exploratory data analysis, obtaining a basic solution, vectorization, preprocessing, hyperparameter optimization, and modeling. **Results:** Comparative experiments conducted using a generalized approach for classical machine learning and deep learning algorithms in order to solve the problem of sentiment analysis of short text messages in natural language processing have demonstrated that the classification quality grows from one stage to another. For classical algorithms, such an increase in quality was insignificant, but for deep learning, it was 8% on average at each stage. Additional studies have shown that the use of automatic machine learning which uses classical classification algorithms is comparable in quality to manual model development; however, it takes much longer. The use of transfer learning has a small but positive effect on the classification quality. **Practical relevance:** The proposed sequential approach can significantly improve the quality of models under development in natural language processing problems.

Keywords – natural language processing, machine learning, deep learning, vectorization, modeling, preprocessing, automatic machine learning, transfer learning.

For citation: Polyakov E. V., Voskov L. S., Abramov P. S., Polyakov S. V. Generalized approach to sentiment analysis of short text messages in natural language processing. *Informatsionno-upravliayushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 2–14. doi:10.31799/1684-8853-2020-1-2-14

Introduction

One of the most important research areas in machine learning is natural language processing [1] which solves the problems related to linguistic data, i. e. any textual content from Internet pages, books, forums or social networks. Determining the emotional coloring of a text (Sentiment Analysis) is a problem of algorithmically telling a negative statement from a positive one, whether it is an online article, comment on news or any other text written by any author. The main difficulty of sentiment analysis is that problems solved for one area cannot be successfully transferred to a different one [2]. As their basic component, sentiment analysis systems use a dictionary of words and phrases common in a particular area, which can significantly differ even from a dictionary for an adjacent area. As an example of such differences, we compared the distribution of words in two data sets (Fig. 1).

The first set of data is the visitors' feedback at the IMDb (Internet Movie Database) website [3] for movie search; the second one is the customers' feedback at the Amazon online store [4]. After analyzing

the distribution of words, you can find the differences in their dictionaries. The IMDb dictionary differs from the Amazon one in almost every component. Another feature are collocations. While in the Amazon reviews bigrams look quite informative, the IMDb reviews need trigrams to be informative. In other words, a combination of bigrams and trigrams gives a better understanding in the case of IMDb, while for the Amazon case bigrams are enough. Thus, each sentiment analysis problem is individual, requiring a separate study. This makes sentiment analysis an important research field.

Related works

Despite a relatively large number of works devoted to comparing approaches and methods for sentiment analysis, most of them study only some aspects of solving the problem [5–12]. For example, in [5], the authors compare the approach based on the lexical algorithm from the Apache Hadoop architecture and Stanford coreNLP library with the implementation of recursive neural networks. The

researchers classify the sentiments of the reviews left at a zoological forum. However, their paper avoids the comparison of sequential approaches traditionally used in natural language processing. In [6], a mood analysis system was proposed for enterprise software developers. The authors limited themselves to using only a set of vectorizers, classic machine learning models, and a preprocessing stack. The proposed SentiSW tools showed acceptable recognition quality. In [11], a BAM model was proposed for mood classification. A novel bi-level attention approach was used, which provided results of high quality. The data used were short texts in Chinese. The authors compared a large number of vectorizers and deep learning models, but did not consider the stages of data preprocessing and hyperparameter setting. Another work [12] discusses

an approach based on the resolution of ambiguities. The authors try to find the best algorithm by heuristic selection of models, using different preprocessing techniques and various deep learning models. They applied the learning transfer approach, but did not consider hyperparameter optimization. Table 1 shows a comparative analysis of the stages of experiments conducted by the authors of the above works and the stages of our work.

We propose a generalized approach to sentiment analysis of short text messages, which consists in sharing all the main stages in the development of forecast models: intelligence analysis, basic solution, vectorization, preprocessing, modeling and hyperparameter tuning. The combined use of these stages allows you to get better results. For the experiments, we chose the Python programming lan-

■ **Table 1.** Comparative analysis of the stages

Research	Intelligence data analysis	Base line	Vectorization/ vectorizer comparison	Preprocessing/ preprocessing comparison	Modeling/model comparison		Transfer learning	Tuning hyperparameters	Automatic machine learning
					Classical machine learning	Deep learning			
Sentiment analysis in a cross-media analysis framework [5]	Partially	No	No	No	The lexical algorithm from Apache-Hadoop	Stanford coreNLP, RNTN	Partially	No	No
Entity-level sentiment analysis of issue comments [6]	Yes	No	TF-IDF, Doc2Vec	Symbols, Stop-Words, Punctuation, Marks, Tokenization, Stemming	Random Forest, Bagging, Gradient Boosting Tree, Naive Bayes, Ridge Regression, Linear Support, Vector Machine	No	No	No	No
Bi-level attention model for sentiment analysis of short texts [11]	Partially	No	BoW, MCNN, GloVe, Word2Vec, FastText, T-WAM	No	SVM	Bi-GRU, AttBiLSTM, TMN, T-WAM, BAM, MCNN, RCNN, VDCNN	BERT	No	No
Thai comments sentiment analysis on social networks with deep learning approach [12]	Partially	No	No	Username, Symbols, Phrase Substitution, Character Replacement	No	NB, CNN, CNN+ATTN, BLSTM, BLSTM+ATTN, CNN+BLSTM, CNN+BLSTM+ATTN, BGRU, BGRU+ATTN, CNN+BGRU, CNN+BGRU+ATTN	ULM-FIT	No	No
This paper	Yes	Yes	BoW, TF-IDF, Word2Vec, Doc2Vec	Lower Case, Stop-Words, Symbols, Lemmatization, Stemming, Tokenization	Logistic Regression, Random Forest, Linear SVC, Gradient Boosting	FFNN, SimpleRNN, LSTM, GRU, BidirectionalSimple RNN, BidirectionalLSTM, BidirectionalGRU, Convolution1D	GloVe, BERT	Yes	Yes

guage, along with the main libraries scikit-learn, Keras, Gensim and Plotly. We used Ubuntu Linux 19.04 operating system, 32 GB of RAM, swap file of size 64 GB, a video card Nvidia GeForce RTX 2060 / PCIe / SSE2 / 6 GB, and a processor Intel Core i7-8700 CPU / 3200 GHz x12.

Research methodology

At each stage of our research, we will consistently apply the basic existing approaches to data processing, conduct experiments and evaluate the results obtained. The conceptual scheme of the research is shown in Fig. 2.


The exploratory analysis is carried out to study the nature of the data; according to its results, an assumption is made about the choice of metric and the set of models suitable for the problem. The basic solution is the first solution that gives us an understanding of what quality of the model can be

obtained without any sophisticated data manipulations. At the vectorization stage, we sequentially train a set of commonly used vectorizers in order to identify the most suitable one. The preprocessing stage can either significantly improve or worsen the final model; therefore, it is necessary to conduct experiments with preprocessing of various types and to identify the best one.

After the preprocessing stage, the stage of modeling and hyperparameter tuning is performed in order to increase the effect of the previous stages by fine-tuning of the vectorizer model and classification model. Table 2 sums up and briefly describes the development stages in the proposed generalized approach.

Exploratory data analysis

Exploratory data analysis assumes obtaining information about the nature of the data in order to



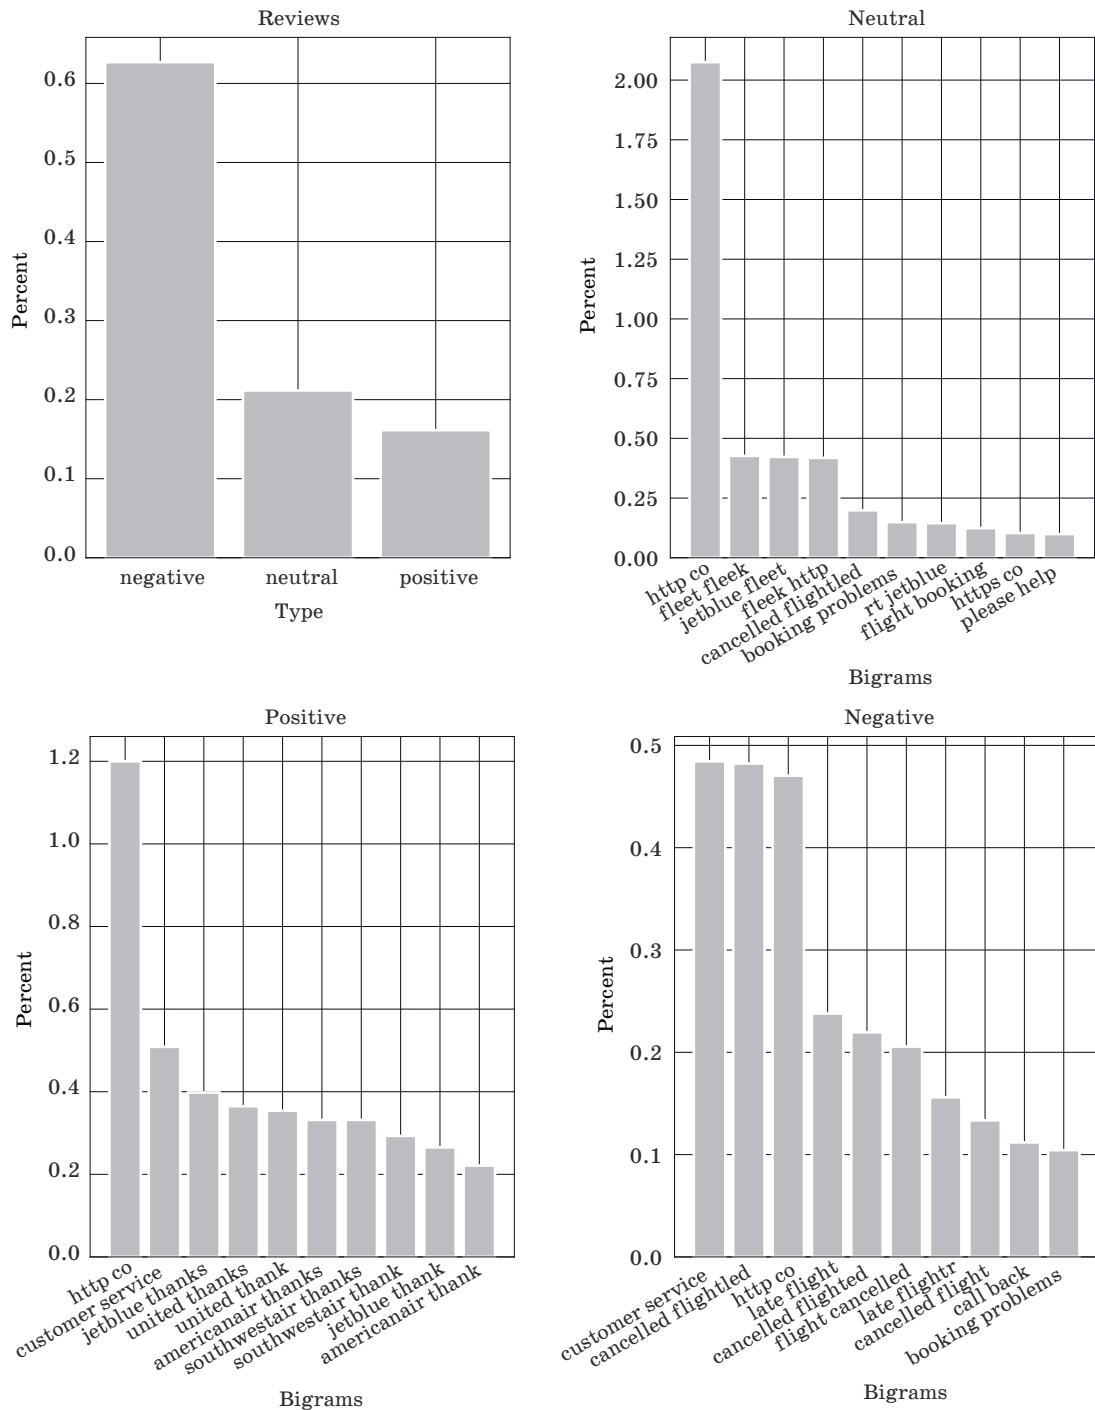
■ Fig. 2. Conceptual scheme of the research

■ Table 2. Generalized approach development stages

Input	Stage	Process	Output
Raw data	Exploratory data analysis	Visual data analysis, selection based on analysis of metrics and models	Metric(s), model(s)
Raw data, metric(s), model(s)	BaseLine	Training of a simple classification model(s) and a simple vectorizer on basic settings	Base model, base score
Raw data, metric(s), base model	Vectorization	Cyclic training of vectorizer models and the basic classification model at basic settings	Best vectorizer, vectorized data, base model
Best vectorizer, vectorized data, base model, metric(s)	Preprocessing	Cyclic data conversion and training on the basic model and the best vectorizer on the basic settings	Best preprocessing, best vectorizer, vectorized data, base model
Best vectorizer, best preprocessing, vectorized data, base model, metric(s)	Modeling	Cyclic training of different models with the best preprocessing and with the best vectorizer at basic settings	Best model, best vectorizer, best preprocessing, vectorized data
Best model, best vectorizer, best preprocessing, vectorized data, metric(s)	Tuning hyper-parameters	Setting hyperparameters for vectorizers and classification models	Customized vectorizer model, customized classifier model

■ Table 3. Twitter users' reviews

Tonality	Text
Positive	1. Thank you for the response, we got it resolved at the counter. 2. ... I love you. Air travel doesn't get easier.
Neutral	1. You must follow me in order for me to send you a direct message if that is what you meant. 2. ha, ha not a make or break for me either way!
Negative	1. I agree but per the captain this issue happened before boarding & we all sat in the plane for almost 2 hrs 2. no it weighed 45.5 and it was the only checked bag



■ Fig. 3. Key statistics on the word distribution in the US airline Twitter comment data set

choose metric and a set of models most appropriate for solving the problem. For the experiments, we chose a benchmark data set containing 14.640 short messages left in Twitter by American airline customers [13]. Examples of the reviews from Twitter users are presented in Table 3.

Statistics of the word distribution in the reviews (Fig. 3) show that the distribution of classes in the samples is not balanced: about 60% of the messages are negative, 23% are neutral, and 17% are positive. For comparison, it is common to use such metrics as Accuracy, Precision or Recall which identify the prediction accuracy separately and independently for each class [14]. The aim of our study is to compare the ability of a model to generalize on the base of a sequence of dependent stages, not by a separate class. Therefore, as a metric for comparison, the ROC-AUC metric [15] was taken which takes into account the actual imbalance of the classes and reflects the stability of the model.

In natural language processing problems, both classical machine learning and deep learning are used. The choice of algorithms depends on the volume and complexity of the data. Often, when the data is huge in volume and the structure is complex, deep learning does the job better. However, determining the data complexity is a difficult task, strongly depending on the experience of the data processing specialist. The 14.640 tweets we used in our research cannot be considered as either small or large amount of data to make a straightforward decision on the choice of an algorithm. We will conduct a comparative study of using both classical algorithms and deep learning in order to demonstrate that deep learning provides the best result with our generalized approach.

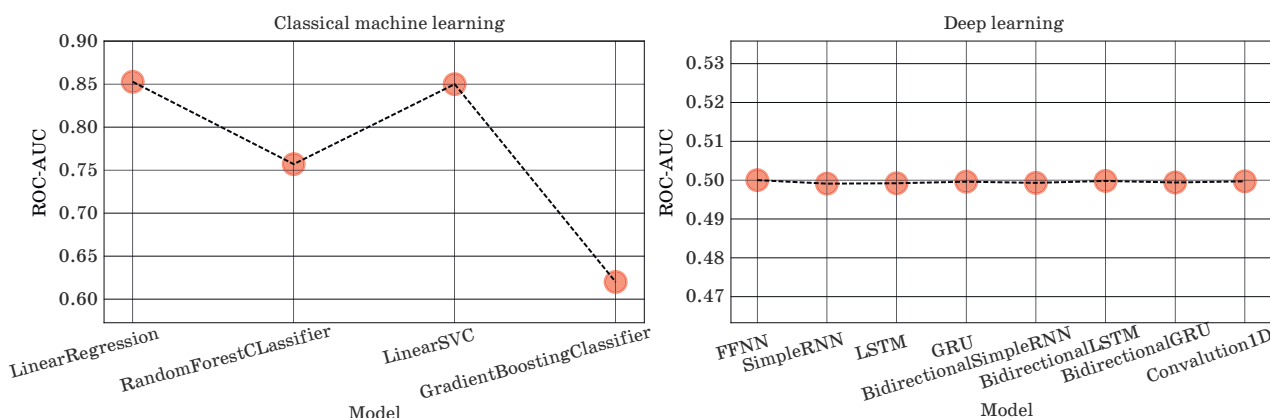
Basic solution

To get a basic solution, we have trained the vectorizer model and the classification models for both

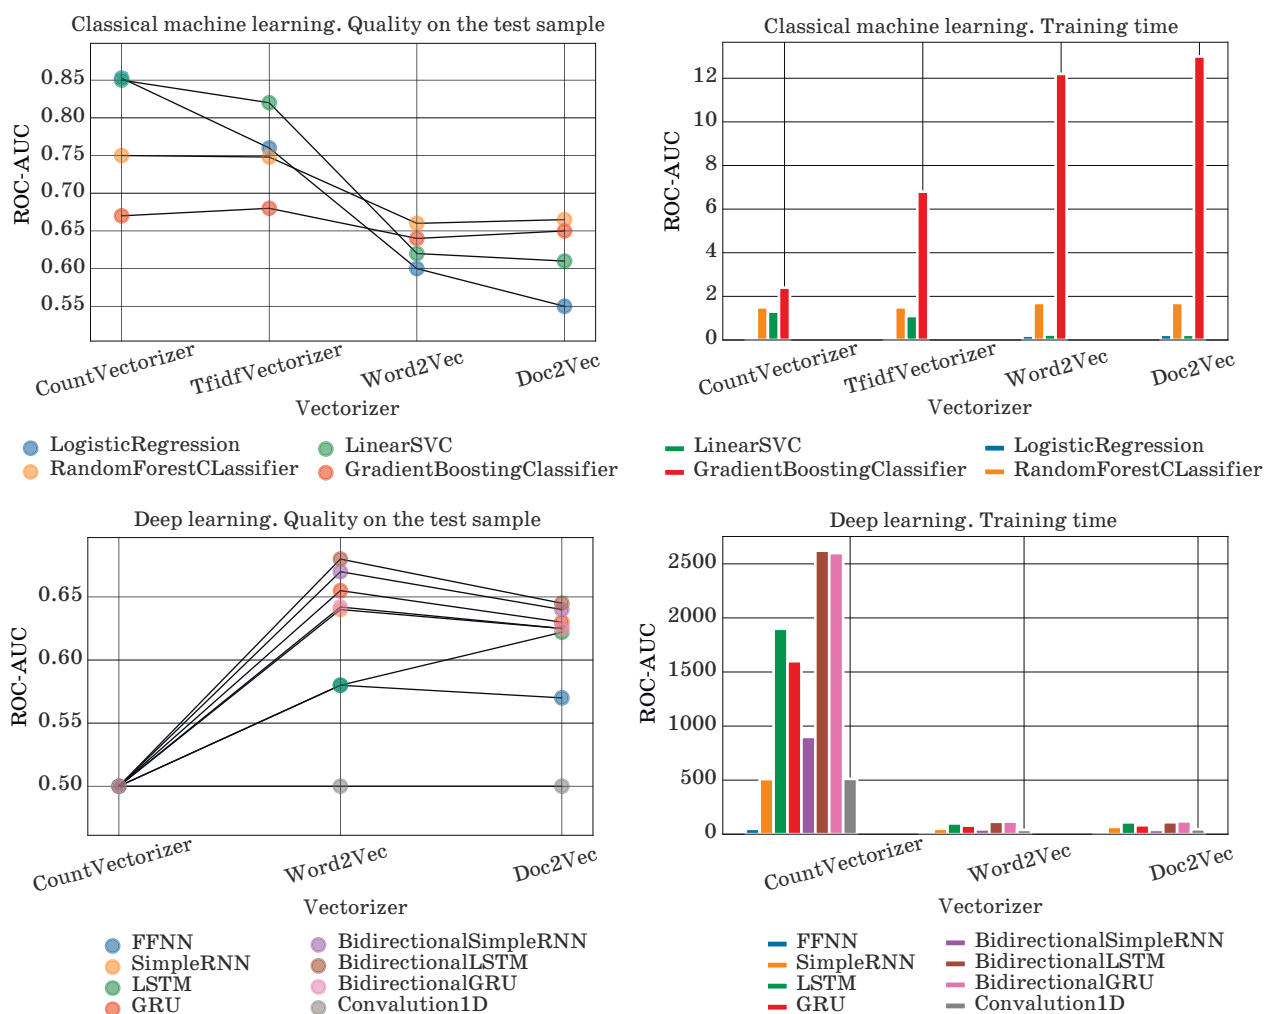
classical algorithms and deep learning. All the training was carried out with the default parameters set up by the developers of the *Keras* library, on 10 eras for deep learning and for classical algorithms, and with default settings for the *scikit-learn* library. The basic solution with classical machine learning and deep learning algorithms is shown in Fig. 4. Evaluation by ROC-AUC metric shows the quality of the basic solution and the machine time spent in the experiment: 0.12 s for CountVectorizer and LogisticRegression, and 11.83 s for FFNN and CountVectorizer. We will use the obtained values of the ROC-AUC metric in the future to evaluate the next steps when improving the model. The resulting low quality (0.5) of the basic model (see Fig. 4) for neural networks using deep learning as compared to the classical machine learning algorithms (0.85) does not mean that the model is unsuitable; the model may be too simple to generalize the data and should be improved. Improving the model by increasing its complexity is a way to improve the classification quality, which will be demonstrated below.

Vectorization

To improve the model, you can use various vectorizers which convert text data into numbers. We use four types of vectorizers with different approaches to text encoding: CountVectorizer (Bag of Words) [16], TfidfVectorizer [17], Word2Vec, and Doc2Vec [18]. These vectorizers were chosen because statistically they are more likely to provide a higher vectorization quality, being commonly used to solve problems of this kind. An improved model with vectorization showed that the basic solution found by the classical algorithms remained the best; however, algorithms based on neural networks significantly improved their performance from 0.5 to 0.68. The best model of the previous step was changed from FFNN to BidirectionalLSTM, and



■ Fig. 4. Basic solution using classic machine learning and deep learning algorithms



■ Fig. 5. Vectorizer selection

the vectorizer was changed to Word2Vec. The improved model had a higher complexity which led to a longer training time: it increased from 11.83 s to 43.7 min (Fig. 5).

Data preprocessing

In our work, we used the most popular types of preprocessing (Table 4): reduction to lower case (lc), deletion of stop words (sw), deletion of characters (sum), lemmatization (lemm), stemming (stem), and combinations thereof [19]. First, those preprocessing types are used which least affect the text structure, followed by those which have a greater effect on it. Processing with the name “dum” means no processing. The preliminary data processing (Fig. 6) provided only a slight increase in quality for LogisticRegression and CountVectorizer from 0.8527 to 0.8577 relative to the previous stage and the basic solution.


The training time increased from 0.12 to 0.80 s. With deep learning, we managed to obtain more significant results, increasing the ROC-AUC from 0.6818 to 0.7649. This time, the model with LSTM layers and such preprocessing as lemmatization or stemming instead of BidirectionalLSTM showed better results, which reduced the training time from 43.7 min down to 27.16 min, respectively.

Modeling and hyperparameter optimization

The previous steps allowed us to choose important joint components: the metric, vectorizer, preprocessing parameters and model. The stage of modeling and hyperparameter optimization is aimed at improving the quality of the resulting model achieved at the previous stages. We use one of the HyperOpt smart tuners [20] based on the Bayesian optimizer in order to avoid a complete

■ Table 4. Preprocessing examples

Preprocessing type	Preprocessing example
dum	I agree but per the captain this issue happened before boarding & we all sat in the plane for almost 2 hrs
lc	I agree but per the captain this issue happened before boarding & we all sat in the plane for almost 2 hrs
sw	Agree per captain issue happened boarding & sat plane almost 2 hrs
sum	I agree but per the captain this issue happened before boarding we all sat in the plane for almost 2 hrs
lemm	I agree but per the captain this issue happened before boarding & we all sat in the plane for almost 2 hrs
stem	I agre but per the captain this issu happen befor board & we all sat in the plane for almost 2 hrs
all	Agre per captain issu happen board sat plane almost 2 hrs
tokens	['I', 'agree', 'but', 'per', 'the', 'captain', 'this', 'issue', 'happened', 'before', 'boarding', '&', 'we', 'all', 'sat', 'in', 'the', 'plane', 'for', 'almost', '2', 'hrs']



■ Fig. 6. Data preprocessing results

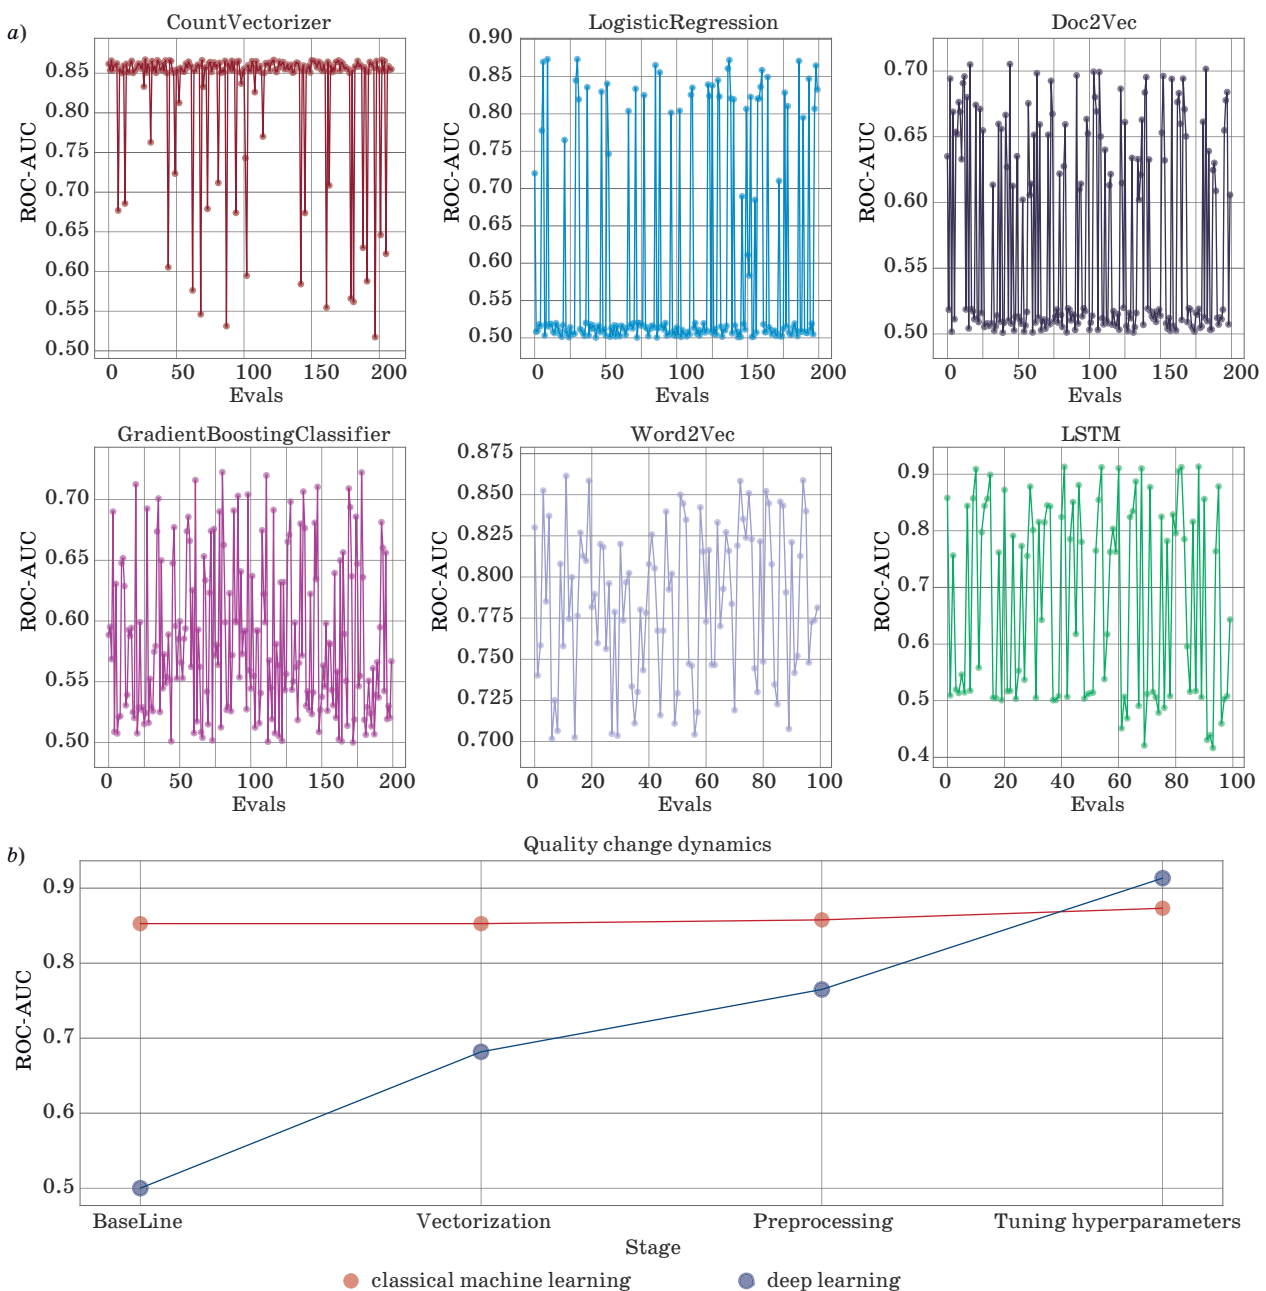
enumeration of parameters and significantly reduce the execution time for this stage.

First, we sequentially tune the vectorizers and models for classical algorithms, and then tune the parameters for deep learning in the same way. As a result of tuning the hyperparameters for CountVectorizer, the ROC-AUC grew from 0.8577 to 0.8671, while with the LogisticRegression tuning, the increase was up to 0.8732 (Fig. 7, a). The modeling time increased from 0.80 s to 32.8 min. Tuning Word2Vec for deep learning increased the ROC-AUC from 0.7649 to 0.8615, while tuning a neural network on LSTM [21] further increased the ROC-AUC up to

0.9133. The modeling time increased from 27.16 min to 79.3 h. For deep learning, we tuned such parameters as the activation functions, range of hidden layers/neurons, optimizers and level of thinning, in order to reduce the effect of retraining.

The application of the proposed generalized approach to sentiment analysis of short text messages provided the best result (0.9133) on sets for which the classical algorithms showed a good result in the basic solution (0.85) and significant improvement from one stage to another (Fig. 7, b).

The results of the hyperparameter optimization, the number of the iterations for the best param-



■ Fig. 7. Hyperparameter tuning: a — iterations of the tuning; b — effect of the stages on the ROC-AUC results

■ **Table 5.** Default hyperparameters

Model	Default hyperparameters
CountVectorizer	analyzer: 'word', binary: False, max_df: 1.0, max_features: None, ngram_range: (1, 1)
LogisticRegression	C: 1.0, class_weight: None, dual: False, fit_intercept: True, max_iter: 100, penalty: 'l2', tol: 0.0001
Doc2Vec	alpha: 0.0001, dbow_words: 0, dm: 1, dm_concat: 0, dm_mean: None, epochs: 10, max_vocab_size: None, min_count: 100, negative: 5, ns_exponent: 0.75, vector_size: 40, window: 1
GradientBoostingClassifier	learning_rate: 0.1, loss: 'deviance', max_depth: 3, max_features: None, min_impurity_decrease: 0.0, min_samples_leaf: 1, min_samples_split: 2, min_weight_fraction_leaf: 0.0, subsample: 1.0
Word2Vec	alpha: 0.025, cbow_mean: 1, hs: 0, iter: 5, max_num_words: 100, max_seq_length: 10, max_vocab_size: None, min_count: 5, negative: 5, ns_exponent: 0.75, sample: 0.001, sg: 0, size: 100, window: 5
LSTM	activation: 'relu', units: 32, optimizer: 'RMSprop', epochs: 3, dropouts: 0.2

■ **Table 6.** Hyperparameter optimization results

Model	Intervals/best options	Iteration	ROC-AUC
CountVectorizer	analyzer ('word', 'char', 'char_wb'): 'char_wb' binary (True, False): False max_df (0.2...1): 0.6 max_features (100...500000): 28100 ngram_range (1...14): (1, 10)	61	0.8671
LogisticRegression	C (0.1...0.9): 0.6241 class_weight ('balanced', None): 'balanced' fit_intercept (True, False): True max_iter (1...1000): 801 penalty ('l1', 'l2'): 'l2' tol (0.0001...1000): 1.0011	142	0.8732
Doc2Vec	alpha (0.0001...10): 7.0001 dbow_words (1, 0): 0 dm (1, 0): 1 dm_concat (1, 0): 1 dm_mean (1, 0): 1 epochs (1...100): 41 max_vocab_size (None, 100...20000): 12100 min_count (100...2000): 100 negative (5...21): 7 ns_exponent (0...1.0): 0.15 vector_size (40...1000): 800 window (1...20): 8	128	0.7053
GradientBoostingClassifier	learning_rate (0.01...10): 0.61 loss ('deviance', 'exponential'): 'exponential' max_depth (2...20): 19 max_features (None, 1...100): None min_impurity_decrease (0...10): 1.6 min_samples_leaf (1...20): 8 min_samples_split (2...10): 5 min_weight_fraction_leaf (0...0.5): 0.1 subsample (0.001...1): 0.64	104	0.7225

ters, as well as the selection ranges are presented in Table 6. The default hyperparameters for the models are presented in Table 5.

Other methods

Automatic machine learning. There are libraries which allow you to automate the processes of model development [22–24]. The most famous one is TPOT [22]. This library uses a genetic algorithm to optimize machine learning pipelines.

The library supports the following stages: selection of features, preprocessing, construction of features, model selection and hyperparameter optimization. We have compared the results of using the

library with the results obtained for all the manual development stages and obtained a comparable ROC-AUC quality which was 0.8724 versus 0.8732 when manually setting up the model. The process took a rather long time, 13.6 h. Unfortunately, for neural networks there are only limited versions of libraries for automatic learning. For example, Auto-Keras [24] supports optimization only for two-dimensional convolutional neural networks, which rules out using these methods for natural language processing problems.

Transfer learning. There are models trained on a large amount of data using huge computing resources. They can be used as ready-made vectorizers without prior training, for example, GloVe [25], ELMo [26], ULMFit [27] or BERT [28]. In our case, the best vec-

torizer was Word2Vec which we replaced by GloVe (a 100-dimensional vector, pre-trained on Twitter messages) and BERT (768-dimensional one). The quality grew up to 0.9232 and 0.9269, respectively.

The discussion of the results

We proposed a generalized approach to sentiment analysis of short text messages and compared it with the classical machine learning algorithms. The comparison showed that the proposed approach provided the best result and showed a significant improvement from one stage to another (Table 7). Using automatic machine learning for classical algorithms is comparable in quality to manual model development, but takes a much longer time. Transfer learning with standard settings slightly improves the model quality.

The aim of this work was to study how a complete generalized approach with various stages affects the model development, as compared to the approaches with selective or partial implementation of stages. We did not make any comparisons with the works whose authors also did sentiment analysis of short text messages using the same set of data, but we have presented the results demonstrating

the improvement of the model as a whole, from one stage to another, as shown in Fig. 7, b.

Conclusion

The paper is devoted to a generalized approach to sentiment analysis of text messages left by customers of American airlines in a microblog. We discussed various approaches, comparing their methods of data preprocessing, vectorization, modeling and hyperparameter tuning, based on classical algorithms or deep learning algorithms. The results showed that the use of the stages studied in this work has a significant effect, being able to improve the quality by approximately 5%, compared to the classical algorithms. The latest SOTA solutions and learning transfer technology are discussed, too.

Financial support

The research was supported by the Academic Fund Program at the National Research University Higher School of Economics (HSE) in 2019–2020 (grant 19-04-022) and by the Russian Academic Excellence Project 5-100.

■ Table 7. Comparison of the generalized approach

Stage	Classical machine learning	Deep learning	ROC-AUC		Time	
			ML	DL	ML	DL
BaseLine	CountVectorizer+ LogisticRegression	CountVectorizer(Embed- ding)+FFNN	0.8527	0.5	0.12 s	11.83 s
Vectoriza- tion	CountVectorizer+ LogisticRegression	BidirectionalLSTM+ Word2Vec	0.8527	0.6818	0.12 s	43.7 min
Preprocess- ing	CountVectorizer+ LogisticRegression+Stemming	BidirectionalLSTM+ Word2Vec+Stemming	0.8547	0.7392	0.28 s	37.3 min
Preprocess- ing combi- nations	CountVectorizer+ LogisticRegression+ Remove Characters+Lemmatization+ Stemming	LSTM+Word2Vec+ Lemmatization+Stemming	0.8577	0.7649	0.80 s	27.16 min
Tuning hyperpa- rameters	CountVectorizer+LogisticRegression+ Remove Characters + Lemmatization+Stemming +Settings	LSTM+Word2Vec+ Lemmatization+ Stemming+Settings	0.8732	0.9133	32.8 min	79.3 h
Automatic machine learning	TPOT	—	0.8724	—	13.6 h	—
Transfer learning	—	LSTM+GloVe+ Lemmatization+Stemming+ Best hyperparameters	—	0.9232	—	37 min
Transfer learning	—	LSTM+BERT+ Lemmatization+ Stemming+ Best hyperparameters	—	0.9269	—	2 h

References

1. *Natural language processing*. Available at: <https://becominghuman.ai/a-simple-introduction-to-natural-language-processing-ea66a1747b32> (accessed 11 August 2019).
2. **Ikoro V., Sharmina M., Malik K., and Batista-Navarro R.** Analyzing sentiments expressed on Twitter by UK Energy Company consumers. *2018 Fifth International Conference on Social Networks Analysis, Management and Security (SNAMS)*, Valencia, 2018, pp. 95–98.
3. *Large movie review dataset*. Available at: <http://ai.stanford.edu/~amaas/data/sentiment/> (accessed 11 August 2019).
4. *Amazon reviews for sentiment analysis*. Available at: <https://www.kaggle.com/bittlingmayer/amazonreviews> (accessed 11 August 2019).
5. **Woldemariam Y.** Sentiment analysis in a cross-media analysis framework. *2016 IEEE International Conference on Big Data Analysis (ICBDA)*, Hangzhou, 2016, pp. 1–5.
6. **Ding J., Sun H., Wang X., and Liu X.** Entity-level sentiment analysis of issue comments. *2018 IEEE/ACM 3rd International Workshop on Emotion Awareness in Software Engineering (SEmotion)*, Gothenburg, 2018, pp. 7–13.
7. **Kumar M., and Bala A.** Analyzing Twitter sentiments through big data. *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)*, New Delhi, 2016, pp. 2628–2631.
8. **Sabra K., Zantout R., EI-Abed M., and Hamandi L.** Sentiment analysis: Arabic sentiment lexicons. *2017 Sensors Networks Smart and Emerging Technologies (SENSET)*, Beirut, 2017, pp. 1–4.
9. **Vanaja S., and Belwal M.** Aspect-level sentiment analysis on E-commerce data. *2018 International Conference on Inventive Research in Computing Applications (ICIRCA)*, Coimbatore, 2018, pp. 1275–1279.
10. **Alshari E. M., Azman A., Doraisamy S., Mustapha N., and Alkeshr M.** Effective method for sentiment lexical dictionary enrichment based on Word2Vec for sentiment analysis. *2018 Fourth International Conference on Information Retrieval and Knowledge Management (CAMP)*, Kota Kinabalu, 2018, pp. 1–5.
11. *Bi-level attention model for sentiment analysis of short texts*. Available at: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=\&arnumber=8807106\&isnumber=6514899> (accessed 11 August 2019).
12. **Piyaphakdeesakun C., Facundes N., and Polvichai J.** Thai comments sentiment analysis on social networks with deep learning approach. *2019 34th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC)*, JeJu, Korea (South), 2019, pp. 1–4.
13. *Twitter US airline sentiment*. Available at: <https://www.kaggle.com/crowdflower/twitter-airline-sentiment> (accessed 11 August 2019).
14. *Top 15 evaluation metrics for classification models*. Available at: <https://www.machinelearningplus.com/machine-learning/evaluation-metrics-classification-models-r/> (accessed 11 August 2019).
15. **Brown Christopher D., Davis Herbert T.** Receiver operating characteristic curves and related decision measures: a tutorial. *Chemometrics and Intelligent Laboratory Systems*, 2006, vol. 80, pp. 24–38.
16. *A Gentle introduction to the bag-of-words model*. Available at: <https://machinelearningmastery.com/gentle-introduction-bag-words-model/> (accessed 11 August 2019)
17. *Tf-idf*. Available at: <http://www.tfidf.com/> (accessed 11 August 2019).
18. *Efficient estimation of word representations in vector space*. Available at: <https://arxiv.org/abs/1301.3781v3> (accessed 11 August 2019).
19. *All you need to know about text preprocessing for NLP and Machine Learning*. Available at: <https://www.kdnuggets.com/2019/04/text-preprocessing-nlp-machine-learning.html> (accessed 11 August 2019).
20. *Hyperopt. Distributed asynchronous hyperparameter optimization in Python*. Available at: <http://hyperopt.github.io/hyperopt/> (accessed 11 August 2019).
21. **Hochreiter S., Schmidhuber J.** Long short-term memory. *Neural Computation*, 1997, vol. 9, no. 8, pp. 1735–1780.
22. **Randal S. Olson, Ryan J. Urbanowicz, Peter C. Andrews, Nicole A. Lavender, La Creis Kidd, and Jason H.** Automating biomedical data science through tree-based pipeline optimization. *Applications of Evolutionary Computation*, 2016, pp. 123–137.
23. *Auto-Sklearn*. Available at: <https://automl.github.io/auto-sklearn/master/> (accessed 11 August 2019).
24. *Auto-Keras: An efficient neural architecture search system*. Available at: <https://arxiv.org/abs/1806.10282v3> (accessed 11 August 2019).
25. *GloVe: Global vectors for word representation*. Available at: <https://nlp.stanford.edu/projects/glove/> (accessed 11 August 2019).
26. *Extending a parser to distant domains using a few dozen partially annotated examples*. Available at: <https://arxiv.org/abs/1805.06556v1> (accessed 11 August 2019).
27. *Universal language model fine-tuning for text classification*. Available at: <https://arxiv.org/abs/1801.06146v5> (accessed 11 August 2019).
28. *BERT: Pre-training of deep bidirectional transformers for language understanding*. Available at: <https://arxiv.org/abs/1810.04805v2> (accessed 11 August 2019).

УДК 004.056

doi:10.31799/1684-8853-2020-1-2-14

Исследование обобщенного подхода к решению задач анализа настроений коротких текстовых сообщений в задачах обработки естественного языкаЕ. В. Поляков^а, аспирант, orcid.org/0000-0002-6143-1408, epolyakov@hse.ruЛ. С. Восков^а, канд. техн. наук, профессор, orcid.org/0000-0002-4008-8807, lvoskov@hse.ruП. С. Абрамов^а, студент, orcid.org/0000-0002-7079-0613, psabramov@edu.hse.ruС. В. Поляков^б, аспирант, orcid.org/0000-0002-2151-6570, s.polyakov@mai.ru^аНациональный исследовательский университет «Высшая школа экономики», Мясницкая ул., 20, Москва, 101000, РФ^бМосковский авиационный институт (национальный исследовательский университет), Волоколамское ш., 4, Москва, 125993, РФ

Введение: определение тональности текста — сложная проблема, решение которой существенно зависит от контекста, объема исследования и объема текстовых данных. Проведенный анализ публикаций показывает, что авторы в своих работах не используют полный спектр возможных преобразований над данными и их комбинаций. Используется только некоторая часть преобразований, что не позволяет в полной мере разрабатывать модели высокого качества классификации. **Цель:** разработка и исследование обобщенного подхода к построению модели, который заключается в последовательном прохождении этапов разведочного анализа, получения базового решения, векторизации, предобработки, настройки гиперпараметров и моделирования. **Результаты:** сравнительные эксперименты, проведенные с применением обобщенного подхода для классических алгоритмов машинного обучения и глубокого обучения к решению задачи анализа настроений коротких текстовых сообщений в области обработки естественного языка, показали динамику роста качества классификации от этапа к этапу. Для классических алгоритмов такой рост качества был незначительным, но для глубокого обучения прирост качества на каждом этапе в среднем составил 8 %. Проведение дополнительных исследований показало, что использование автоматического машинного обучения, в котором применяются классические алгоритмы классификации, сопоставимо по качеству с ручной разработкой модели, однако занимает намного больше времени. Использование переноса обучения оказывает небольшой, но положительный эффект на качество классификации. **Практическая значимость:** предложенный последовательный подход позволяет существенно повысить качество разрабатываемых моделей в задачах обработки естественного языка.

Ключевые слова — обработка естественного языка, машинное обучение, глубокое обучение, векторизация, моделирование, предварительная обработка, автоматическое машинное обучение, перенос обучения.

Для цитирования: Polyakov E. V., Voskov L. S., Abramov P. S., Polyakov S. V. Generalized approach to sentiment analysis of short text messages in natural language processing. *Информационно-управляющие системы*, 2020, № 1, с. 2–14. doi:10.31799/1684-8853-2020-1-2-14

For citation: Polyakov E. V., Voskov L. S., Abramov P. S., Polyakov S. V. Generalized approach to sentiment analysis of short text messages in natural language processing. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 2–14. doi:10.31799/1684-8853-2020-1-2-14

UDC 004.93: 004.89: 004.048: 007.51

doi:10.31799/1684-8853-2020-1-15-23

Time-frequency transforms in analysis of non-stationary quasi-periodic biomedical signal patterns for acoustic anomaly detection

A. O. Iskhakova^{a,b}, PhD, Tech., Senior Researcher, orcid.org/0000-0001-8358-298X, iskhakova.ao@gmail.com

M. D. Alekhin^c, PhD, Tech., Head of Department of Biomedical Engineering, orcid.org/0000-0003-2091-2755

A. V. Bogomolov^d, Dr. Sc., Tech., Professor, Leading Researcher, orcid.org/0000-0002-7582-1802

^aV. A. Trapeznikov Institute of Control Sciences of RAS, 65, Profsoyuznaya St., 117997, Moscow, Russian Federation

^bTomsk State University of Control Systems and Radioelectronics, 40, Lenina Pr., 634050, Tomsk, Russian Federation

^cJSC «RPA «Electronic Device Engineering», 2, 2nd Boyevskaya St., 107104, Moscow, Russian Federation

^dBurnazyan Federal Medical and Biophysical Center of Federal Medical Biological Agency, 23, Marshala Novikova St., 123098, Moscow, Russian Federation

Introduction: New approaches to efficient compression and digital processing of audio signals are relevant today. There is a lot of interest to new pattern recognition methods which can improve the quality of acoustic anomaly detection. **Purpose:** Comparative analysis of methods for time-frequency transformation of audio signal patterns, including non-stationary quasi-periodic biomedical signals in the problem of acoustic anomaly detection. **Results:** The study compared different time-frequency transforms (such as windowed Fourier, Gabor, Wigner, pseudo Wigner, Choi – Williams, Bertrand, pseudo Bertrand, smoothed pseudo Bertrand, and wavelet transforms) based on systematization of their functional characteristics (such as the existence and limitedness of basis functions, presence of zero moments and biorthogonal form, opportunity of two-dimensional representation and inverse transformation, real time processing, time-frequency transform quality, control of time-frequency definition, time and frequency interference suppression, relative computational complexity, fast algorithm implementation) for the problem of biomedical signal pattern recognition. A comparative table is presented with estimates of information capacity for the considered time-frequency transforms. **Practical relevance:** The proposed approach can solve some acoustic anomaly detection algorithm implementation problems common in non-stationary quasi-periodic processes, in order to study disruptive effects causing a change in the functional state of ergatic system operators.

Keywords – system analysis, non-stationary quasi-periodic processes, pattern recognition, biomedical signal processing, ergatic systems, functional states, disruptive effect, time-frequency transforms, acoustic anomaly detection, frequency deviation, noise.

For citation: Iskhakova A. O., Alekhin M. D., Bogomolov A. V. Time-frequency transforms in analysis of non-stationary quasi-periodic biomedical signal patterns for acoustic anomaly detection. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 15–23. doi:10.31799/1684-8853-2020-1-15-23

Introduction

“The Colosseum”, a massive radiofrequency channel emulator run by Defense Advanced Research Projects Agency (DARPA) Spectrum Collaboration Challenge (SC2), is transitioning to the Platform for Advanced Wireless Research (PAWR) after a final spectrum competition, matchup at Mobile World Congress Los Angeles on October 23, 2019 [1]. It means that advanced research will grow rapidly on solutions [2], enabling radio networks to autonomously collaborate and dynamically determine spectrum use from moment to moment, using modern time-frequency transformation instruments on feature extraction phase.

Initially, the progress in the field of quantum statistics formed the foundation for time-frequency (TF) analysis of non-stationary quasi-periodic biomedical (NQB) signals [3]. The first classical pub-

lications of Gabor and Ville were due to the trends in quantum mechanics, the mathematical apparatus of which has similar features to the TF analysis of NQB signals. In 1946, Gabor developed an original method, closely related to coherent states in quantum mechanics [4]. In the same publication, an important concept of the analytic signal was introduced. Two years later, Ville [5] modified the distribution, first used by Wigner to study quantum statistics.

In the early 1980s researchers paid close attention to the study of orthogonal systems of bases of general form, which led to the emergence of a generalized theory of spectral analysis. In 1982 Morlet in his publication [6] addressing the study of seismic signals introduced the concept of the basis function of wavelet transform (WT). This study is reflected in many works on this subject and is used for research of seismically unstable objects and territo-


ries. In particular, works devoted to assessing the characteristics of volcanoes and creating models and calculations for timely response to changes in their values [7, 8].

An important contribution to the WT theory was made by Daubechies, who in 1988 developed a class of bases for orthogonal wavelets [9] of the same name. The created family of orthogonal wavelets with the compact carrier calculated in the iterative way further was investigated and applied to a solution of different applied tasks. It is now represent an effective mathematical apparatus in NQB signal pattern analysis and recognition [10–12], as well as for geophysical [13, 14], neurophysiological [15], acoustics [16–18], safety and security [19–21], reconnaissance [22, 23], and bio-radiolocation [24, 25] problems solving and are popular in other interdisciplinary fields of science and technology [26–28].

It should be noted, that each TF transform has its own strengths and weaknesses, and particular transform type should be selected each time, based on the conditions of the applied tasks of NQB signal processing [29]. The analysis of TF transforms should be performed systematically, allowing to take into consideration advantages and disadvantages of their properties, to improve the quality of NQB signal processing [30].

Thus, the present work is aimed at performing comparative analysis of TF transforms based on systematization of their main characteristics in the problems of processing of NQB signals patterns, using the example of test low-frequency biomedical signal realization (Fig. 1).

The novelty of the study is in providing an informative instrument in a form of a comparative table clearly systemizing functional characteristics of considered TF transformations for justified selection a set of them for sensible identification of non-stationary anomalies, applying digital signal processing techniques on the next stages. The validity of the proposed approach can be further strengthened using expert methods and broadening the classes of analyzed signal classes in the search of concrete particularities in both time and



■ Fig. 1. Analyzed test NQB signal

frequency domains. Thus, unification of signal representation and formalization of classification and clusterization tasks lead to founding a novel method for automated pattern recognition for non-stationary quasi-periodic processes on the base of simultaneous application of convolutional neural networks and a set of TF transformations, selected by the maximum of entropy heterogeneity [31].

The applicability of time-frequency transformations in practical tasks of sound analysis in a virtual environment

Time-frequency transformations allow to extract various characteristics of audio signals. Therefore, it can be used to solve the plenty of practical tasks related to monitoring and tracking of audio materials, analysis and decision making [32–34].

In particular, such an implementation with data mining elements is typical for the design of socio-cyberphysical systems (SCPS) — systems that are characterized by decision making directly by its own elements. As described in [35], the decision scheme in the SCPS is based on the analysis of the data by the cybernetic component based on the context and the corresponding plurality of valid decisions. The cyberphysical system receives data that is delivered by different kinds of sensors, actuators, tags, tokens and other types of electronic devices. The cybernetic component processes this data and forms the context. The context provides information that allows to take a look at the current state of the system environment. It is the basis for generating the plenty of possible solutions. The decision making process is supported by communication and interaction between system components. Information from cybernetic to cybernetic, from cybernetic to human, from human to cybernetic, from cybernetic and human to central repository, and from central repository to cybernetic and human is shared throughout the decision-making scheme [36].

One of the most advanced and complex SCPS is the cyber environment formed by the Internet. The main features of this SCPS are [37]:

- the large amount of data distributed in the system;
- heterogeneity of data: different data types, for example, texts, graphic files, audio signals, and the mixed varieties, for example, for example, video streams which integrate a visual stream and an audio stream;
- high speed of data distribution in the system;
- a large number of users (people) in the system;
- the distributed cybernetic component for decision making;

— various forms of a context, which is the basis for generation of possible decisions at identification of a problem;

— delayed and not always obvious reaction of the system operators to events and decisions in the system.

Time-frequency transformations allow to extract and calculate different characteristics of audio signals and their values, in this particular case audio files — elements of a virtual environment. That is why this methods can be used to solve practical problems related to monitoring and tracking of audio materials, their analysis and decision-making.

An example of such a problem situation is the identification of various anomalies, such as frequency deviations, noise effects and other “emissions”. Their presence may indicate abnormal sound of the material, including the presence of destructive effect on the listener (operator) and be the reason for change of its condition [38].

In this problem situation it is possible to select three main premises for emergence of an indisposition and unpleasant feelings at the user of virtual environment who periodically or is regularly affected: existence of elastic fluctuations that are unheard a human ear — with a frequency below 16 Hz (infrasound) or is higher than 20,000 Hz (ultrasound), and also existence of vibrations. These sound anomalies (for a human ear) can be shown in acoustic record as it is constant throughout, and in separate timepoints or with some period.

Thus, the application of TF transformation methods may allow to identify and recognize different characteristics and features of audio signals and can be used for monitoring of audio streams in the SCPS operating in virtual environment.

Comparative analysis of time-frequency transforms


Linear time-frequency transforms

Windowed Fourier transform

In windowed Fourier transform (WFT), spectral density function $S_{\text{WFourier}}(\omega, \tau)$ for signal $s(t)$ is defined [39] by the formula

$$S_{\text{WFourier}}(\omega, \tau) = \int_{-\infty}^{+\infty} (s(t)w(t-\tau)\exp(-i\omega t))dt. \quad (1)$$

The idea of traditional Fourier transform, with the disadvantage in the lack of information about the position of the frequency components on the time axis, was improved into the WFT (Fig. 2). It has a constant time resolution and enables identifying the features of long-period components of NQB



■ Fig. 2. Result of WFT application (Hamming window) for the test NQB signal realization


signals. However, a significant shortcoming of the WFT is the lack of localization of the basis functions. The influence of local features on the form of the function of WFT spectral density is limited in time only by the width of the window. At the same time, the advantage of the WFT include a wide range of various window functions [40].

Gabor transform


In Gabor transform (GT), spectral density function $S_{\text{Gabor}}(\omega, \tau)$ for signal $s(t)$ is defined [39] by the formula

$$S_{\text{Gabor}}(\omega, \tau) = \frac{1}{(\pi\sigma^2)^{\frac{1}{4}}} \int_{-\infty}^{+\infty} \left(s(t) \exp\left(-\frac{(t-\tau)^2}{2\sigma^2}\right) \exp(-i\omega t) \right) dt. \quad (2)$$


Gabor transform is a kind of WFT with a Gaussian window (Fig. 3). The main advantage of GT is that it has a good TF localization. There is also reverse GT. At the same time, the lack of self-similarity of the basis should be treated as a shortcoming of GT. Thus, each time for different scales of the period, a different number of periods of the harmonic function falls into the GT window. The analyzed signal is actually decomposed into



■ Fig. 3. Result of GT application for the test NQB signal realization



■ Fig. 4. Result of WT application (Morlet basis) for the test NQB signal realization



■ Fig. 5. Result of WGT application for the test NQB signal realization

different basis functions, rather than into the same one, as for example, in the case of WT [40].

Wavelet transform

In Wavelet transform (WT), spectral density function $S_{\text{Wavelet}}(\omega, \tau)$ for signal $s(t)$ is defined [39] by the formula

$$S_{\text{Wavelet}}(\omega, \tau) = \left| k \frac{2\pi}{\omega} \right|^{\frac{1}{2}} \int_{-\infty}^{+\infty} \left(s(t) \psi^* \left(\frac{\omega(t-b)}{2\pi k} \right) \right) dt. \quad (3)$$

The main concept of WT is based on analysis of a signal with different resolutions, also called a multiple-scale wavelet analysis (MSWA), generating orthogonal and biorthogonal forms (Fig. 4). In bi-orthogonal WT, the signal is decomposed applying the method of cross-use of mutually orthogonal basis functions. The main advantages of WT are the good localization of basis functions with respect to time and frequency, and, as a consequence, high TF resolution, which enables a detailed investigation of the local features of NQB signals. A wide choice of basis functions of WT and the possibility of their customized construction enables the selection of the optimal parameters of WT for each particular problem. However, the shortcomings of WT are dependence of the wavelet spectrum of the analyzed signal on the type of the selected mother wavelet and subjectivity of its choice [40].

Bi-linear time-frequency transforms

Wigner transform

In Wigner transform (WGT), spectral density function $S_{\text{Wigner}}(\omega, \tau)$ for signal $s(t)$ is defined [39] by the formula

$$S_{\text{Wigner}}(\omega, \tau) = \int_{-\infty}^{+\infty} \left(s \left(\tau + \frac{t}{2} \right) s^* \left(\tau - \frac{t}{2} \right) \exp(-i\omega t) \right) dt. \quad (4)$$

The main advantage of WGT is its good TF resolution (Fig. 5). There is also reverse WGT. Its short-

coming is the presence of interference terms of the spectral density function for multicomponent NQB signals.


However, there are methods that make it possible to substantially mitigate the effects of the influence of these interference terms using averaging procedures. For example, the introduction of an additional time window function in calculating WGT leads to pseudo Wigner transform (PWGT). But excessive narrowing of the window causes the TF representation to blur on the TF plane in most of the cases. The additional weight function helps to mitigate the frequency interference terms, which finds smoothed pseudo Wigner transform (SPWGT) [40].

Choi – Williams transform

In Choi – Williams transform (CWT), spectral density function $S_{\text{Choi-W}}(\omega, \tau)$ for signal $s(t)$ is defined [39] by the formula

$$S_{\text{Choi-W}}(\omega, \tau) = \left(\sqrt{\frac{\sigma}{4\pi}} \int_{-\infty}^{+\infty} \left(\frac{1}{|t|} \exp(-i\omega t) \right) \times \right. \\ \left. \times \int_{-\infty}^{+\infty} \left(\exp \left(-\frac{(u-\tau)^2 \sigma}{4t^2} \right) s \left(\tau + \frac{t}{2} \right) s^* \left(\tau - \frac{t}{2} \right) \right) du dt. \quad (5)$$

Implementation of this bilinear TF transform enables reducing the intensity of the interference



■ Fig. 6. Result of CWT application for the test NQB signal realization


terms (Fig. 6). The main advantage of CWT is the ability to control the level of interference. Thus, in some applications, it is possible to select the optimum values of the parameters, at which the undesirable effects turn out to be quite well suppressed, and TF resolution remains acceptable within the framework of the solving problem. It is worth to note that the cases of successful CWT application includes a number of medical studies, which resulted in achieving a significant reduction in interference in the tasks of TF representation of biomedical signals [40].

Bertrand transform

In Bertrand transform (BT), spectral density function $S_{\text{Bertrand}}(\omega, \tau)$ for the signal $s(t)$ is defined [39] by the formula

$$S_{\text{Bertrand}}(\omega, \tau) = \int_{-\infty}^{+\infty} \frac{1}{|t|} \int_{\tau - \frac{|t|}{2}}^{\tau + \frac{|t|}{2}} \left(s\left(u + \frac{t}{2}\right) s^*\left(u - \frac{t}{2}\right) \exp(-i\omega t) \right) dudt. \quad (6)$$

In addition to the typical shortcoming associated with the existing interference of most bilinear TF transforms, the essential weakness of BT is the impossibility of its implementation in real time (Fig. 7). The pseudo Bertrand transform (PBT) is better in some aspects: asymptotically having the same properties as BT, it enables reducing the influence of interference terms along the frequency axis and allows real-time implementation. For simultaneous interference reduction along the time and frequency axes, the smoothed pseudo Bertrand



■ Fig. 7. Result of BT application for the test NQB signal realization

transform (SPBT) was developed, which has an additional smoothing frequency window function [40].

Results of the comparison and systematization

The results of systematization of the main characteristics of discussed TF transforms in analysis of NQB signals patterns are provided in Table.

Table shows the transformation designations as follows:

- WFT — window Fourier transform;
- GT — Gabor transform;
- WT — Wavelet transform;
- WGT — Wigner transform;
- PWGT — pseudo Wigner transform;
- SPWGT — smoothed pseudo Wigner transform;
- CWT — Choi — Williams transform;
- BT — Bertrand transform;
- PBT — pseudo Bertrand transform;
- SPBT — smoothed pseudo Bertrand transform;

■ Systematization of characteristics of TF transforms

Characteristic	WFT	GT	WT	WGT	PWGT	SPWGT	CWT	BT	PBT	SPBT
I	±	±	+	±	±	±	±	-	-	-
II	+	+	+	-	-	-	-	-	-	-
III	-	-	+	+	+	+	+	-	-	-
IV	-	+	+	-	-	-	-	-	-	-
V	+	+	+	+	+	+	+	-	-	-
VI	+	+	+	+	+	+	+	-	-	-
VII	+	+	+	+	+	+	+	-	+	+
VIII	++	++	+++	++	+	+	++	++	+	+
IX	+	+	++	-	-	-	++	-	-	-
X	++	-	++	-	+	+	+	-	+	+
XI	++	-	++	-	-	+	+	-	-	+
XII	++	++	++	+	±	-	±	+	±	-
XIII	-	-	+	-	-	-	-	-	-	-

and the characteristics of the transforms are as follows:

- I — presence of basis functions;
- II — finiteness of basis functions;
- III — presence of zero times;
- IV — presence of a biorthogonal form;
- V — presence of a two-dimensional form;
- VI — possibility of reverse transform;
- VII — possibility of real time processing;
- VIII — time-frequency localization;
- IX — resolution control;
- X — time interference suppression;
- XI — frequency interference suppression;
- XII — computational complexity;
- XIII — presence of a fast computational algorithm.

Thus, comparative analysis of the TF transforms in processing of NQB signals reveals that linear TF transforms, such as WFT and GT, do not have sufficiently good time and frequency localization properties at the same time. Generally, good frequency resolution is accompanied by worse time localization, and an increase of the time resolution reduces the frequency resolution.

In turn, bilinear TF transforms have satisfactory characteristics of localization on the TF plane, but their essential drawback is the existence of interference terms. In the modified bilinear WT and BT, the interference is eliminated with smoothing time and frequency windows, but this simultaneously results in a worse time and frequency resolution, accordingly. The latter circumstance explain the overall advantages and prospects of using these TF transforms in practical applications of NQB signal precise structure analysis. The relatively high complexity and lack of fast computational algorithms for the bilinear TF transforms significantly hinder their application in the tasks of real-time NQB signals processing.

Conclusion

The comparative values of application of the main time-frequency transforms methods for processing of a test non-stationary quasi-periodic biomedical signal showed that basic time-frequency methods can be used in different tasks of identifying audio signals features. Based on the given results it can be concluded, that WT has one of the best properties in the terms of TF localization which makes it especially efficient for informative features extraction for attribute space forming in the tasks of automated recognition of NQB signals patterns. Availability of variety of existing mother wavelets and the possibility of construction of customized basis functions give the opportunity to select the optimal basis of WT on the strength of properties and character peculiarities of analyzed NQB signals. The choice of the method also depends on the practical task being solved. For example, the problem of detecting sound anomalies in audio materials, that are spread in the virtual environment, can be better solved using such methods as WFT, WT, WGT, as they are more accurate in determining low frequency inclusions and (if present) vibrations.

Financial support

The present work was performed in the framework of “BioSpectrum” perspective program (JSC “RPA “Electronic Device Engineering”) supported by grant of the President of the Russian Federation for leading scientific schools NSh-2553.2020.8 and RFBR projects no. 18-29-22104, no. 18-08-00244, no. 20-013-00306.

References

1. SC2 Spectrum Collaboration Challenge — Using AI to Unlock the True Potential of the RF Spectrum. Available at: <https://www.spectrumcollaborationchallenge.com/> (accessed 13 December 2019).
2. Klabukov I. D., Yakovets A. V., Alekhin M. D. Management of systems engineering and technical assistance of DARPA research programs. *Innovatsii*, 2017, no. 5(223), pp. 12–19 (In Russian).
3. Malfante M., Mars J., Mura M. D., Gervaise C. Automatic fish sounds classification. *The Journal of the Acoustical Society of America*, 2018, vol. 143, pp. 2834–2846, doi:10.1121/1.5036628
4. Gabor D. Theory of communication. Part 1: The analysis of information. *IEE Proceedings*, 1946, vol. 93, iss. 26, pp. 429–457, doi:10.1049/ji-3-2.1946.0074
5. Ville J. Theorie et applications de la notion de signal analytique. *Cables et Transmission*, 1948, vol. 2, no. 1, pp. 61–74 (In French).
6. Morlet J., Arens G., Fourgeau I., Giard D. Wave propagation and sampling theory. *Geophysics*, 1982, vol. 47(2), pp. 203–236. doi:10.1190/1.1441329
7. Malfante M., Mura M. D., Metaxian J.-P., Mars J., Macedo O., Inza L. A. Machine learning for volcano-seismic signals: Challenges and perspectives. *IEEE Signal Processing Magazine*, 2018, vol. 35, pp. 20–30. doi:10.1109/MSP.2017.2779166
8. Hammer C., Beyreuther M., Ohrnberger M. A Seismic-event spotting system for volcano fast-response systems. *The Bulletin of the Seismological Society of America*, 2102, vol. 102, pp. 948–960. doi:10.1785/0120110167
9. Daubechies I. Orthonormal bases of compactly supported wavelets. *Communications on Pure and Ap-*

- plied Mathematics*, 1988, vol. 41, pp. 909–996. doi:10.1002/cpa.3160410705
10. Pankratov A. N., Pyatkov M. I., Tetuev R. K., Nazipova N. N., Dedus F. F. Search for extended repeats in genomes based on the spectral-analytical method. *Mathematical Biology and Bioinformatics*, 2012, vol. 7, pp. 476–492.
 11. Alekhin M., Anishchenko L., Tataraidze A., Ivashov S., Korostovtseva L., Sviryaev Y., Bogomolov A. Selection of wavelet transform and neural network parameters for classification of breathing patterns of bio-radiolocation signals. *Communications in Computer and Information Science*, 2014, vol. 404, pp. 175–178. doi:10.1007/978-3-642-54121-6_15
 12. Gorshkov Y. G. Visualization of multi level wavelet analysis of phonograms. *Scientific Visualization*, 2015, vol. 7, no. 2, pp. 96–111. Available at: <http://sv-journal.org/2015-2/08.php?lang=en> (accessed 13 December 2019) (In Russian).
 13. Mandrikova O. V., Solovjev I. S., Geppener V. V., Klionsky D. M. New wavelet based approach intended for the analysis of subtle features of complex natural signals. *Pattern Recognition and Image Analysis*, 2011, vol. 21, iss. 2, pp. 300–303. doi:10.1134/S1054661811020726
 14. Rao Y. S., Naresh K., Kumar M. K., Mahaboob S. Detection and minimization of harmonics using daubechies wavelet. *International Journal of Applied Engineering Research*, 2015, vol. 10, pp. 11889–11908.
 15. Khorev V. S., Maksimenko V. A., Pitcik E. N., Runnova A. E., Kurkin S. A., Hramov A. E. Analysis of motor activity using electromyogram signals. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2019, no. 3, pp. 114–120 (In Russian). doi:10.31799/1684-8853-2019-3-114-120
 16. Krashennnikov V. R., Armer A. I., Khvostov A. V. Preparation of templates in speech command recognition by single and double channel scheme in background noise. *Pattern Recognition and Image Analysis*, 2008, vol. 18, iss. 4, pp. 580–583. doi:10.1134/S1054661808040068
 17. Dragan S. P., Bogomolov A. V., Kotlyar-Shapiro A. D., Kondrat'eva E. A. A method for investigation of the acoustic reflex on the basis of impedance measurements. *Biomedical Engineering*, 2017, vol. 51, iss. 1, pp. 72–76. doi:10.1007/s10527-017-9687-6
 18. Bogomolov A. V., Sviridyuk G. A., Keller A. V., Zinkin V. N., Alekhin M. D. Information-logical modeling of information collection and processing at the evaluation of the functional reliability of the aviation ergate control system operator. *Proceedings of 2018 International Conference on Human Factors in Complex Technical Systems and Environments (ERGO)*, 2018, pp. 106–110. doi:10.1109/ERGO.2018.8443849
 19. Lu T.-C., Chang C.-C., Liu Y.-L. A content-based image authentication scheme based on singular value decomposition. *Pattern Recognition and Image Analysis*, 2006, vol. 16, iss. 3, pp. 506–522. doi:10.1134/S1054661806030187
 20. Shumskaya O. O., Zelezny M. Adaptive algorithm of replacement-based embedding of data into compressed JPEG images. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2018, no. 5, pp. 44–56 (In Russian). doi:10.31799/1684-8853-2018-5-44-56
 21. Iskhakov A. Y. Adaptive authentication technologies in behavioral analysis solutions of robotic systems. *Proceedings of the VIth International Workshop "Critical Infrastructures: Contingency Management, Intelligent, Agent-based, Cloud Computing and Cyber Security" (IWCI-2019)*, 2019. doi:10.2991/iwci-19.2019.10. Available at: <https://www.atlantis-press.com/proceedings/iwci-19/125917301> (accessed 13 December 2019).
 22. Yang Y., Sun H., Cao Y. Unsupervised urban area extraction from SAR imagery using GMRF. *Pattern Recognition and Image Analysis*, 2006, vol. 16, iss. 1, pp. 116–119. doi:10.1134/S1054661806010378
 23. Iskhakov A. Yu., Iskhakova A. O., Meshcheryakov R. V., Bendraou R., Melekhova O. Application of user behavior thermal maps for identification of information security incident. *SPIIRAS Proceedings*, 2018, iss. 6(61), pp. 147–171 (In Russian). doi:10.15622/sp.61.6
 24. Dafna E., Tarasiuk A., Zigel Y. Sleep staging using nocturnal sound analysis. *Scientific Reports*, 2018, vol. 8, article number 13474. doi:10.1038/s41598-018-31748-0
 25. Bai X., Jun D., Wang Z.-R., Lee C.-H. A hybrid approach to acoustic scene classification based on universal acoustic models. *Interspeech 2019*, 2019, pp. 3619–3623. doi:10.21437/Interspeech.2019-2171
 26. Taylor J. *Advanced Ultrawideband Radar: Signals, Targets, and Applications (Force Drawing Series)*. Boca Raton, CRC Press, 2016. 494 p.
 27. Iskhakova A. O. Processing of big data streams in intelligent electronic data analysis systems. *Proceedings of the VIth International workshop "Critical infrastructures: Contingency management, Intelligent, Agent-based, Cloud computing and Cyber security" (IWCI-2019)*, 2019. doi:10.2991/iwci-19.2019.4. Available at: <https://www.atlantis-press.com/proceedings/iwci-19/125917301> (accessed 13 December 2019).
 28. Golovnin O. K., Stolbova A. A. Wavelet analysis as a tool for studying the road traffic characteristics in the context of intelligent transport systems with incomplete data. *SPIIRAS Proceedings*, 2019, vol. 18, no. 2, pp. 326–353 (In Russian). doi:10.15622/sp.18.2.326-353
 29. Boashash B. *Time-frequency signal analysis and processing: A Comprehensive reference*. 2nd ed. Cambridge, Academic Press, 2015. 1056 p.
 30. Cohen L. *Time-frequency analysis*. New Jersey, Prentice Hall, 1995. 299 p.

31. Alekhin M. D., et al. *Ustrojstvo dlya avtomaticheskogo raspoznavaniya patternov radiosignalov* [A device for automated recognition of patterns of radiotechnical signals]. Patent RU, no. 175179. Published on 18.12.2017. Patent holder JSC "RPA "Electronic Device Engineering".
32. Zhdanko I. M., Zinkin V. N., Soldatov S. K., Bogomolov A. V., Sheshegov P. M. Fundamental and applied aspects of preventing the adverse effects of aviation noise. *Human Physiology*, vol. 42, pp. 705–714. doi:10.1134/S0362119716070227
33. Iskhakova A. O., Meshcheryakov R. V. Automatic search of the malicious messages in the Internet of things systems on the example of an intelligent detection of the unnatural agents requests. *Proceedings of the 2nd Russia and Pacific Conference on Computer Technology and Applications (RPC)*, 2017, pp. 85–89. doi:10.1109/RPC.2017.8168074
34. Gorodetskiy A. E., Kurbanov V. G., Tarasova I. L. Decision-making in central nervous system of a robot. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2018, no. 1, pp. 21–30 (In Russian). doi:10.15217/issn1684-8853.2018.1.21
35. Smirnov A. V., Levashova T. V. Models of decision support in socio-cyber-physical systems. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2019, no. 3, pp. 55–70 (In Russian). doi:10.31799/1684-8853-2019-3-55-70
36. Smirnov A. V., Levashova T. V. Knowledge acquisition in socio-cyber-physical systems through information exchange between resources. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2017, no. 6, pp. 113–122 (In Russian). doi:10.15217/issn1684-8853.2017.6.113
37. Tatarnikova T. M. Statistical methods for studying network traffic. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2018, no. 5, pp. 35–43 (In Russian). doi:10.31799/1684-8853-2018-5-35-43
38. Dragan S. P., Bogomolov A. V., Kondrat'eva E. A. Mathematical model of polyharmonic signal processing to study the state of the tympanic membrane. *2016 International Conference on Engineering and Telecommunication (EnT)*, 2016, pp. 21–25. doi:10.1109/EnT.2016.013
39. Auger F., Flandrin P., Goncalves P., Lemoine O. *Time-frequency toolbox. For use with MATLAB: Reference guide*. Houston, Rice University Press, 2005. Available at: <http://tftb.nongnu.org/refguide.pdf> (accessed 13 December 2019).
40. Chernogor L. F., Lazorenko O. V. System spectral analysis of the ultra-wideband signals. *2012 6th International Conference on Ultrawideband and Ultra-short Impulse Signals*, 2012, pp. 243–245. doi:10.1109/UWBUSIS.2012.6379794

УДК 004.93: 004.89: 004.048: 007.51
doi:10.31799/1684-8853-2020-1-15-23

Время-частотные преобразования в анализе паттернов нестационарных квазипериодических биомедицинских сигналов для задач идентификации акустических аномалий

А. О. Исхакова^{а, б}, канд. техн. наук, старший научный сотрудник, orcid.org/0000-0001-8358-298X, iskhakova.ao@gmail.com

М. Д. Алёхин^б, канд. техн. наук, начальник отдела, orcid.org/0000-0003-2091-2755

А. В. Богомолов^в, доктор техн. наук, профессор, ведущий научный сотрудник, orcid.org/0000-0002-7582-1802

^аИнститут проблем управления им. В. А. Трапезникова РАН, Профсоюзная ул., 65, Москва, 117997, РФ

^бТомский государственный университет систем управления и радиоэлектроники, Ленина пр., 40, Томск, 634050, РФ

^вАО «НПО «Электронное приборостроение», 2-я Боевская ул., 2, Москва, 107014, РФ

^гФедеральный медицинский биофизический центр им. А. И. Бурназяна, Маршала Новикова ул., 23, Москва, 123098, РФ

Введение: создание новых подходов для решения прикладных задач эффективного сжатия аудиосигналов и их цифровой обработки является актуальной научной задачей, что подтверждается повышением интереса к новым методам распознавания паттернов для улучшения качества идентификации акустических аномалий. **Цель:** проведение сравнительного анализа время-частотных преобразований паттернов аудиосигналов, включая рассмотрение тестовой реализации нестационарного квазипериодического биомедицинского сигнала в задаче идентификации акустических аномалий. **Результаты:** проведен сравнительный анализ время-частотных преобразований (оконного Фурье; Габора; Вигнера; псевдо Вигнера; сглаженного псевдо Вигнера; Чои — Вильямса; Бертрана; псевдо Бертрана; сглаженного псевдо Бертрана; вейвлет-преобразования) на основе систематизации их ведущих функциональных характеристик (существование базисных функций и их ограниченность; наличие нулевых моментов и биортогонального вида; возможность представления в двумерной форме и осуществления обратного преобразования; обработка в режиме реального времени; качество время-частотной локализации; управление время-частотным разрешением; подавление интерференции по времени и по частоте; относительная вычислительная сложность; реализация быстрого алгоритма вычислений) для задачи распознавания паттернов биомедицинских сигналов. Представлена сравнительная таблица оценок информативности рассмотренных время-частотных преобразований для анализа паттернов нестационарных квазипериодических биомедицинских сигналов. **Практическая значимость:** повышение эффективности интеллектуального анализа паттернов при разработке специальных алгоритмов цифровой обработки аудиосигналов для автоматизированной идентификации акустических аномалий, собственных нестационарным квазипериодическим процессам при исследовании эффектов акустических воздействий на операторов эргатических систем, приводящих к изменению функциональных состояний.

Ключевые слова — системный анализ, нестационарные квазипериодические процессы, распознавание образов, обработка биомедицинских сигналов, эргатические системы, функциональные состояния, эффекты воздействий, время-частотные преобразования, идентификация акустических аномалий, девиация частоты, шум.

Для цитирования: Iskhakova A. O., Alekhin M. D., Bogomolov A. V. Time-frequency transforms in analysis of non-stationary quasi-periodic biomedical signal patterns for acoustic anomaly detection. *Информационно-управляющие системы*, 2020, № 1, с. 15–23. doi:10.31799/1684-8853-2020-1-15-23

For citation: Iskhakova A. O., Alekhin M. D., Bogomolov A. V. Time-frequency transforms in analysis of non-stationary quasi-periodic biomedical signal patterns for acoustic anomaly detection. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 15–23. doi:10.31799/1684-8853-2020-1-15-23

УВАЖАЕМЫЕ АВТОРЫ!

Научные базы данных, включая SCOPUS и Web of Science, обрабатывают данные автоматически. С одной стороны, это ускоряет процесс обработки данных, с другой — различия в транслитерации ФИО, неточные данные о месте работы, области научного знания и т. д. приводят к тому, что в базах оказывается несколько авторских страниц для одного и того же человека. В результате для всех по отдельности считаются индексы цитирования, снижая рейтинг ученого.

Для идентификации авторов в сетях Thomson Reuters проводит регистрацию с присвоением уникального индекса (ID) для каждого из авторов научных публикаций.

Процедура получения ID бесплатна и очень проста, есть возможность провести регистрацию на 12-ти языках, включая русский (чтобы выбрать язык, кликните на зеленое поле вверху справа на стартовой странице): <https://orcid.org>

УДК 004.056

doi:10.31799/1684-8853-2020-1-24-33

Использование нейросетей для прогнозирования подверженности пользователей социальных сетей деструктивным воздействиям

А. А. Браницкий^а, канд. техн. наук, orcid.org/0000-0003-3104-0622

Е. В. Дойникова^а, канд. техн. наук, orcid.org/0000-0001-6707-9153

И. В. Котенко^а, доктор техн. наук, профессор, orcid.org/0000-0001-6859-7120, ivkote@comsec.spb.ru

^аСанкт-Петербургский институт информатики и автоматизации РАН, 14-я линия В. О., 39, Санкт-Петербург, 199178, РФ

Постановка проблемы: в рамках социальных сетей пользователи имеют возможность удаленно общаться, самовыражаться, искать людей со схожими интересами. В то же время социальные сети как источник информации могут оказывать негативное влияние на поведение и мышление их пользователей. **Цель исследования:** разработка методики прогнозирования подверженности пользователей социальных сетей деструктивным воздействиям на основе использования искусственных нейронных сетей. **Результаты:** разработана методика и выполнена экспериментальная оценка прогнозирования результатов теста Аммона по профилю пользователя в социальной сети при помощи искусственных нейронных сетей. За основу методики взяты результаты теста Аммона для студентов медицинского вуза. Для обучения нейронной сети сформирован набор признаков на базе информации, предоставляемой пользователями в социальных сетях. По результатам экспериментов подтверждено наличие зависимости между информацией, предоставляемой пользователями в социальных сетях, и психологическими характеристиками личности. Разработан механизм, предназначенный для своевременного выявления деструктивных воздействий и профилей пользователей в социальных сетях, указывающих на подверженность таким воздействиям, упрощающий работу специалистов-психологов. Результаты экспериментов показали, что наибольшей точностью среди исследованных четырех типов нейронных сетей обладает многослойная нейронная сеть. В дальнейшем планируется расширить набор признаков для повышения точности нейронной сети. **Практическая значимость:** полученные результаты могут быть использованы для построения систем, предназначенных для выявления в интернет-пространстве воздействий, неблагоприятных для психического здоровья молодого поколения и нации в целом.

Ключевые слова – нейронная сеть, тест Аммона, профиль пользователя, социальная сеть, психологические шкалы, деструктивное воздействие, признаки.

Для цитирования: Браницкий А. А., Дойникова Е. В., Котенко И. В. Использование нейросетей для прогнозирования подверженности пользователей социальных сетей деструктивным воздействиям. *Информационно-управляющие системы*, 2020, № 1, с. 24–33. doi:10.31799/1684-8853-2020-1-24-33

For citation: Branitskiy A. A., Doynikova E. V., Kotenko I. V. Use of neural networks for forecasting of the exposure of social network users to destructive impacts. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 24–33 (In Russian). doi:10.31799/1684-8853-2020-1-24-33

Введение

В настоящее время социальные сети являются одним из наиболее распространенных интернет-ресурсов среди представителей молодого поколения. Возможность общения, нахождения людей с похожими интересами, а также удаленного обмена информацией способствует росту популярности таких сетевых сервисов. Информация, размещаемая в профилях пользователей социальной сети, может включать переписку с друзьями, сведения о личных интересах, а также фотографии. Эти данные могут использоваться в качестве источника для построения психологического портрета пользователя. В частности, то, что пользователь считает нужным сообщить о себе в социальной сети, может многое о нем сказать [1].

Стоит отметить, что в социальных сетях может присутствовать вредоносная информация:

пропаганда насильственных действий, популяризация нездорового образа жизни и вредных привычек, призывы к нарушению религиозных и морально-идеологических устоев в обществе и т. д. Подобная информация оказывает негативное влияние, уровень которого для разных пользователей может существенно различаться. Тем самым рассматриваемая задача, а именно построение систем, определяющих степень подверженности пользователей социальных сетей деструктивным воздействиям, является актуальной. Своевременное выявление таких воздействий в интернет-пространстве за счет мониторинга информации в социальных сетях, а также целевых профилей, подверженных подобным влияниям, позволит ослабить или даже предотвратить их негативную роль. В настоящее время для определения подверженности индивидуумов негативным воздействиям используются специа-

лизированные тесты, которые необходимо проводить регулярно, и дорогостоящее оборудование, что затрудняет этот процесс.

Для решения поставленной задачи может использоваться аппарат искусственных нейронных сетей (НС), которые широко распространены в целях классификации объектов и успешно рекомендовали себя как инструмент поиска аномалий.

Релевантные работы

Анализ работ в рассматриваемой области позволил выделить следующие схожие группы задач: 1) классификация клинических данных; 2) выявление психологических нарушений; 3) определение эмоционального настроения; 4) выделение социальных групп; 5) защита от вредоносной информации в сети Интернет.

Для многоклассовой категоризации клинических диагнозов на основе различных медицинских показаний авторы работы [2] применяют рекуррентную НС в целях обработки многомерных временных рядов медицинских наблюдений. Результаты экспериментов подтвердили высокую эффективность применения модели, содержащей 128 ячеек долгой краткосрочной памяти.

Мониторинг психологического состояния пользователей сети Интернет привлекает внимание многих ИТ-специалистов. В частности, исследовалось [3] применение сверточных НС для выявления психологических нарушений. Для обучения и тестирования нейросетевой модели в качестве исходных выступали данные, полученные из сервисов социальных микроблогов. Выделены два типа атрибутов, которые формируют анализируемый вектор признаков и обрабатываются НС: 1) низкоуровневые атрибуты, извлеченные из единичного сообщения (твита), включая текст или изображение; 2) статистические атрибуты, касающиеся активности аккаунта (количество твитов, количество комментариев к сообщениям) в течение заданного периода времени. Результаты экспериментов показали целесообразность использования четырехслойной НС, в которой в качестве функции активации применялся особый вид логистической функции.

Большой объем полезной информации, пригодной для составления психологического профиля человека, может быть получен из учетной записи, размещенной на его персональной странице в социальной сети. В частности, авторы статьи [4] рассматривают вопрос построения системы распознавания психологического профиля и особенностей характера человека по его фотографиям из социальной сети Facebook. Авторы отмечают, что для общительных и открытых людей

характерны фотографии, в которых присутствует множество человеческих лиц и преобладают светлые тона, в то время как для людей с депрессивным мышлением чаще встречаются картинки с замкнутыми пространствами.

Исследования, представленные в работах [5, 6], посвящены анализу настроений интернет-пользователей. На основе данных, извлекаемых из коротких сообщений, авторы предлагают строить глубокую НС, способную предсказывать бинарное настроение (положительное или отрицательное) адресанта. Обрабатываемый вектор признаков строится в многоуровневом стиле: для анализа используется информация, извлеченная как из отдельных символьных последовательностей, так и из более высокоуровневых синтаксических конструкций, а именно предложений [5].

В работе [7] определяется уровень эмоционального воздействия, производимого на человека в результате просмотра цифровых изображений. В качестве признаков, характеризующих изображения, подлежащие обработке, использовались параметры яркости цветовых схем, относительное преобладание темных цветов, параметры текстур и композиции. Для автоматической классификации изображений по уровню эмоционального воздействия применялся наивный байесовский классификатор.

Основой методики обнаружения групп в социальных сетях, представленной в работе [8], является генетический алгоритм, оптимизируемая фитнес-функция которого направлена на поиск плотно сгруппированных узлов внутри графа связей, причем разные образовавшиеся таким образом кластеры должны разреженно соединяться друг с другом или вовсе не иметь общих связей. Одним из прикладных назначений данной методики можно назвать выделение общих интересов у исследуемой группы людей и построение усредненного психологического профиля участника обнаруженной группы.

Предложено [9] рассматривать генетический алгоритм как эвристический инструмент для решения NP-полной задачи — кластеризации фрагмента социальной сети. В работе [10] для определения количества кластеров внутри социальной сети предлагается применять байесовский подход.

В работе [11] решается задача прогнозирования повторной публикации сообщений в социальной сети Twitter. Для вычисления показателей точности и полноты использованы линейная машина опорных векторов и логистическая регрессия.

Вопросы защиты пользователей от вредоносной и нежелательной информации рассматривались в статьях [12–15]. Одним из целевых назначений разработанной авторами методики в рамках рассматриваемой предметной области является

сокращение (или вовсе предотвращение) случаев обращения доступа представителей молодого поколения к информации, носящей нелегитимный характер. Данный фактор имеет также важное значение при построении систем родительского контроля, что позволит уберечь несовершеннолетних детей от информации, способной отрицательно воздействовать на психологическое состояние ребенка. Архитектура разработанной на базе этой методики программной системы организована в иерархическом стиле. На первом уровне размещаются бинарные классификаторы, определяющие принадлежность анализируемого контента к определенной категории. Второй уровень включает классификаторы, ориентированные на использование отдельных структурных элементов html-контента и предназначенные для определения темы. На третьем уровне располагается агрегирующий классификатор.

Рассмотренные работы подтверждают актуальность затронутой проблемы и необходимость совершенствования существующих методов. В отличие от представленных работ данное исследование направлено на разработку комплексной методики, предназначенной для выявления подверженности пользователей социальных сетей деструктивным воздействиям и сочетающей в себе технологии искусственных НС при анализе разнородных данных (скалярных величин, текста, изображений).

Методика прогнозирования подверженности пользователей социальных сетей деструктивным воздействиям

При разработке методики прогнозирования подверженности пользователей социальных сетей деструктивным воздействиям были выбраны многослойные НС. Такой выбор обусловлен способностью искусственных НС к аппроксимации разделяющих гиперплоскостей между сложными линейно неразделимыми множествами [16–18]. Предлагаемая методика включает три шага: 1) сбор данных из профилей пользователей социальной сети; 2) формирование вектора признаков; 3) прогнозирование результатов теста Аммона по собранному данным из профиля пользователя социальной сети при помощи обученных НС.

Сбор данных из социальных профилей

Полученные в результате проведенного онлайн-тестирования Аммона среди студентов-медиков записи были помечены 18 шкалами, представляющими собой комбинации шести Я-функций (агрессии, тревоги, внешнего Я-отграничения и пр.) и трех компонентов (конструктивного, де-

структивного, дефицитарного). Для каждой из таких пар вычислялось значение Т-балла (Т), интерпретируемое как низкое для $0 \leq T \leq 39$, среднее для $40 \leq T \leq 60$ или высокое для $61 \leq T \leq 110$. Исследуемый набор данных содержал 460 записей, описывающих уникальные профили пользователей социальной сети.

Формирование вектора признаков

В роли признаков, описывающих профили пользователей в социальной сети, использовались три группы исходных данных: 1) численные параметры (скаляры), включающие месяц рождения, количество подписчиков, друзей и фотографий и пр.; 2) последовательность слов (например, параметры, направленные на формирование набора наиболее употребительных слов в рамках каждой психологической шкалы); 3) параметры, вычисляемые на уровне бинарных потоков данных (например, результат классификации изображения при помощи НС imagenet [19]). В табл. 1 приведены сведения о вычисляемых параметрах.

Примеры наиболее популярных слов, встречающихся в постах, и наиболее частых категорий фотографий, распознанных НС imagenet, приведены в табл. 2.

Прогнозирование результатов теста Аммона

При проведении экспериментов учитывался только компонент деструктивности. В роли нейросетевых классификаторов рассматривались многослойная нейронная сеть (МНС) с тремя скрытыми слоями нейронов, машина опорных векторов (МОВ) с радиально-базисным ядром, линейная регрессия (ЛР), а также сверточная нейронная сеть (СНС). При обучении первых трех классификаторов использовалось подмножество признаков, представленных в табл. 1. Для обучения последнего классификатора использовались посты, размещенные на стенах профилей в социальной сети. Функционирование этого классификатора (рис. 1) включает следующие шаги.

1. Преобразование текста на распределительном слое. Текст разбивается на отдельные предложения. Каждому слову приписывается уникальный численный идентификатор: чем больше частота встречаемости слова, тем меньше это значение. Полученные значения размещаются внутри прямоугольной решетки таким образом, чтобы ячейка под номером (i, j) соответствовала j -му слову i -го предложения. Выравнивание обеспечивается путем приписывания нулей справа до получения строки максимальной длины.

2. Применение свертки. Каждая подматрица, составленная из элементов построенной на шаге 1 решетки, поэлементно умножается на ядро свертки. Полученные произведения суммируются.

■ **Таблица 1.** Параметры, формирующие вектор признаков

■ **Table 1.** Parameters forming the feature vector

№	Параметр	Тип исходных данных
1	Количество подписчиков	Скаляр
2	Количество друзей	То же
3	Количество групп	— " —
4	Количество фотографий	— " —
5	Количество подписок	— " —
6	Количество видео	— " —
7	Пол (м/ж)	— " —
8	Количество постов	— " —
9	Количество репостов	— " —
10	Месяц рождения	— " —
11–55	Результат применения word2vec [20] между пятью наиболее употребительными словами, характерными для постов каждого класса, и тремя наиболее употребительными словами в постах анализируемого профиля	Последовательность слов
56–100	Результат применения word2vec между пятью наиболее частыми категориями фотографий в рамках каждого класса и тремя наиболее частыми категориями фотографий в анализируемом профиле	Байтовая последовательность (изображение)
101	Результат применения сверточной НС над последовательностью слов в постах	Последовательность слов

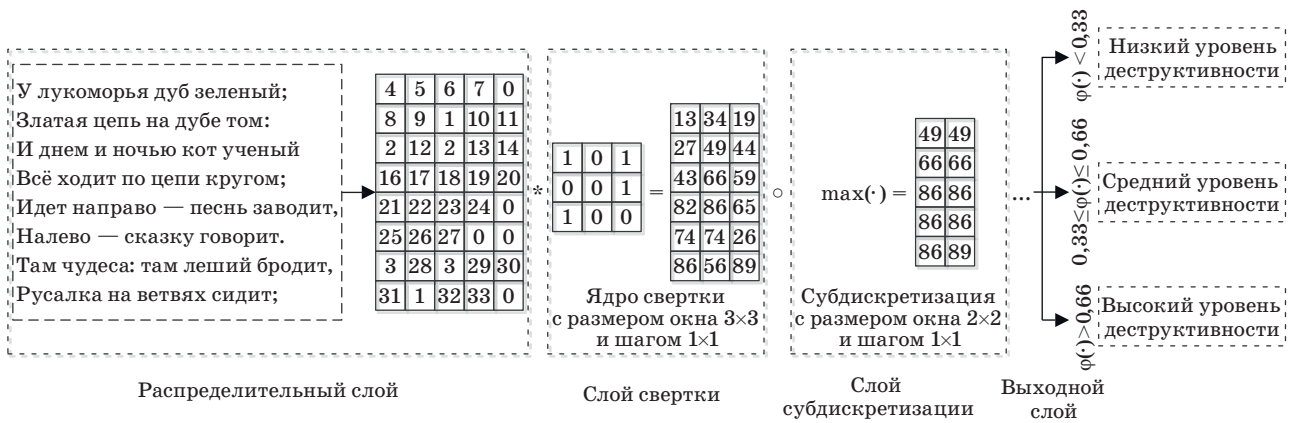
■ **Таблица 2.** Примеры наиболее популярных слов и категорий фотографий, характерных для различных уровней деструктивного нарциссизма

■ **Table 2.** Examples of the most popular words and categories of photos characteristic for various levels of destructive narcissism

Слово	Частота	Слово	Частота	Слово	Частота
Уровень деструктивного нарциссизма					
низкий		средний		высокий	
В постах					
Очень	59	Club	106	Подарки	58
Спасибо	56	Vkfeed	106	Очень	46
Всегда	34	Iphone	106	The	42
Мат*	34	Очень	71	Можно	41
Даже	32	Спасибо	64	Просто	39
На фотографиях					
Dust	174	Suit	453	Site	6222
Site	159	Tie	433	Web	1975
Wig	136	Site	417	Website	1960
Shirt	128	Miniskirt	413	Internet	1874
Boo	112	Pajama	409	Book	1151

3. Применение субдискретизации. Из матрицы, полученной на шаге 2, извлекаются наиболее весомые элементы внутри окна заданного размера. С этой целью применяется операция максимума.

4. Интерпретация выходных результатов. Сигналы, полученные после шага 3, оформляются в виде вектора, который скалярно умножается на веса выходного слоя; результат — величина y . Низкий уровень деструктивности соответствует



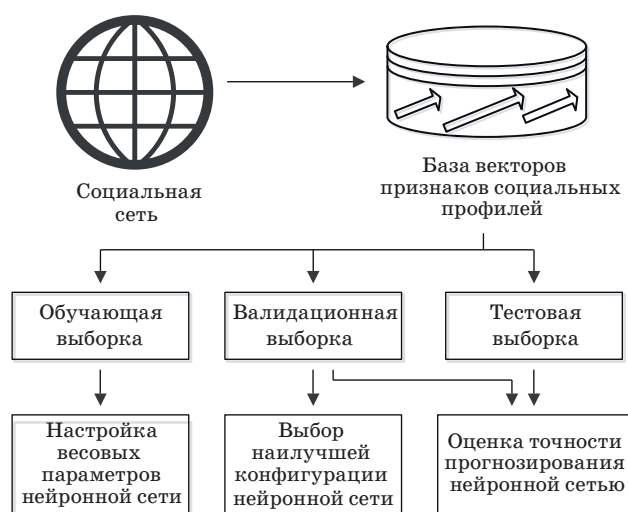
■ **Рис. 1.** Функционирование СНС, обученной на постах профилей в социальной сети (применение нормализации на распределительном слое и функции активации на слое свертки опущено)
 ■ **Fig. 1.** The functioning of the convolutional neural network trained at the posts of profiles in a social network (the use of normalization on the distribution layer and activation functions on the convolution layer is omitted)

случаю $\varphi(y) < 0,33$, средний уровень — случаю $0,33 \leq \varphi(y) \leq 0,66$, высокий уровень — случаю $\varphi(y) > 0,66$, где φ — сигмоидная функция активации.

Эксперименты по оценке методики

Эксперименты проводились по схеме, представленной на рис. 2.

В экспериментах использовалась 10-блочная перекрестная проверка. Исходный набор признаков данных разбивался на 10 частей таким образом, чтобы в каждой из этих частей содержались примерно равноразмерные подвыборки, состоящие из элементов одного и того же класса. Девять частей использовалось для обучения.



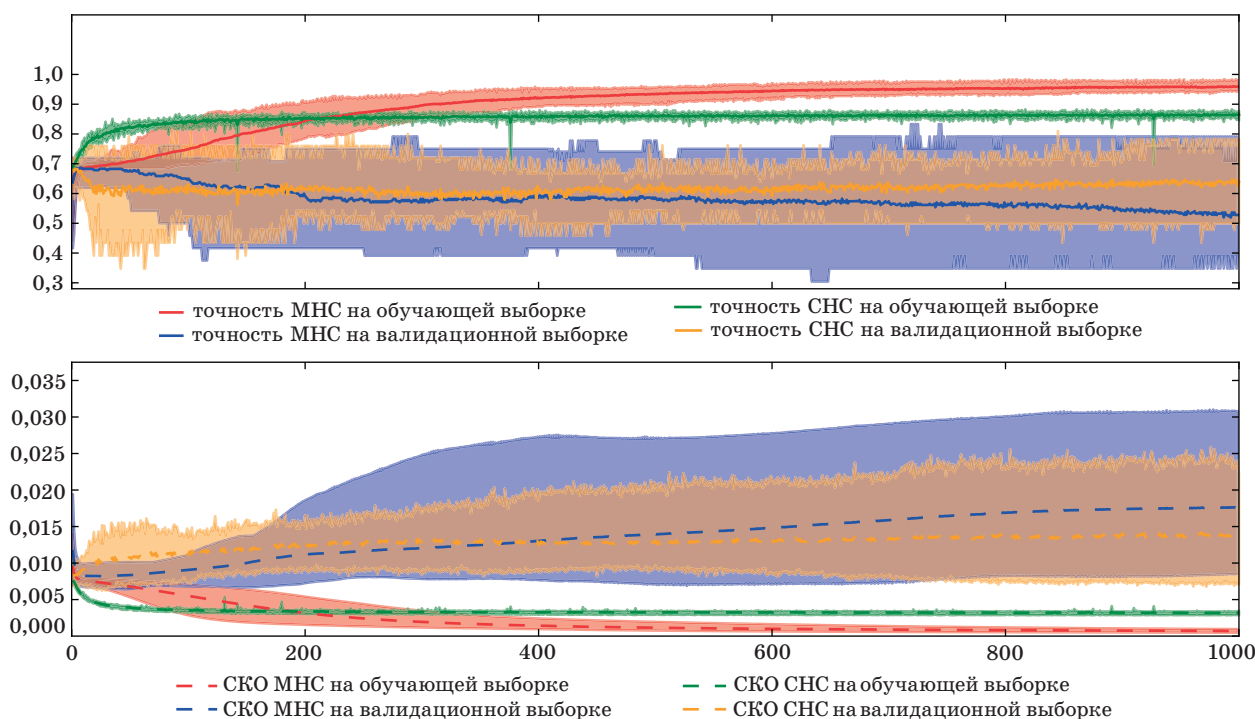
■ **Рис. 2.** Схема эксперимента
 ■ **Fig. 2.** The scheme of the experiment

Оставшаяся часть использовалась в качестве тестовой, половина элементов которой формировала валидационное множество.

Итеративная настройка весовых коэффициентов НС осуществлялась при помощи элементов обучающей выборки. Валидационная выборка использовалась для вычисления среднеквадратичной ошибки (СКО) после каждой эпохи обучения и последующего выбора конфигурации НС с наименьшей СКО. Тестовая выборка использовалась для вычисления точности результатов прогнозирования. На рис. 3 представлена зависимость точности и СКО МНС и СНС от номера эпохи обучения на обучающей и валидационной выборках для психологической шкалы деструктивной агрессии.


Многослойная НС характеризуется более быстрой сходимостью алгоритма обучения по сравнению с СНС. В то же время с увеличением числа эпох обучения для первой наблюдается заметное снижение точности прогнозирования уровня психологической шкалы на валидационной выборке, что обуславливается детальным представлением признаков и появлением эффекта переобучения. На рис. 4 отражено влияние размерности вектора признаков, обрабатываемого при помощи МНС, на точность и СКО прогнозирования элементов обучающей и валидационной выборок. Увеличение числа признаков позволяет существенно снизить СКО, вычисленную на обучающей выборке, но по мере увеличения числа эпох обучения, как и в случае рис. 3, также наблюдается уменьшение обобщающей способности МНС на валидационной выборке.

Корреляция признаков с меткой прогнозируемых уровней деструктивного нарциссизма приведена на рис. 5. Наибольшее абсолютное значение корреляции доставляет последний признак,



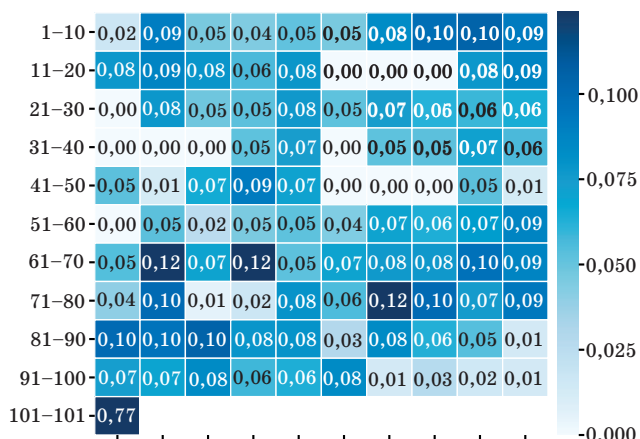
■ **Рис. 3.** Зависимость точности и SKO МНС и СНС от номера эпохи обучения для психологической шкалы деструктивной агрессии

■ **Fig. 3.** The dependence of accuracy and mean-square error of the multilayer neural network and the convolutional neural network on the number of the epoch of training for the psychological scale destructive aggression




■ **Рис. 4.** Зависимость точности и SKO МНС от номера эпохи обучения для психологической шкалы деструктивной агрессии

■ **Fig. 4.** The dependence of accuracy and mean-square error of the multilayer neural network on the number of the epoch of training for the psychological scale destructive aggression



■ **Рис. 5.** Корреляция признаков с меткой прогнозируемых уровней деструктивного нарциссизма
 ■ **Fig. 5.** Correlation of features with a label of predicted levels of destructive narcissism



● низкий уровень ■ средний уровень ▼ высокий уровень
 ■ **Рис. 6.** Первые две главные компоненты признаков для психологической шкалы деструктивного нарциссизма
 ■ **Fig. 6.** The first two main components of features for the psychological scale of destructive narcissism

■ **Таблица 3.** Значения точности прогнозирования результатов теста Аммона для четырех типов классификаторов на тестовой выборке
 ■ **Table 3.** The accuracy of predicting the results of the Ammon’s test for four types of classifiers in the test sample

Классификатор	Деструктивный компонент Я-функции, %						Среднее значение
	первой	второй	третьей	четвертой	пятой	шестой	
МНС (1-10)	68,74	57,87	48,96	66,23	50,43	67,39	59,94
МНС (1-55)	69,62	62,18	49,89	66,47	48,51	67,62	60,71
МНС (1-100)	70,10	59,36	52,32	66,65	51,39	67,80	61,27
МНС (1-101)	70,15	59,76	52,82	66,12	51,59	67,60	61,34
МОВ (1-10)	68,49	55,4	48,35	65,07	48,57	67,79	58,95
ЛР (1-10)	30,89	41,84	39,21	30,41	41,12	47,74	38,54
СНС	64,48	46,94	44,51	58,99	43,85	59,06	52,97

представляющий собой выходное значение СНС, предварительно обученной на постах.

Первые две главные компоненты признаков представлены на рис. 6. Области, содержащие объекты из разных уровней, перекрывают друг друга, поэтому сужение размерности анализируемых векторов признаков для обучения НС может приводить к увеличению ошибок прогнозирования результатов теста Аммона.

Представленные в табл. 3 значения точности, вычисленные на тестовой выборке для четырех классификаторов: МНС, МОВ, ЛР, СНС, — усреднялись по 10 блокам перекрестной проверки. Для обучения МОВ и ЛР использовались только 10 скалярных параметров, представленных в табл. 1. Для МНС дополнительно выполнялось обучение также с привлечением параметров второй и третьей групп исходных данных.

Наибольшее значение точности, полученное посредством усреднения по шести психологическим шкалам деструктивности, принадлежит МНС, которая обучалась с применением 101-мерного вектора признаков. Наименьшее значение точности было получено с использованием ЛР, что подтверждает необходимость введения слоя нелинейности для корректного обособления объектов из разных классов.

Заключение

В статье рассмотрено приложение НС к задаче прогнозирования результатов теста Аммона по профилю пользователей социальной сети. Было выполнено экспериментальное сравнение четырех различных типов НС, среди которых наилуч-

шими показателями точности обладает четырех-слойный перцептрон.

Полученные результаты экспериментов по шкалам деструктивности теста Аммона для тестовой группы молодежи указывают на то, что зависимость между информацией, предоставляемой пользователями в социальных сетях, и психологическими характеристиками личности существует. В то же время необходимо учитывать, что эксперимент проводился только для ограниченной группы молодых людей и для ограниченного набора характеристик личности. Для более точных результатов, и тем более формирования выводов о конкретной личности, необходим более тщательный анализ личности экспертами, а также анализ условий, в которых данная личность существует.

К достоинствам предлагаемой методики можно отнести то, что она позволяет автоматически обрабатывать большие объемы данных в социальных сетях и сосредоточиться эксперту на ограниченной группе тех личностей, которые

могут быть подвержены деструктивным воздействиям.

К недостаткам относится тот факт, что психологические характеристики личности являются очень индивидуальными, и разработка единого автоматического механизма их анализа является сложной задачей, требующей комплексного учета большого количества факторов, далеко не все из которых находят отражение в социальной сети. Поэтому в дальнейшей работе предполагается сосредоточиться на выделении новых признаков подверженности деструктивности, определяемых на основе информации, предоставляемой в социальных сетях, а также на расширении методики на другие шкалы теста Аммона.

Финансовая поддержка

Работа выполнена при частичной финансовой поддержке проекта РФФИ 18-29-22034 мк и бюджетной темы 0073-2019-0002.

Литература

1. Казнова Н. Н., Овчинникова И. Г. Специфика коммуникации в социальных сетях по сравнению с блогосферой. *Вопросы психолингвистики*, 2014, № 21, с. 86–97.
2. Lipton Z. C., et al. *Learning to diagnose with LSTM recurrent neural networks*. arXiv preprint arXiv: 1511.03677, 2015 (дата обращения: 02.12.2019).
3. Lin H., et al. User-level psychological stress detection from social media using deep neural network. *Proceedings of the 22nd ACM International Conference on Multimedia*, ACM, 2014, pp. 507–516.
4. Segalin C., et al. What your Facebook profile picture reveals about your personality. *Proceedings of the 2017 ACM on Multimedia Conference*, ACM, 2017, pp. 460–468.
5. dos Santos C., Gatti M. Deep convolutional neural networks for sentiment analysis of short texts. *Proceedings of COLING 2014, the 25th International Conference on Computational Linguistics: Technical Papers*, 2014, pp. 69–78.
6. Socher R., et al. Semi-supervised recursive autoencoders for predicting sentiment distributions. *Proceedings of the Conference on Empirical Methods in Natural Language Processing*, Association for Computational Linguistics, 2011, pp. 151–161.
7. Machajdik J., Hanbury A. Affective image classification using features inspired by psychology and art theory. *Proceedings of the 18th ACM International Conference on Multimedia*, ACM, 2010, pp. 83–92.
8. Pizzuti C. Ga-net: A genetic algorithm for community detection in social networks. *International Conference on Parallel Problem Solving from Nature*, Springer, Berlin, Heidelberg, 2008, pp. 1081–1090.
9. Firat A., Chatterjee S., Yilmaz M. Genetic clustering of social networks using random walks. *Computational Statistics & Data Analysis*, 2007, vol. 51, no. 12, pp. 6285–6294.
10. Handcock M. S., Raftery A. E., Tantrum J. M. Model-based clustering for social networks. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, 2007, vol. 170, no. 2, pp. 301–354.
11. Yang Z., et al. Understanding retweeting behaviors in social networks. *Proceedings of the 19th ACM International Conference on Information and Knowledge Management*, ACM, 2010, pp. 1633–1636.
12. Kotenko I., Chechulin A., Komashinsky D. Categorisation of web pages for protection against inappropriate content in the internet. *International Journal of Internet Protocol Technology (IJIPT)*, 2017, vol. 10, no. 1, pp. 61–71.
13. Котенко И. В., Чечулин А. А., Комашинский Д. В. Автоматизированное категорирование веб-сайтов для блокировки веб-страниц с неприемлемым содержанием. *Проблемы информационной безопасности. Компьютерные системы*, 2015, № 2, с. 62–68.
14. Котенко И. В., Саенко И. Б., Чечулин А. А. *Защита от нежелательной и вредоносной информации в глобальных информационных сетях. Информационно-психологическая и когнитивная безопасность: коллективная монография/ под ред. И. Ф. Кефели, Р. М. Юсупова*. СПб., Аврора, 2017. 345 с.
15. Новожилов Д. А., Чечулин А. А., Котенко И. В. Улучшение категорирования веб-сайтов для бло-

кировки неприемлемого содержимого на основе анализа статистики HTML-тэгов. *Информационно-управляющие системы*, 2016, № 6, с. 65–73. doi:10.15217/issn1684-8853.2016.6.65

16. Cybenko G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems (MCSS)*, 1989, vol. 2, no. 4, pp. 303–314.
17. Funahashi K. I. On the approximate realization of continuous mappings by neural networks. *Neural Networks*, 1989, vol. 2, no. 3, pp. 183–192.

18. Hornik K., Stinchcombe M., White H. Multilayer feedforward networks are universal approximators. *Neural Networks*, 1989, vol. 2, no. 5, pp. 359–366.
19. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 2012, pp. 1097–1105.
20. Mikolov T., et al. *Efficient estimation of word representations in vector space*. arXiv preprint arXiv:1301.3781, 2013 (дата обращения: 02.12.2019).

UDC 004.056

doi:10.31799/1684-8853-2020-1-24-33

Use of neural networks for forecasting of the exposure of social network users to destructive impacts

A. A. Branitskiy^a, PhD, Tech., orcid.org/0000-0003-3104-0622, branitskiy@comsec.spb.ru

E. V. Doynikova^a, PhD, Tech., orcid.org/0000-0001-6707-9153, doynikova@comsec.spb.ru

I. V. Kotenko^a, Dr. Sc., Tech., Professor, orcid.org/0000-0001-6859-7120, ivkote@comsec.spb.ru

^aSaint-Petersburg Institute for Informatics and Automation of the RAS, 39, 14 Line, V. O., 199178, Saint-Petersburg, Russian Federation

Introduction: In social networks, the users can remotely communicate, express themselves, and search for people with similar interests. At the same time, social networks as a source of information can have a negative impact on the behavior and thinking of their users. **Purpose:** Developing a technique of forecasting the exposure of social network users to destructive influences, based on the use of artificial neural networks. **Results:** A technique has been developed and experimentally evaluated for forecasting Ammon's test results by a social network user's profile using artificial neural networks. The technique is based on the results of Ammon's test for medical students. For training the neural network, a set of features was generated based on the information provided by social network users. The results of the experiments have confirmed the dependence between the data provided by social network users and their psychological characteristics. A mechanism has been developed aimed at prompt detection of destructive impacts or social network users' profiles indicating the susceptibility to such impacts, in order to facilitate the work of psychologists. The experiments have shown that out of the four investigated types of neural networks, the highest accuracy is provided by a multilayer neural network. In the future, it is planned to expand the set of features in order to achieve a better accuracy. **Practical relevance:** The obtained results can be used to develop systems for monitoring the Internet environment, detecting the impacts potentially dangerous for mental health of the young generation and the nation as a whole.

Keywords — neural network, Ammon's test, user profile, social network, psychological scales, destructive impact, features.

For citation: Branitskiy A. A., Doynikova E. V., Kotenko I. V. Use of neural networks for forecasting of the exposure of social network users to destructive impacts. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 24–33 (In Russian). doi:10.31799/1684-8853-2020-1-24-33

References

1. Kaznova N. N., Ovchinnikova I. G. Specific features of computer mediated communication: social networks vs. weblogs. *Journal of Psycholinguistics*, 2014, no. 21, pp. 86–97 (In Russian).
2. Lipton Z. C., et al. *Learning to diagnose with LSTM recurrent neural networks*. Available at: arXiv preprint arXiv:1511.03677, 2015 (accessed 2 December 2019).
3. Lin H., et al. User-level psychological stress detection from social media using deep neural network. *Proceedings of the 22nd ACM International Conference on Multimedia*, ACM, 2014, pp. 507–516.
4. Segalin C., et al. What your Facebook profile picture reveals about your personality. *Proceedings of the 2017 ACM on Multimedia Conference*, ACM, 2017, pp. 460–468.
5. dos Santos C., Gatti M. Deep convolutional neural networks for sentiment analysis of short texts. *Proceedings of COLING 2014, the 25th International Conference on Computational Linguistics: Technical Papers*, 2014, pp. 69–78.
6. Socher R., et al. Semi-supervised recursive autoencoders for predicting sentiment distributions. *Proceedings of the Conference on Empirical Methods in Natural Language Processing*, Association for Computational Linguistics, 2011, pp. 151–161.
7. Machajdik J., Hanbury A. Affective image classification using features inspired by psychology and art theory. *Proceedings of the 18th ACM International Conference on Multimedia*, ACM, 2010, pp. 83–92.
8. Pizzuti C. Ga-net: A genetic algorithm for community detection in social networks. *International Conference on Parallel Problem Solving from Nature*, Springer, Berlin, Heidelberg, 2008, pp. 1081–1090.
9. Firat A., Chatterjee S., Yilmaz M. Genetic clustering of social networks using random walks. *Computational Statistics & Data Analysis*, 2007, vol. 51, no. 12, pp. 6285–6294.
10. Handcock M. S., Raftery A. E., Tantrum J. M. Model-based clustering for social networks. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, 2007, vol. 170, no. 2, pp. 301–354.
11. Yang Z., et al. Understanding retweeting behaviors in social networks. *Proceedings of the 19th ACM International Conference on Information and Knowledge Management*, ACM, 2010, pp. 1633–1636.
12. Kotenko I., Chechulin A., Komashinsky D. Categorisation of web pages for protection against inappropriate content in the internet. *International Journal of Internet Protocol Technology (IJIPT)*, 2017, vol. 10, no. 1, pp. 61–71.

13. Kotenko I., Chechulin A., Komashinsky D. Automated categorization of web-sites for inappropriate content blocking. *Information Security Problems. Computer Systems*, 2015, no. 2, pp. 62–68 (In Russian).
14. Kotenko I., Saenko I., Chechulin A. *Zashchita ot nezhelatel'noj i vredonosnoj informacii v global'nyh informacionnyh setyah. Informacionno-psihologicheskaya i kognitivnaya bezopasnost'* [Protection from unwanted and harmful information in global information networks. Information-psychological and cognitive security]. Ed. I. F. Kefeli, R. M. Yusupova. Saint-Petersburg, Avrora Publ., 2017. 345 p. (In Russian).
15. Novozhilov D. A., Chechulin A. A., Kotenko I. V. Improving website categorization based on HTML tag statistics for blocking unwanted content. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2016, no. 6, pp. 65–73 (In Russian). doi:10.15217/issn1684-8853.2016. 6.65
16. Cybenko G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems (MCSS)*, 1989, vol. 2, no. 4, pp. 303–314.
17. Funahashi K. I. On the approximate realization of continuous mappings by neural networks. *Neural Networks*, 1989, vol. 2, no. 3, pp. 183–192.
18. Hornik K., Stinchcombe M., White H. Multilayer feedforward networks are universal approximators. *Neural Networks*, 1989, vol. 2, no. 5, pp. 359–366.
19. Krizhevsky A., Sutskever I., Hinton G. E. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 2012, pp. 1097–1105.
20. Mikolov T., et al. *Efficient estimation of word representations in vector space*. Available at: arXiv preprint arXiv:1301.3781, 2013 (accessed 2 December 2019).

УВАЖАЕМЫЕ АВТОРЫ!

Научная электронная библиотека (НЭБ) продолжает работу по реализации проекта SCIENCE INDEX. После того как Вы зарегистрируетесь на сайте НЭБ (<http://elibrary.ru/defaultx.asp>), будет создана Ваша личная страничка, содержание которой составят не только Ваши персональные данные, но и перечень всех Ваших печатных трудов, имеющих в базе данных НЭБ, включая диссертации, патенты и тезисы к конференциям, а также сравнительные индексы цитирования: РИНЦ (Российский индекс научного цитирования), h (индекс Хирша) от Web of Science и h от Scopus. После создания базового варианта Вашей персональной страницы Вы получите код доступа, который позволит Вам редактировать информацию, помогая создавать максимально объективную картину Вашей научной активности и цитирования Ваших трудов.

УДК 519.713.1

doi:10.31799/1684-8853-2020-1-34-43

Генерация автоматов на основе рекуррентных нейросетей и автоматического выбора кластеризации

П. Г. Грачев^а, аспирант, orcid.org/0000-0002-1133-8432С. Б. Муравьев^а, канд. техн. наук, программист, orcid.org/0000-0002-4251-1744А. А. Фильченков^а, канд. физ.-мат. наук, доцент, orcid.org/0000-0002-1133-8432А. А. Шалыто^а, доктор техн. наук, профессор, orcid.org/0000-0002-2723-2077, shalyto@mail.ifmo.ru^аСанкт-Петербургский национальный исследовательский университет информационных технологий, механики и оптики, Кронверкский пр., 49, Санкт-Петербург, 197101, РФ

Введение: задача индуцирования регулярной грамматики состоит в построении детерминированных конечных автоматов по списку слов-примеров и слов-контрпримеров из неизвестного регулярного языка. Эта задача является одной из центральных в теории формальных языков и сопряженных с ней областях. Одним из наиболее успешных ее решений является обучение рекуррентной нейронной сети классификации слов и последующая кластеризация векторов в пространстве весов. Однако результат кластеризации не всегда позволяет построить непротиворечивый автомат. Более сложные модели для индуцирования грамматики требовательны к памяти, времени обучения и числу тренировочных примеров. **Цель:** построение модели для индуцирования грамматики, использующей новые методы машинного обучения. **Методы:** в качестве классификатора применена рекуррентная нейронная сеть, использующая предложенную авторами функцию ошибки. Для кластеризации реализован метод совместного выбора и настройки гиперпараметров алгоритма кластеризации для различных мер оценки. **Результаты:** проведено тестирование на наборах данных, соответствующих десяти различным регулярным грамматикам и, соответственно, десяти различным детерминированным автоматам. По результатам тестирования разработанная модель корректно синтезирует автоматы с числом состояний и с числом входных символов не более пяти. Для четырех из семи успешно индуцированных грамматик построенный автомат получился минимальным. Для трех наборов данных Test-автомат построить не удалось – либо из-за недостаточности числа кластеров в предложенном разбиении, либо из-за невозможности построить из этого разбиения непротиворечивый автомат. **Обсуждение:** применение алгоритма поиска наибольшего правдоподобия между кластерами векторов и соответствующими состояниями автомата для принятия решений в случае нахождения противоречий могло бы расширить область применимости модели.

Ключевые слова – индуцирование грамматики, рекуррентные нейронные сети, кластеризация.

Для цитирования: Грачев П. Г., Муравьев С. Б., Фильченков А. А., Шалыто А. А. Генерация автоматов на основе рекуррентных нейросетей и автоматического выбора кластеризации. *Информационно-управляющие системы*, 2020, № 1, с. 34–43. doi:10.31799/1684-8853-2020-1-34-43

For citation: Grachev P. G., Muravyov S. B., Filchenkov A. A., Shalyto A. A. Automata generation based on recurrent neural networks and automated cauterization selection. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 34–43 (In Russian). doi:10.31799/1684-8853-2020-1-34-43

Введение

Формальный язык является одним из основных понятий математической логики и информатики. Он представляет собой множество конечных строк, состоящих из символов, которые принадлежат некоторому конечному алфавиту. Такой язык может быть определен не только перечислением всех его слов, но и списком некоторых формально описанных правил их порождения. Формальные языки широко используются в самых разнообразных областях, включая среды программирования [1], формальную логику и языки [2, 3] и представление естественных языков [4].

Согласно иерархии Хомского, формальные языки можно разбить на четыре вложенных класса: неограниченные, контекстно-зависимые, контекстно-свободные и регулярные [5]. Регулярные языки могут быть представлены с помощью де-

терминированных конечных автоматов (ДКА). Автомат — это абстрактная математическая модель, состоящая из состояний и переходов между ними. Детерминированные автоматы используются не только для представления регулярных языков, но и как самостоятельная математическая модель, например в различных управляющих системах, таких как светофоры, торговые автоматы, лифты, а также для сетевых протоколов [6]. Автоматы применяются в биологии [7], логистике [8], компьютерной безопасности [9] и т. д.

Построение ДКА, соответствующего некоторому формальному языку, по списку формальных правил или по текстовому описанию этого языка является одной из наиболее частых задач в теории формальных языков [10], а методы ее решения известны из литературы [11, 12]. Такая задача, как правило, возникает при использовании моделей и идей из теории формальных языков, например в системах, проверяющих коррект-

ность написания строк [13]. Однако когда правила неизвестны, требуется построить детерминированный автомат по подмножеству слов, принадлежащих некоторому неизвестному формальному языку. Такое описание не является полным и однозначным, поскольку регулярный язык может содержать бесконечно много слов. Проблема получения некоторого формального описания языка по конечному числу слов-примеров, а в некоторых случаях слов-контрпримеров, в англоязычной литературе называется *grammar inference* [14]. За этим понятием нет закрепившегося термина на русском языке. В рамках данной работы будет использоваться термин *индуцированные грамматики*.


Базовым и исторически первым алгоритмом для индуцирования грамматики стал алгоритм смещения состояний [15]. Его идея состоит в построении префиксного дерева, эквивалентного примерам из тестовой выборки с последующим объединением состояний. Появление и развитие технологий машинного обучения позволило разработать новые модели для индуцирования грамматики. Одним из наиболее удачных решений является применение рекуррентной нейронной сети, классифицирующей слова по их принадлежности к неизвестному формальному языку [16–19]. Обученная нейронная сеть выделяет векторы (состояния весов), которые впоследствии подвергаются кластеризации. Кластеры состояний приводятся в соответствие с состояниями конструируемого автомата с помощью алгоритма, описанного далее. В результате строится детерминированный автомат, соответствующий неизвестному формальному языку.

В данной работе предлагается новый метод решения задачи индуцирования грамматики, использующий модификацию классифицирующей рекуррентной нейронной сети. В этой сети кластеризация весов выполняется с применением метода совместного выбора и настройки гиперпараметров алгоритма кластеризации на основе обучения с подкреплением.

Основные понятия

Детерминированный конечный автомат

Детерминированный конечный автомат — один из способов представления регулярных языков [20]. Автомат состоит из состояний, которые могут быть терминальными или нетерминальными, и переходов между ними. Каждый переход осуществляется по одному из символов алфавита. В графическом представлении одного из ДКА (рис. 1) квадратами показаны терминальные состояния, окружностями — нетерминальные. Стартовое состояние отмечено звездочкой. Все



■ Рис. 1. Пример детерминированного конечного автомата

■ Fig. 1. An example of deterministic finite-state automaton

переходы между состояниями помечены символами, по которым переходы осуществляются.

Для того чтобы определить принадлежность слова к регулярному языку по ДКА, необходимо обработать данное слово с помощью автомата. Обработка начинается в нулевом состоянии и происходит посимвольно. Если после обработки автомат закончил свою работу в терминальном состоянии, то слово является принадлежащим искомому регулярному языку, и наоборот. В качестве иллюстрации рассмотрим автомат из рис. 1 и определим с его помощью принадлежность к описываемому им языку слова 'acab'. Автомат начинает свою работу в нулевом состоянии и последовательно совершает переходы в другие состояния по символам 'a', 'c', 'a' и 'b'. Таким образом, цепочка переходов: 0 → 1 → 2 → 3 → 3. Состояние 3 является нетерминальным, поэтому слово 'acab' не принадлежит к регулярному языку.

Искусственные нейронные сети

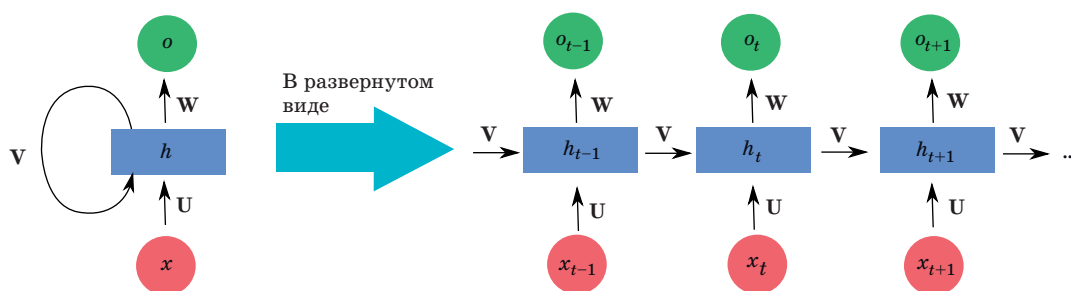
Искусственная нейронная сеть — это система соединенных между собой искусственных нейронов, каждый из которых принимает на вход числовые сигналы и формирует с использованием функции активации выходной числовой сигнал, который подается на вход других нейронов.

В данной работе применяются рекуррентные нейронные сети. Пример рекуррентной сети представлен на рис. 2, где W , V , U — матрицы весов.

Сеть состоит из входного X , скрытого H и выходного O слоев. Скрытые и выходные сигналы этой сети описываются соотношениями

$$h_t = f(V \times h_{t-1} + U \times x_t + c);$$

$$o_t = g(W \times h_t + d),$$



■ **Рис. 2.** Пример рекуррентной нейронной сети
 ■ **Fig. 2.** An example of recurrent neural network

где f, g — функции активации; c, d — параметры сети.

Для того чтобы правильно настроить параметры сети ($\mathbf{W}, \mathbf{V}, \mathbf{U}, c, d$), используется техника обучения с учителем. При этом часть данных помечается как тестовые, они последовательно подаются на вход сети, а ее ответ сравнивается с ожидаемым. Обычно используется некоторая функция ошибки $E(y, N(x))$, зависящая от реального значения y и ответа сети $N(x)$. Далее по значению функции ошибки пересчитываются значения параметров сети. Для этого, например, можно применить метод обратного распространения ошибки, который использует градиентный спуск.

Задача индуцирования грамматики и ее решение с помощью рекуррентных нейронных сетей

Формально задача индуцирования регулярной грамматики формулируется следующим образом. Задан алфавит и список строк над ним, каждая строка помечена как принадлежащая или не принадлежащая неизвестному регулярному языку. Необходимо построить детерминированный конечный автомат, соответствующий этому языку (он корректно обрабатывает все строки из входного списка). Этот автомат должен содержать как можно меньше состояний.

Классифицирующая рекуррентная нейронная сеть была впервые применена к задаче индуцирования регулярной грамматики в работе [16]. Предложенная авторами нейросеть обрабатывает слова посимвольно, а в качестве ответа возвращает число, которое можно интерпретировать как вероятность того, что обрабатываемое слово принадлежит искомому регулярному языку.

Обрабатываемое слово рассматривается как последовательность символов. Каждый символ алфавита кодируется в виде единичного вектора (вектора, состоящего из нулей на всех позициях, кроме одной, где стоит единица) размерности M , где M — мощность словаря. Если очередной символ слова является i -м символом алфавита, то со-

ответствующий ему единичный вектор будет содержать единицу на i -й позиции и нули на всех остальных. Рекуррентный слой нейронной сети принимает на вход векторы символа и состояния и возвращает следующий вектор состояния. Каждый вектор состояния имеет одинаковую размерность N . Следующее состояние вычисляется по формуле: $\mathbf{s}_{i+1} = \mathbf{s}_i \times \mathbf{W} \times \mathbf{a}_i$, где \mathbf{s}_i — вектор состояний; \mathbf{a}_i — вектор символов алфавита; \mathbf{W} — параметрическая матрица размерности $N \times N \times M$. Ответ нейронной сети зависит от вектора-состояния, полученного после последовательной обработки всех символов слова. Нулевой элемент этого вектора рассматривается как ответ нейронной сети. Описанная нейронная сеть обучается на примерах до наступления условий останова.

После того как нейронная сеть обучена, формируется список векторов-состояний, получаемый при обработке слов-примеров. К векторам из этого списка применяется алгоритм кластеризации, описанный в следующем разделе, и каждый полученный кластер рассматривается как соответствующий определенному состоянию автомата.

Таким образом, каждому слову из списка слов-примеров ставится в соответствие некоторый кластер, который в свою очередь соответствует некоторому состоянию автомата. Если для определенной строки s известно соответствующее ей состояние f , а также известно состояние t , соответствующее строке s^*c , где c — символ из словаря, а $*$ — знак конкатенации, то это позволяет построить переход из состояния f в состояние t по символу c . С использованием данного правила строится ДКА, который и возвращается в качестве ответа для задачи индуцирования грамматики.

Описанная схема применения рекуррентной нейронной сети получила свое развитие в работах [17, 18] и остается актуальной для задачи грамматического индуцирования. Так, например, авторы [19] используют в качестве классификатора нейронную сеть архитектуры долгой крат-

кроссочной памяти (*Long Short Term Memory — LSTM*), а в качестве алгоритма кластеризации — *L* Angluin*.

Предложенный алгоритм индуцирования грамматики

Используемая рекуррентная нейронная сеть

В основе применяемой модели для индуцирования грамматики лежит модификация рекуррентной нейронной сети, описанной в предыдущем разделе, которая решает задачу классификации. Размерность вектора, определяющего состояние сети, задается величиной параметра $n_neurons$.

В качестве функции ошибки предлагается специальная функция, названная *CardiLoss*. Значение функции рассчитывается по формуле

$$CardiLoss(x) = 4(N(x) - y)^2,$$

где x — слово-пример; $N(x)$ — ответ нейронной сети; y — правильный ответ. При тестировании модели авторами установлено, что сети, имеющие функцию ошибки, прямо пропорциональные $N(w)$, склонны сходиться к локальному минимуму, соответствующему возвращению ответа 0,5 на любые входные данные. Функция *CardiLoss* сформирована так, что имеет значение, близкое к 1,0 при ответе нейронной сети, равном 0,5, что позволяет избежать схождения к локальному минимуму.

Обучение нейронной сети осуществляется по эпохам. Перед началом очередной эпохи тренировочная выборка полностью перемешивается. В рамках одной эпохи обучение ведется последовательно по примерам. Если после обработки очередного примера значение функции *CardiLoss* оказалось выше значения гиперпараметра *expected_loss*, то считается, что нейронная сеть дала неправильный ответ. Обучение нейросети ведется до тех пор, пока в рамках одной эпохи нейросеть не даст правильные ответы на все слова из обучающей выборки.

Сбор векторов-состояний для последующей кластеризации

После того как нейронная сеть обучилась, начинается сбор векторов-состояний для последующей кластеризации. Для каждой строки w из списка слов-примеров рассмотрим список ее префиксов, состоящий из $|w| + 1$ строк. Каждый из них обрабатывается с помощью обученной рекуррентной нейронной сети и добавляется в список векторов-состояний.

Различные слова могут иметь совпадающие префиксы. Таким образом, в списке векторов-со-

стояний возможны одинаковые элементы. Это делается для того, чтобы в итоговой кластеризации больший вес (в смысле числа соответствующих им векторов) имели наиболее часто встречающиеся состояния.

Применение метода выбора и настройки гиперпараметров алгоритма кластеризации векторов-состояний на основе обучения с подкреплением

Известно большое число алгоритмов кластеризации, каждый из которых обладает гиперпараметрами, влияющими на его работу. Выбор конкретного алгоритма и значений его гиперпараметров будет определять итоговую кластеризацию.

В настоящей работе предлагается подбирать лучший алгоритм кластеризации и настраивать его гиперпараметры за счет решения задачи оптимизации качества кластеризации. В силу отсутствия математически корректного определения задачи кластеризации [21] универсальную меру качества разбиения выделить невозможно. В данной работе использовались четыре меры качества кластеризации: *Silhouette*, *Calinski-Harabasz*, *OS* и *gD41*. Обоснование и описание выбора мер приведено в диссертации [22].


В рамках настоящей работы используется метод *MASSCAH* [23, 24], опишем его.

Рассмотрим некоторое множество алгоритмов кластеризации $A = \{A^1, A^2, \dots, A^m\}$, из которых будем осуществлять выбор. С каждым алгоритмом A^j связано пространство гиперпараметров Λ^j . Необходимо за фиксированное время T найти алгоритм $A_{\lambda^*}^j$ такой, что $A_{\lambda^*}^j \in \operatorname{argmax}_{A^j \in A, \lambda \in \Lambda^j} Q(A^j, \lambda, D)$. Критерий качества Q — значение одной из множества мер качества кластеризации; D — набор данных.

Рассмотрим алгоритм настройки гиперпараметров [25], который является итеративным (*sequential*) и позволяет выбирать новые значения гиперпараметров на основе истории их выбора настройки. Разобьем временной бюджет T на равные интервалы. В начале каждого из них метод будет определять, для какого алгоритма кластеризации из заданного множества A будет производиться настройка. В подобной постановке задача определения, какой алгоритм настраивать следующим, эквивалентна задаче о многоруком бандите [26]. Иллюстрация работы метода представлена на рис. 3.

Решение о том, какую из ручек выбирает алгоритм обучения с подкреплением, принимается с помощью алгоритма *Softmax* [26], которому на итерации k подается на вход следующий вещественный вектор X :

$$X = \operatorname{Softmax}(R^k) + \operatorname{Softmax}(U^k),$$



■ **Рис. 3.** Иллюстрация работы предложенного метода MASSCAN настройки гиперпараметров

■ **Fig. 3.** Schematic representation of operation of the presented method MASSCAN on hyperparameters tuning

где $\text{Softmax}(x) = \left(\frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \right)_{i=1..n}$; $\mathbf{R}^k = (r_i^k)_{i=1..n}$ —

вектор наград, получаемых каждой ручкой обучения с подкреплением; $\mathbf{U}^k =$

$= \left(\sqrt{\frac{2 \ln \left(n + \sum_{j=1}^n \ln t_j^k \right)}{1 + \ln t_j^k}} \right)_{i=1..n}$ — вектор поправок,

которые вносятся в соответствии с затраченным временем; t_i^k — время, которое было потрачено на вычисления целевой функции для ручки i до итерации k , с.

В данной работе использовалось семь моделей алгоритмов кластеризации, составляющих множество \mathbf{A} : k -средних, DBSCAN, алгоритм распространения похожести, алгоритм агломеративной иерархической кластеризации, алгоритм среднего сдвига (*Mean Shift*), гауссова смесь и байесовская гауссова смесь. Реализации всех семи алгоритмов и соответствующие им множества гиперпараметров были заимствованы из библиотеки *scikit-learn* [27]. В качестве итеративного алгоритма выбора гиперпараметров использовался алгоритм *SMAC* [28].

Построение ДКА по построенной кластеризации

Предполагается, что каждый полученный кластер соответствует некоторому состоянию автомата. Для каждого вектора-состояния нейросети рассмотрим кластер c , в который он попал, и соответствующее ему слово w . Если это слово содержится в исходном наборе размеченных слов-примеров, то пометим кластер c в соответствии с этой разметкой. Если этот кластер уже помечен

иначе, то обнаружено противоречие, и попытка построения считается проваленной. В противном случае рассмотрим слово w_0 , являющееся вторым по длине префиксом строки w . При этом $w = w_0 + a_0$, где $a_0 = w[|w|]$ — последний символ слова w . Рассмотрим соответствующий w_0 кластер c_0 . Построим ребро из состояния, соответствующего c_0 , в состояние, соответствующее c , по символу a_0 . Если же из состояния, соответствующего c_0 , по символу a_0 уже имеется ребро, которое ведет не в c , то обнаружено противоречие, и попытка построения автомата считается проваленной.

Если при переборе векторов-состояний попытка построить автомат не будет провалена, то в результате работы приведенного алгоритма будет построен ДКА.

После этого проверим корректность построенного автомата. Переберем все слова из списка слов-примеров и применим к ним полученный автомат. Если для каждого слова он завершает свою работу в правильном состоянии — в состоянии, соответствующем разметке, то этим доказывается правильность построенного автомата.

Эксперименты

Тестовые данные

Значительная часть мировых исследований, посвященных проблеме индуцирования грамматик, использует для тестирования наборы данных, предложенные в работе [29]. Однако они соответствуют только грамматикам, содержащим не более двух символов в алфавитах, к тому же некоторые из этих грамматик не являются регулярными. Для полноценного тестирования модели необходимо использовать только регулярные грамматики, содержащие различное число символов в алфавите. Для тестирования описанной модели был разработан такой набор регулярных грамматик и, соответственно, набор размеченных списков слов-примеров.

Было разработано 10 регулярных грамматик, и для каждой из них был вручную построен минимальный ДКА. Построенные автоматы имеют от трех до десяти состояний и от двух до пяти символов в алфавитах. Далее был применен алгоритм генерации набора данных. По целевым автоматам и по сформированным наборам параметров для генерации были синтезированы 10 наборов слов-примеров, соответствующих регулярным грамматикам. Каждое слово в таком наборе помечено нулем или единицей в зависимости от принадлежности слова целевому регулярному языку. Описание разработанных автоматов и количество слов в соответствующих наборах данных представлены в табл. 1.

- **Таблица 1.** Тестовые регулярные грамматики и соответствующие наборы данных
- **Table 1.** The description of test regular grammars and corresponding datasets

ID	Описание регулярного языка	Число		
		символов в алфавите	состояний в минимальном автомате	слов в наборе данных
D1	Слова, которые не содержат одинаковых символов на соседних позициях	2	4	500
D2	Слова, которые не содержат одинаковых символов на соседних позициях	3	5	520
D3	Слова, длина которых кратна трем	3	3	586
D4	Слова, содержащие подстроку 'bac'	3	4	580
D5	Слова, принадлежащие регулярному языку, соответствующему автомату на рис. 1	3	4	500
D6	Слова, содержащие подстроку 'abacaba'	3	8	1200
D7	Слова, символы в которых отсортированы лексикографически	5	6	1200
D8	Слова, содержащие не более двух согласных или одной гласной подряд	5	5	1200
D9	Слова, длина которых кратна двум или пяти	3	10	1200
D10	Слова, не содержащие символа 'b', длина которых по модулю 3 равна единице	5	4	1200

Программная реализация и тестирование

Классифицирующая рекуррентная нейронная сеть была реализована на языке *Python 3* с использованием специализированной библиотеки машинного обучения *PyTorch*. При обучении сети на каждом из наборов данных использовались параметры $n_neurons = 16$ и $expected_loss = 0,02$.

Алгоритм одновременных выбора и настройки алгоритма кластеризации для получения разбиения векторов-состояний был реализован на языке *Python* версии 3.7.5. Для реализации данного алгоритма использовались библиотеки *SMAC* [30] и *ConfigSpace* [31]. Каждой паре «мера качества — набор данных» отводился временной бюджет 5000 с.

Вычисления проводились на двух серверах, которые при помощи специального планировщика распределяли задачи. Параметры серверов:

- 64-ядерный процессор *AMD Opteron 6378 @ 2.4 GHz, 256 GB RAM;*
- 64-ядерный процессор *AMD Opteron 6380 @ 2.5 GHz, 496 GB RAM.*

Алгоритм построения ДКА был реализован на языке *Python* версии 3.7.5. Если на основе полученной кластеризации удавалось построить непротиворечивый ДКА, корректно обрабатывающий каждое слово из списка слов-примеров, то попытка построения ДКА считалась успешной.

Результаты экспериментов

Из десяти автоматов, разработанных для поставленной задачи, семь были построены пра-

вильно, причем четыре из них получились минимально возможными. Приведем полную сводную таблицу результатов с указанием использованной меры настройки гиперпараметров для кластеризации (табл. 2).


- **Таблица 2.** Результаты тестирования предлагаемой модели

- **Table 2.** Results of the proposed model's testings


ID	Удалось ли построить корректный ДКА?	Число состояний		Примененная мера настройки гиперпараметров
		в минимальном автомате	в построенном моделью автомате	
D1	+	4	4	<i>gD41</i>
D2	+	5	7	<i>gD41</i>
D3	+	3	3	<i>gD41</i>
D4	+	4	8	<i>gD41</i>
D5	+	4	4	<i>gD41</i>
D6	–	8	–	–
D7	–	6	–	–
D8	+	5	5	<i>gD41</i>
D9	–	10	–	–
D10	+	4	5	<i>Calinski-Harabasz</i>

Для некоторых наборов данных, например для соответствующего языку D10, удалось построить корректный ДКА, верно обрабатывающий все строки-примеры, который, однако, не является минимальным по числу состояний. На рис. 4 изображен минимально возможный автомат, соответствующий языку D10, а на рис. 5 — автомат, построенный предложенным методом по словам-примерам из D10. Отметим, что эти автоматы эквивалентны — первый получается из второго слиянием состояний 3 и 0 и перенумерацией состояний, никак не влияющей на структуру автомата. Слияние состояний 3 и 0 допустимо, поскольку их терминальность совпадает, а переходы по одним и тем же символам ведут в одни и те же состояния.

Результаты экспериментов показали, что оптимальной для небольших по числу переходов



■ Рис. 4. Целевой ДКА для языка D10
 ■ Fig. 4. Target DFA for the D10 language



■ Рис. 5. Автомат, корректно обрабатывающий все слова из набора данных для языка D10, построенный моделью
 ■ Fig. 5. Synthesized automaton which processes all the words from D10 dataset correctly

автоматов (не превышающих 20–25 переходов) является мера $gD41$. Однако при ее использовании оказалось невозможным построить непротиворечивый автомат для D10. Соответствующую регулярную грамматику удалось индуцировать при использовании меры *Calinski-Harabasz*.

Автоматы, соответствующие наборам данных D6, D7 и D9, не удалось построить ни для каких мер. В каждом из случаев произошло одно из двух событий:

А) полученная кластеризация определяет число состояний, которое меньше числа состояний у минимально возможного автомата, соответствующего искомой регулярной грамматике;

Б) на основе полученной кластеризации невозможно построить непротиворечивый ДКА.

Детали тестирования модели на этих наборах данных отображены в табл. 3.

Поскольку для тестирования модели был сгенерирован специальный набор данных, то результаты экспериментов сложно сопоставимы с результатами аналогичных исследований других авторов. Однако предложенный метод показал лучшие результаты по сравнению с методом из статьи [30], в которой использовались те же наборы данных.

Сравнение полученных результатов с результатами из статьи [19], считающей одной из наиболее актуальных работ последних лет по задаче индуцирования грамматик, показывает, что размеры получаемых автоматов сопоставимы. Однако нейронная сеть, которая используется в настоящей работе, содержит меньше настраиваемых параметров и быстрее обучается, чем используемая авторами статьи [19] сеть *LSTM*. Кроме того, авторы [19] считают положительным результатом построение автомата, чья точность на тренировочном наборе данных отличается от единицы (например, равна 0,99), в то время как в настоящей работе корректным считается только автомат, имеющий точность, равную единице.

■ Таблица 3. Результаты тестирования на наборах данных D6, D7, D9

■ Table 3. Results of testings on D6, D7 & D9 datasets

Набор данных \ мера	<i>Calinski-Harabasz</i>	$gD41$	<i>OS</i>	<i>Silhouette</i>
D6	Б	А	А	Б
D7	Б	Б	А	Б
D9	Б	Б	А	А

Заключение

Полученные результаты показывают эффективность предлагаемого метода и применимость метода выбора и настройки гиперпараметров алгоритма кластеризации на основе обучения с подкреплением к задаче индуцирования грамматики.

Усложнение грамматик (свыше 25–30 переходов) приводит к тому, что автоматы не удается синтезировать. Для улучшения результатов модели можно предпринять следующие шаги:

1) использовать рекуррентные нейросети иных структур в качестве *RNN*-акцептора (к примеру, *LSTM* или модели с вниманием);

2) использовать иные меры настройки гиперпараметров для алгоритма кластеризации;

3) разработать и применить алгоритм, устраняющий противоречия в кластеризации в пользу наиболее правдоподобного варианта.

Финансовая поддержка

Данное исследование выполнено при поддержке проекта государственного задания №2.8866.2017/БЧ «Технология разработки программного обеспечения систем управления ответственными объектами на основе глубокого обучения и конечных автоматов», выполняемого в рамках базовой части государственного задания.

Литература

1. Bahlke R., Snelling G. The PSG system: from formal language definitions to interactive programming environments. *ACM Transactions on Programming Languages and Systems (TOPLAS)*, 1986, vol. 8, no. 4, pp. 547–576.
2. Van Fraassen B. C. *Formal semantics and logic*. Macmillan, 1971. 343 p.
3. Hoare C. A. R., Wirth N. An axiomatic definition of the programming language PASCAL. *Acta Informatica*, 1973, vol. 2, no. 3, pp. 335–355.
4. Kate R. J., Wong Y. W., Mooney R. J. Learning to transform natural to formal languages. *AAAI*, 2005, pp. 1062–1068.
5. Jäger G., Rogers J. Formal language theory: refining the Chomsky hierarchy. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 2012, vol. 367, no. 1598, pp. 1956–1970.
6. Gribkoff E. *Applications of deterministic finite automata*. <https://web.cs.ucdavis.edu/~rogaway/classes/120/spring13/eric-dfa.pdf> (дата обращения: 15.12.2019).
7. Sirakoulis G. C., Karafyllidis I., Mizas C., Mardiris V., Thanailakis A., Tsalides P. A cellular automaton model for the study of DNA sequence evolution. *Computers in Biology and Medicine*, 2003, vol. 33, no. 5, pp. 439–453.
8. Meng J. P., Dai S. Q., Dong L. Y., Zhang J. F. Cellular automaton model for mixed traffic flow with motorcycles. *Physica A: Statistical Mechanics and its Applications*, 2007, no. 380, pp. 470–480.
9. Filiol E. *Computer viruses: from theory to applications*. Springer Science & Business Media, 2006. 417 p.
10. Sakarovitch J. *Elements of automata theory*. Cambridge University Press, 2009. 785 p.
11. Angluin D. Inference of reversible languages. *Journal of the ACM*, 1982, vol. 29, no. 3, pp. 741–765.
12. Gold E. M. Language identification in the limit. *Information and Control*, 1967, vol. 10, no. 5, pp. 447–474.
13. Yu F., Bultan T., Ibarra O. Relational string verification using multi-track automata. *Proceedings of the 15th International Conference “Implementation and Application of Automata”*, Manitoba, Canada, 2010, pp. 1909–1924.
14. De la Higuera C. *Grammatical inference: learning automata and grammars*. Cambridge University Press, 2010. 417 p.
15. Barzdin I. M. *Finite automata-behavior and synthesis*. North-Holland Publishing Company, 1973. 321 p.
16. Giles C. L., Sun G. Z., Chen H. H., Lee Y. C., Chen D. Higher order recurrent networks and grammatical inference. *Advances in Neural Information Processing Systems*, 1990, vol. 2, pp. 380–387.
17. Gile C. L., Miller C. B., Chen D., Sun G. Z., Chen H. H., Lee Y. C. Extracting and learning an unknown grammar with recurrent neural networks. *Proceedings of the 3rd Conference “Advances in Neural Information Processing Systems”*, 1992, pp. 317–324.
18. Omlin C. W., Giles C. L. Constructing deterministic finite-state automata in recurrent neural networks. *Journal of the ACM*, 1996, vol. 43, no. 6, pp. 937–972.
19. Weiss G., Goldberg Y., Yahav E. *Extracting automata from recurrent neural networks using queries and counterexamples*. <https://arxiv.org/pdf/1711.09576.pdf> (дата обращения: 15.12.2019).
20. Hopcroft J. E., Motwani R., Ullman J. D. Introduction to automata theory, languages, and computation. *Acta Sigact News*, 2001, vol. 32, no. 1, pp. 60–65.
21. Hennig C. What are the true clusters? *Pattern Recognition Letters*, 2015, no. 64, pp. 53–62.
22. Муравьев С. Б. Система автоматического выбора и оценки алгоритмов кластеризации и их параметров: дис. ... канд. техн. наук: 05.13.17. Санкт-Петербург, Университет ИТМО, 2019. 308 с.
23. Shalamov V., Efimova V., Muravyov S., Filchenkov A. Reinforcement-based method for simultaneous clustering algorithm selection and its hyperparameters optimization. *Procedia Computer Science*, 2018, no. 136, pp. 144–153.

24. Муравьев С. Б., Ефимова В. А., Шаламов В. В., Фильченков А. А., Сметанников И. Б. Автоматическая настройка гиперпараметров алгоритмов кластеризации с помощью обучения с подкреплением. *Научно-технический вестник информационных технологий, механики и оптики*, 2019, т. 19, вып. 3, с. 508–515.
25. Eggenberger K., Feurer M., Hutter F., Bergstra J., Snoek J., Hoos H., Leyton-Brown E. Towards an empirical foundation for assessing Bayesian optimization of hyperparameters. *NIPS Workshop on Bayesian Optimization in Theory and Practice*, 2013, vol. 10, pp. 1–5.
26. Sutton R. S. *Reinforcement learning*. MIT Press, 1998. 1054 p.
27. Pedregosa F. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 2011, no. 12, pp. 2825–2830.
28. Hutter F., Hoos H., Leyton-Brown K. An evaluation of sequential model-based optimization for expensive blackbox functions. *Genetic and Evolutionary Computation Conference*, Amsterdam, July 2013, pp. 1209–1216.
29. Tomita M. Learning of construction of finite automata from examples using hill-climbing. RR: regular set recognizer. *Proceedings of Fourth International Cognitive Science Conference*, 1982, pp. 105–108.
30. Hutter F., Hoos H. H., Leyton-Brown K. Sequential model-based optimization for general algorithm configuration. *Learning and Intelligent Optimization*. Springer, 2011, pp. 507–523.
31. Lindauer M., Eggenberger K., Feurer M., Biedenkapp A., Marben J., Müller P., Hutter F. *BOAH: A tool suite for multi-fidelity bayesian optimization & analysis of hyperparameters*. <https://arxiv.org/pdf/1908.06756v1.pdf> (дата обращения: 15.12.2019).

UDC 519.713.1

doi:10.31799/1684-8853-2020-1-34-43

Automata generation based on recurrent neural networks and automated cauterization selectionP. G. Grachev^a, Post-Graduate Student, orcid.org/0000-0002-1133-8432S. B. Muravyov^a, PhD, Tech., Programmer, orcid.org/0000-0002-4251-1744A. A. Filchenkov^a, PhD, Phys.-Math., Associate Professor, orcid.org/0000-0002-1133-8432A. A. Shalyto^a, Dr. Sc., Tech., Professor, orcid.org/0000-0002-2723-2077, shalyto@mail.ifmo.ru^aSaint-Petersburg National Research University of Information Technologies, Mechanics and Optics,

49, Kronverkskii Pr., 197101, Saint-Petersburg, Russian Federation

Introduction: The regular inference problem is to synthesize deterministic finite-state automata by a list of words which are examples and counterexamples of some unknown regular language. This problem is one of the main in the theory of formal languages and related fields. One of the most successful solutions to this problem is training a recurrent neural network on word classification and clustering the vectors in the space of RNN inner weights. However, it is not guaranteed that a consistent automaton can be constructed based on the clustering results. More complex models require more memory, training time and training samples. **Purpose:** Creating a brand new grammar inference algorithm which would use modern machine learning methods. **Methods:** A recurrent neural network with an error function proposed by the authors was used for classification. For clustering, the method of joint selection and tuning of hyperparameter was used. **Results:** Ten different datasets were used for testing the models, corresponding to ten different regular grammars and ten automata. According to the test results, the developed model successfully synthesize automata with no more than five input characters and states. For four grammars, out of the seven successfully inferred ones, the constructed automaton was minimal. For three datasets, an automaton could not be built, either because of an insufficient number of clusters in the proposed partition, or because of the inability to build a consistent automaton for this partition. **Discussion:** Applying the algorithm of search for maximum likelihood between the clusters of vector and the corresponding states in order to resolve structural conflicts may expand the scope of the model.

Keywords — grammar inference, recurrent neural networks, clusterization.

For citation: Grachev P. G., Muravyov S. B., Filchenkov A. A., Shalyto A. A. Automata generation based on recurrent neural networks and automated cauterization selection. *Informatsionno-upravliayushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 34–43 (In Russian). doi:10.31799/1684-8853-2020-1-34-43

References

- Bahlke R., Snelting G. The PSG system: from formal language definitions to interactive programming environments. *ACM Transactions on Programming Languages and Systems (TOPLAS)*, 1986, vol. 8, no. 4, pp. 547–576.
- Van Fraassen B. C. *Formal semantics and logic*. Macmillan, 1971. 343 p.
- Hoare C. A. R., Wirth N. An axiomatic definition of the programming language PASCAL. *Acta Informatica*, 1973, vol. 2, no. 3, pp. 335–355.
- Kate R. J., Wong Y. W., Mooney R. J. Learning to transform natural to formal languages. *AAAI*, 2005, pp. 1062–1068.
- Jäger G., Rogers J. Formal language theory: refining the Chomsky hierarchy. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 2012, vol. 367, no. 1598, pp. 1956–1970.
- Gribkoff E. Applications of deterministic finite automata. *UC Davis*, 2013. Available at: <https://web.cs.ucdavis.edu/~rogaway/classes/120/spring13/eric-dfa.pdf> (accessed 15 December 2019).
- Sirakoulis G. C., Karafyllidis I., Mizas C., Mardiris V., Thanailakis A., Tsalides P. A cellular automaton model for the study of DNA sequence evolution. *Computers in Biology and Medicine*, 2003, vol. 33, no. 5, pp. 439–453.

8. Meng J. P., Dai S. Q., Dong L. Y., Zhang J. F. Cellular automaton model for mixed traffic flow with motorcycles. *Physica A: Statistical Mechanics and its Applications*, 2007, no. 380, pp. 470–480.
9. Filiol E. *Computer viruses: from theory to applications*. Springer Science & Business Media, 2006. 417 p.
10. Sakarovitch J. *Elements of automata theory*. Cambridge University Press, 2009. 785 p.
11. Angluin D. Inference of reversible languages. *Journal of the ACM*, 1982, vol. 29, no. 3, pp. 741–765.
12. Gold E. M. Language identification in the limit. *Information and Control*, 1967, vol. 10, no. 5, pp. 447–474.
13. Yu F., Bultan T., Ibarra O. Relational string verification using multi-track automata. *Proceedings of the 15th International Conference “Implementation and Application of Automata”*, Manitoba, Canada, 2010, pp. 1909–1924.
14. De la Higuera C. *Grammatical inference: learning automata and grammars*. Cambridge University Press, 2010. 417 p.
15. Barzdin I. M. *Finite automata-behavior and synthesis*. North-Holland Publishing Company, 1973. 321 p.
16. Giles C. L., Sun G. Z., Chen H. H., Lee Y. C., Chen D. Higher order recurrent networks and grammatical inference. *Advances in Neural Information Processing Systems*, 1990, pp. 380–387.
17. Gile C. L., Miller C. B., Chen D., Sun G. Z., Chen H. H., Lee Y. C. Extracting and learning an unknown grammar with recurrent neural networks. *Proceedings of the 3rd Conference “Advances in Neural Information Processing Systems”*, 1992, pp. 317–324.
18. Omlin C. W., Giles C. L. Constructing deterministic finite-state automata in recurrent neural networks. *Journal of the ACM*, 1996, vol. 43, no. 6, pp. 937–972.
19. Weiss G., Goldberg Y., Yahav E. *Extracting automata from recurrent neural networks using queries and counterexamples*. Available at: <https://arxiv.org/pdf/1711.09576.pdf> (accessed 15 December 2019).
20. Hopcroft J. E., Motwani R., Ullman J. D. Introduction to automata theory, languages, and computation. *Acm Sigact News*, 2001, vol. 32, no. 1, pp. 60–65.
21. Hennig C. What are the true clusters? *Pattern Recognition Letters*, 2015, no. 64, pp. 53–62.
22. Muravyov S. B. *Sistema avtomaticheskogo vybora i otsenki algoritmov klasterizatsii i ih parametrov*. Dis. kand. tehn. nauk: 05.13.17 [Automated system for selection and evaluation clusterization algorithms and their parameters, PhD tech. sci. diss.]. Saint-Petersburg, ITMO University, 2019. 308 p. (In Russian).
23. Shalamov V., Efimova V., Muravyov S., Filchenkov A. Reinforcement-based method for simultaneous clustering algorithm selection and its hyperparameters optimization. *Procedia Computer Science*, 2018, no. 136, pp. 144–153.
24. Muravyov S. B., Efimova V. A., Shalamov V. V., Filchenkov A. A., Smetannikov I. B. Automated hyperparameters tuning for clusterization algorithm using reinforcement learning. *Nauchno-tehnicheskiiy vestnik informatsionnyh tehnologii, mehaniki i optiki*, 2019, vol. 19, no. 3, pp. 508–515 (In Russian).
25. Eggenberger K., Feurer M., Hutter F., Bergstra J., Snoek J., Hoos H., Leyton-Brown E. Towards an empirical foundation for assessing Bayesian optimization of hyperparameters. *NIPS Workshop on Bayesian Optimization in Theory and Practice*, 2013, vol. 10, pp. 1–5.
26. Sutton R. S. *Reinforcement learning*. MIT Press, 1998. 1054 p.
27. Pedregosa F. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 2011, no. 12, pp. 2825–2830.
28. Hutter F., Hoos H., Leyton-Brown K. An evaluation of sequential model-based optimization for expensive blackbox functions. *Genetic and Evolutionary Computation Conference*, Amsterdam, July 2013, pp. 1209–1216.
29. Tomita M. Learning of construction of finite automata from examples using hill-climbing: RR: regular set recognizer. *Proceedings of Fourth International Cognitive Science Conference*, 1982, pp. 105–108.
30. Hutter F., Hoos H. H., Leyton-Brown K. Sequential model-based optimization for general algorithm configuration. *Learning and Intelligent Optimization*. Springer, 2011, pp. 507–523.
31. Lindauer M., Eggenberger K., Feurer M., Biedenkapp A., Marben J., Müller P., Hutter F. *BOAH: A tool suite for multi-fidelity bayesian optimization & analysis of hyperparameters*. Available at: <https://arxiv.org/pdf/1908.06756v1.pdf> (accessed 15 December 2019).

УДК 681.391.83

doi:10.31799/1684-8853-2020-1-44-53

Поиск бинарных кодовых последовательностей с низким уровнем боковых лепестков эволюционным способом

С. Н. Шаров^а, доктор техн. наук, профессор, orcid.org/0000-0002-9634-155XС. Г. Толмачев^а, канд. техн. наук, [orcid.org/0000-0001-9434-1268, tsg17@yandex.ru](mailto:tsg17@yandex.ru)^аАО «Концерн «Гранит-Электрон», Госпитальная ул., 3, Санкт-Петербург, 191014, РФ

Введение: выбор параметров сложных кодированных сигналов, используемых в активных радиолокационных системах летательных аппаратов для обнаружения объектов, во многом определяет их качественные характеристики и возможность скрытой работы. Актуальной задачей при проектировании систем подобного типа является формирование ансамблей шумоподобных бинарных кодовых последовательностей фиксированной длины с заданными характеристиками. **Цель:** поиск шумоподобных бинарных кодовых последовательностей заданной длины, оптимальных по критерию минимального уровня боковых лепестков апериодической автокорреляционной функции. **Результаты:** предложена процедура поиска бинарных кодовых последовательностей с заданными параметрами, основанная на эволюционном подходе. В качестве критерия отбора кодовых последовательностей используется минимальный уровень положительных боковых лепестков автокорреляционной функции. Дополнительное ограничение накладывается на длину подстроки из кодов одного знака. На примере 31-разрядных кодовых последовательностей показана возможность формирования представительного массива последовательностей с наилучшим отношением главного пика апериодической автокорреляционной функции к ее максимальному положительному боковому лепестку. Предложен алгоритм формирования шумоподобной серии сигналов, использующий найденные кодовые последовательности. В качестве меры отличия двух бинарных кодовых последовательностей в серии используется расстояние Хемминга. Показаны преимущества предложенного подхода в сравнении с известным способом формирования шумоподобных сигналов на основе псевдослучайных m -последовательностей. **Практическая значимость:** полученные результаты целесообразно использовать в алгоритмах радиолокационных систем автономных летательных аппаратов с высокой разрешающей способностью по дальности для обнаружения физических объектов на фоне подстилающей поверхности, например, надводных объектов.

Ключевые слова – кодовая последовательность, боковой лепесток, автокорреляционная функция, генетический алгоритм, рекомбинация, отбор.

Для цитирования: Шаров С. Н., Толмачев С. Г. Поиск бинарных кодовых последовательностей с низким уровнем боковых лепестков эволюционным способом. *Информационно-управляющие системы*, 2020, № 1, с. 44–53. doi:10.31799/1684-8853-2020-1-44-53

For citation: Sharov S. N., Tolmachev S. G. Search for binary code sequences with low autocorrelation sidelobes by the evolutionary method. *Informatsionno-upravlyaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 44–53 (In Russian). doi:10.31799/1684-8853-2020-1-44-53

Введение

При разработке радиолокационных систем (РЛС) обнаружения активного типа, устанавливаемых на борту летательных аппаратов, наряду с обеспечением требований помехоустойчивости и скрытности их функционирования большое внимание уделяется формированию определенных свойств зондирующих сигналов, с помощью которых выделяются информативные признаки обнаруживаемых объектов. На практике широко применяются сложные шумоподобные сигналы, использующие дискретные кодовые последовательности (КП) для модуляции излучения РЛС [1]. Алгоритм формирования сигналов бортовых РЛС должен задействовать только те последовательности, которые имеют требуемые показатели качества. Примером кодированных сигналов являются фазоманипулированные сигналы. Последовательность фаз (0 или π) в отдельных временных квантах можно представить в виде со-

ответствующей последовательности чисел (кодов) «+1» или «-1»: $\{a_N\} = \{a_i, i = 1, \dots, N\}, a_i = \pm 1$.

Одной из актуальных задач практического использования кодированных сигналов является задача синтеза ансамблей бинарных КП с требуемыми свойствами их автокорреляционной функции (АКФ) [2, 3]. Представительная выборка КП позволяет формировать с их помощью псевдослучайные (шумоподобные) последовательности зондирующих сигналов, затрудняющие их обнаружение и постановку им искусственных помех.

Значения АКФ бинарной КП в дискретные моменты времени определяются выражением [4]

$$R_k = \sum_{i=1}^{N-k} a_i a_{i+k}. \text{ Для бортовых РЛС большое зна-}$$

чение имеет вид апериодической АКФ КП, так как их зондирующие сигналы, как правило, не являются непрерывными. Апериодическая АКФ бинарной КП имеет ярко выраженный центральный пик R_0 , величина которого равна длине КП,

и боковые лепестки (БЛ) $R_{k \neq 0}$. Большие БЛ АКФ являются нежелательными и могут приводить к появлению ложных целей и пропуску реальных целей. Для оценки АКФ по уровню БЛ используют две характеристики [5]: мерит-фактор MF — отношение уровня главного пика к суммарной «энергии» БЛ и уровень максимального БЛ (*peak sidelobe*) $PSL = \max(R_{k \neq 0})$.

Минимизация параметра PSL важна при обнаружении целей на фоне подстилающей поверхности, когда объект и фон порождают отклики с высокой амплитудой БЛ, которые в зависимости от уровня срабатывания порогового устройства могут быть восприняты как ложные цели. Чем меньше уровень БЛ, тем меньше вероятность ложного срабатывания.

Постановка задачи построения бинарных КП, оптимальных по минимаксному критерию — MPS (*minimum peak sidelobe*) кодов ($\min(PSL)$), известна с начала 50-х годов прошлого столетия. В большинстве случаев эта задача решается методом полного перебора [6]. Использование переборных алгоритмов для поиска КП большой длины N представляет большие трудности. Основные усилия разработчиков направлены на поиск возможностей сокращения вычислительной сложности переборных алгоритмов [7]. Основные результаты синтеза MPS -последовательностей приведены в работе [1]. На сегодня известны оптимальные бинарные MPS -последовательности с минимальным уровнем БЛ — бинарные КП Баркера до длины $N = 13$. Существуют методы синтеза бинарных КП с достаточно малым уровнем БЛ: КП Лежандра, Якоби, Холла, Зингера, m -последовательности и т. д. [8].

Простым способом, не требующим больших аппаратных и программных затрат, является рекуррентная процедура формирования бинарных КП максимальной длины, так называемых m -последовательностей, имеющих приемлемый уровень БЛ АКФ [6]. Для реализации КП задается произвольный набор чисел $x_j \in \{0, 1\}$, $j = 1 \dots n$ и начальная подстрока последовательности $a_1, \dots, a_j, \dots, a_n$, где $a_j \in \{+1, -1\}$. Каждый следующий элемент последовательности a_{i+1} вычисляется по

$$\text{рекуррентной формуле: } a_{i+1} = \prod_{j=1}^n a_{i-j+1}^{x_j}, \text{ где } i > n.$$

Образуется бесконечная повторяющаяся последовательность чисел a_i , причем максимальный период повторения составляет $N = 2^n - 1$. Первые n элементов последовательности выбираются произвольным образом, кроме запрещенной комбинации из всех единиц. Известно [9, 10], что для любого n существует $s = \varphi(N)/n$ различных вариантов рекуррентной формулы, отличающихся значениями x_j и формирующих КП максимального периода N , где $\varphi(N)$ — функ-

ция Эйлера, т. е. число целых чисел, взаимно простых с N и меньших, чем N . Значения $x_j \neq 0$ в рекуррентной формуле определяют вид образующего полинома и обратные связи в генераторе m -последовательности.


Преимущества m -последовательностей, имеющие существенное значение для бортовых РЛС автономных летательных аппаратов, заключаются в следующем [4].

1. Рекуррентная формула просто реализуется с помощью n регистров сдвига. Могут быть построены m -последовательности, период которых больше любого наперед заданного значения N .


2. Апериодическая АКФ сигнала, модулированного одним периодом m -последовательности, имеет уровень БЛ не более \sqrt{N} .

3. m -последовательности позволяют сформировать шумоподобный зондирующий сигнал за счет свойства ее «хаотичности». Если из периода последовательности выбрать все возможные группы кодов длиной n , то среди них найдутся любые не повторяющиеся комбинации из символов $+1$ и -1 .

Например, для КП длины $N = 31$ значения $n = 5$, $s = 6$, т. е., используя 30 различных комбинаций первых n элементов, можно получить 180 различных вариантов m -последовательностей разного качества, причем эти последовательности будут попарно зеркальными. Иначе говоря, оригинальными можно признать только половину из них. Типовой вид АКФ m -последовательности длины $N = 31$ приведен на рис. 1. Величины максимальных положительных БЛ (*peak sidelobe positive* PSL_p) в этом ансамбле КП принимают значения в интервале от трех до шести. Количественное распределение значений PSL_p в массиве генерируемых КП в отношении ко всему его объему, Sm , показано на рис. 2. Очевидно, что менее 30 % КП имеют наименьший уровень БЛ $PSL_p = 3$. Таким



■ **Рис. 1.** Пример АКФ 31-разрядной m -последовательности
 ■ **Fig. 1.** An example of ACF 31-bit m -sequences



■ **Рис. 2.** Распределение значений PSL_p в массиве 31-разрядных m -последовательностей

■ **Fig. 2.** Distribution of values peak sidelobe an array 31-bit m -sequences

образом, к недостаткам m -последовательностей можно отнести ограниченное количество генерируемых КП и достаточно большие значения БЛ их АКФ, превышающие минимально достижимый уровень в 1,5–3 раза.

Необходимо отметить, что оценка бинарных КП по критерию минимума максимальных положительных БЛ АКФ может применяться для приема сигналов с известной начальной фазой.

Еще одним способом формирования бинарных КП являются бинарные последовательности Лежандра [8]. За основу берется простое число p , значения $0, 1, \dots, p - 1$ отождествляются с номерами позиций i символов a_i периодической КП $\{a_i\}$ периода $N = p$. Тогда правило формирования периодической КП Лежандра определяется в виде

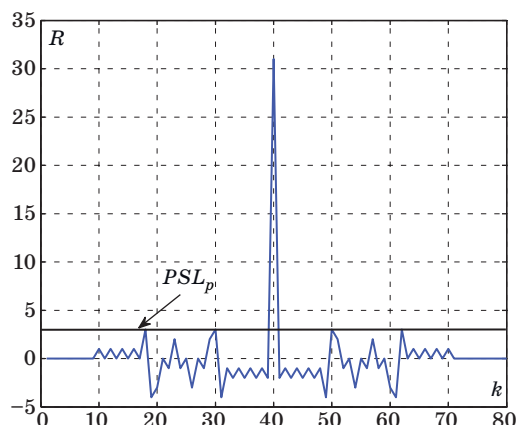
$$a_i = \begin{cases} +1, & i = 0 \pmod{p}; \\ \psi(i), & i \neq 0 \pmod{p}, \end{cases}$$

где $\psi(i)$ — функция, принимающая значения +1 или -1 в зависимости от принадлежности элемента i к категории вычетов (символ Лежандра):

$$\psi(i) = \begin{cases} +1, & i - \text{вычет} \pmod{p}; \\ -1, & i - \text{невычет} \pmod{p}. \end{cases}$$

Число i такое, что наибольший общий делитель $(i, p) = 1$, называется вычетом степени n , если $\exists(x) : x^n \equiv i \pmod{p}$. Например, для $N = 31$ и $n = 2$ АКФ КП Лежандра имеет вид как на рис. 3.

В общем случае КП Лежандра образуют более мощный, чем m -последовательности, класс бинарных КП с минимаксной периодической АКФ за счет того, что они определены для большего количества значений N . Но при использовании КП одной длины N , для которой определены оба варианта последовательностей, количество последова-



■ **Рис. 3.** АКФ 31-разрядной последовательности Лежандра

■ **Fig. 3.** ACF 31-bit Legendre sequence

тельств, формируемых методом Лежандра, меньше, чем m -последовательностей. Свойство минимальности уровня PSL_p не соблюдается как для аperiodической АКФ КП Лежандра, так и для АКФ m -последовательностей.

В настоящее время не известны регулярные правила построения MPS-последовательностей произвольной длины [1]. Различные способы локального компьютерного поиска позволяют синтезировать бинарные последовательности с приемлемым уровнем БЛ для практически значимых значений N .

Вместе с тем при проектировании радиолокационных систем обнаружения и самонаведения летательных аппаратов актуальной задачей является формирование представительного ансамбля MPS-последовательностей заданной длины N [11]. Массив этих КП записывается в память бортового компьютера и используется для формирования шумоподобной серии зондирующих сигналов РЛС. Для поиска нужного количества КП нет необходимости использовать вычислительно сложные алгоритмы полного перебора. Альтернативой полному перебору вариантов КП являются алгоритмы псевдослучайного целенаправленного поиска, относящиеся к классу генетических алгоритмов (ГА) [12].

Генетический алгоритм формирования ансамбля бинарных КП с требуемым уровнем боковых лепестков

Генетический алгоритм — эвристический способ поиска квазиоптимальных вариантов решений, являющийся разновидностью эволюционных вычислений. В основе ГА лежит итерационная стохастическая процедура комбинирования свободных параметров проектируемого объекта

с последующим целенаправленным отбором вариантов, лучших с точки зрения заданного критерия — функционала качества [13–15].

Задача оптимизации функционала качества в терминологии ГА формулируется как задача поиска экстремума функции приспособленности (*fitness function* — *FFn*) особей, образующих популяцию. Каждая особь, представляющая один из вариантов решения задачи, кодируется строкой символов, называемой хромосомой. Более приспособленные особи — это более приемлемые решения, имеющие лучшие значения *FFn*. В рассматриваемой задаче особь — это один из возможных вариантов КП. Последовательность символов +1 и -1 в бинарной КП может использоваться в ГА в качестве хромосомы особи. Функцию приспособленности целесообразно определить в виде отношения максимума АКФ (основного лепестка) к максимальному положительному значению ее БЛ. Поскольку максимум АКФ равен длине КП, *N*, то приспособленность *k*-й КП $FFn(k) = N/PSLp(k)$.

Генетический алгоритм запускает несколько циклов эволюции популяции особей. Начальная популяция формируется случайным образом. В каждом цикле ГА поочередно реализуются три операции [16]:

— рекомбинация особей текущей популяции путем скрещивания (кроссовера) пар КП-родителей для формирования новых вариантов КП-потомков;

— мутация (инвертирование) некоторых символов в хромосомах КП-потомков по произвольному правилу;

— отбор (селекция) в следующее поколение наиболее приспособленных особей из текущей популяции.

За счет целенаправленного отбора средняя приспособленность особей должна возрастать от поколения к поколению. Из последнего поколения отбираются *k*-е КП с требуемыми значениями $FFn(k) > FFnm$, где *FFnm* — пороговый уровень приспособленности. Сформировать выборку *MPS* последовательностей нужного объема можно путем многократного запуска поисковой процедуры [17–20].

Исходными данными для алгоритма являются: размер исходной популяции — количество изначально генерируемых КП, *P*; допустимый максимальный уровень положительных боковых лепестков, *PSLp*, и допустимая длина подстроки из одинаковых символов (-1 или +1) внутри КП, *LenMax*.

Предлагаемый алгоритм в виде псевдокода выглядит следующим образом [21]:

```
procedure MakeBestKod
// Алгоритм реализует эвристический поиск бинарных КП
// фиксированной длины с
// требуемым уровнем положительных БЛ апериодической АКФ.
```

```
// Input: N – длина КП, Pslp – требуемый уровень БЛ АКФ,
// NumMax – предельный размер массива КП,
// LenMax – максимальная длина одинаковых символов в КП,
// Nga – предельное количество циклов ГА,
// P – количество особей в популяции
// Output: Mn – массив найденных бинарных КП
Nkod <- 0 // обнуление счетчика найденных КП
Mn <- {} // пустой массив КП
while Nkod < NumMax // основной цикл алгоритма
  M <- PopulationBegin(P,N) // формирование начальной
  // популяции бинарных КП
  for n=1:Nga // цикл генетического алгоритма
    for p=1:P step 2 // цикл перебора особей
      // в популяции
      // кроссовер
      Par1 <- M(p, N) // первая родительская КП
      Par2 <- M(p+1, N) // вторая родительская КП
      r = random(N-1) // случайное место разрыва КП
      child1(Par1(1:r)&Par2(r+1:N)) // формирование КП-потомка 1
      child2(Par2(1:r)&Par1(r+1:N)) // формирование КП-потомка 2
      // мутация
      child1 <- Mutat(child1)
      child2 <- Mutat(child2)
      M <- (child1, child2) // добавить КП-потомки в текущую
      // популяцию
    end for p
    PeakSidelob(M) // вычисление значений PSLp
    // для каждой КП
    M <- Selection(M) // отбор P лучших КП
  end for n
  for k=1:P // выбор КП из последней
  популяции
    if PeakSidelob(M(k)) >= Pslp and NotDubl(M(k), Mn)
      // если k-я КП имеет требуемый уровень БЛ и отсутствует
      // в массиве Mn
      Mn <- M(k) // перенос КП в массив Mn
      Nkod = Nkod + 1
    endif
  end for k
end while
return Mn
```

В качестве примера рассмотрим реализацию ГА для поиска бинарных КП длины $N = 31$ для следующих условий: $PSLp = 2$ ($FFnm > 15$), $LenMax \leq 5$, $P = 50$ и $Nga = 20$. При отсутствии априорной информации начальная популяция КП может быть сформирована путем генерации последовательности псевдослучайных чисел a_i , где $i \in [1, \dots, N]$ по правилу

$$a_i = \begin{cases} +1, & r_i > 0,5 \\ -1, & r_i \leq 0,5 \end{cases}$$

где r_i — псевдослучайное значение из интервала $[0, 1]$.

Рекомбинация КП начальной популяции производится разбиением массива КП на пары с последующим применением к ним оператора одноточечного кроссовера, в котором точка разрыва родительских хромосом выбирается случайно. Например, пара родительских КП представлена в табл. 1, где значения +1 и -1 для более компактного представления заменены знаками «+» и «-» соответственно.

■ Таблица 1. Родительские КП
 ■ Table 1. Parent code sequences

№	A	B	№	A	B	№	A	B
1	+	+	11	+	-	21	-	+
2	+	+	12	+	-	22	+	-
3	+	-	13	+	-	23	-	-
4	+	+	14	-	-	24	-	+
5	+	+	15	-	+	25	+	+
6	-	-	16	+	+	26	+	-
7	-	+	17	+	+	27	-	-
8	-	-	18	+	-	28	+	+
9	-	+	19	+	+	29	+	-
10	-	-	20	+	+	30	+	+
						31	+	-

■ Таблица 3. КП-потомок D после мутации
 ■ Table 3. Code sequence D after mutation

№	E	№	E	№	E
1	+	11	-	21	-
2	+	12	-	22	+
3	-	13	-	23	-
4	+	14	-	24	-
5	+	15	+	25	+
6	-	16	+	26	+
7	+	17	+	27	-
8	-	18	+	28	+
9	+	19	+	29	+
10	-	20	-	30	+
				31	+

Приспособленность родительских КП $FFn(A) = 3,1$, $FFn(B) = 5,2$.

Допустим, что оператор кроссовера генерирует точку разрыва хромосом после 17-го элемента КП, тогда образуются новые дочерние КП (табл. 2), частично наследующие свойства родительских КП.

Приспособленность КП-потомков $FFn(C) = 3,4$, $FFn(D) = 3,9$.


Вторая КП-потомок содержит запрещенную подстроку из шести значений +1 подряд и подвергается точечной мутации (табл. 3).

Приспособленность КП-потомка после мутации $FFn(E) = 5,2$.

Массив КП-родителей и потомков образует расширенную популяцию. Этот массив сортируется по уменьшению значения приспособленности FFn , и первая половина массива переносится в следующее поколение (элитный отбор). Типовой

■ Таблица 2. КП-потомки
 ■ Table 2. Code sequence-childrens

№	C	D	№	C	D	№	C	D
1	+	+	11	+	-	21	+	-
2	+	+	12	+	-	22	-	+
3	+	-	13	+	-	23	-	-
4	+	+	14	-	-	24	+	-
5	+	+	15	-	+	25	+	+
6	-	-	16	+	+	26	-	+
7	-	+	17	+	+	27	-	-
8	-	-	18	-	+	28	+	+
9	-	+	19	+	+	29	-	+
10	-	-	20	+	+	30	+	+
						31	-	+



■ Рис. 4. Изменение средней приспособленности популяции

■ Fig. 4. Change in average fitness-function

график роста средней приспособленности особей от поколения к поколению представлен на рис. 4.

Результаты моделирования

При отборе КП использовались два значения, ограничивающих длину подстроки из одинаковых элементов внутри КП: $LenMax = 4$ и $LenMax = 5$, — в целях экспериментального определения размера массивов КП с разными показателями шумоподобности. Количество циклов поиска составило 10000. В результате было сформировано два массива бинарных КП. Для показателя $LenMax = 4$ найдено 126 КП и для $LenMax = 5$ — 519 КП.

Результаты моделирования показывают, что рост приспособленности популяции завершает-


ся за 10–20 поколений. Из последнего поколения отбираются и заносятся в базу КП со значением $FFn > 15$. В силу локального характера эволюционного поиска за один запуск алгоритма может быть найдено ограниченное количество КП, удовлетворяющих заданным условиям. Для формирования представительного массива КП необходимо запустить несколько циклов эволюционного поиска с разными начальными данными. После каждого цикла поиска в результирующий массив добавляются новые КП, они проверяются на предмет дублирования с уже имеющимися КП. Также дубликатами с одинаковыми значениями FFn считаются КП, полученные из исходной КП инвертированием всех ее символов, и зеркальные КП с обратным порядком символов.

В качестве примера приведены две найденные КП (табл. 4) и соответствующие им АКФ (рис. 5).

■ Таблица 4. Пример оптимальных 31-разрядных КП

■ Table 4. Two optimal 31-bit code sequence

№	F	G	№	F	G	№	F	G
1	-	+	11	+	+	21	-	-
2	+	-	12	+	-	22	-	+
3	-	+	13	+	-	23	+	+
4	-	-	14	-	-	24	+	+
5	-	-	15	+	-	25	-	+
6	+	-	16	-	+	26	+	-
7	+	-	17	+	-	27	+	-
8	+	+	18	+	+	28	-	+
9	-	+	19	+	+	29	-	+
10	+	-	20	+	+	30	-	-
						31	-	-



■ Рис. 5. АКФ кодовых последовательностей F и G

■ Fig. 5. ACF code sequences F and G

При формировании радиолокационных сигналов, модулированных бинарными КП, важно придать им шумоподобный характер для обеспечения скрытности работы РЛС [22]. К шумоподобным относятся серии сигналов, отвечающие следующим основным требованиям [8]:

— кодовые последовательности, используемые для формирования сигналов, должны быть уравновешенными, т. е. появление любого символа в КП должно быть равновероятным ($P(\langle 1 \rangle) = P(\langle -1 \rangle)$);

— АКФ КП должна быть близка к дельта-функции;

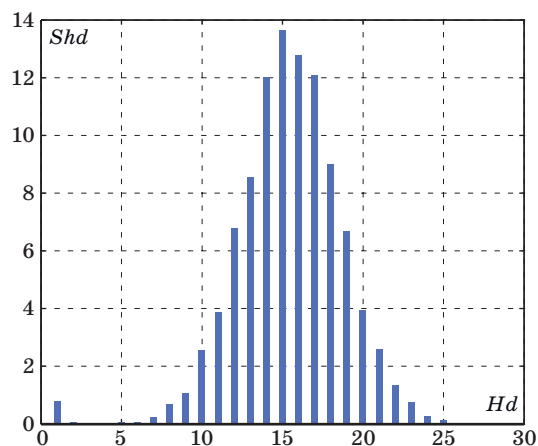
— вероятность появления строки из n символов в КП должна быть обратно пропорциональна длине строки;

— значения функции кросс-корреляции пары КП, входящих в шумоподобный ансамбль, должны быть минимизированы.

Таким образом, при формировании шумоподобной серии нужно обеспечить случайный выбор КП из массива, причем следующая КП должна существенно отличаться от предыдущей. Степень различия двух бинарных КП i и j характеризуется расстоянием Хемминга — $Hd(i, j)$. На рис. 6 представлена гистограмма распределения количества (Shd) каждого из значений $Hd(i, j)$, полученных при попарном сравнении 126 КП из массива.

Очередная КП выбирается в массиве случайным образом из списка КП, удовлетворяющих условию $Hd(i, j) > Hmax$, где $Hmax$ — пороговое значение хеммингова расстояния между предыдущей КП i и следующей КП j . Значение $Hmax$ выбирается на основе анализа гистограммы рис. 6 и требуемой длины серии.

Алгоритм формирования шумоподобной серии КП в виде псевдокода выглядит следующим образом:



■ Рис. 6. Распределение значений $Hd(i, j)$ в массиве КП

■ Fig. 6. Distribution of values $Hd(i, j)$ an array code sequences


```

procedure FormKP
// Алгоритм формирует шумоподобную серию из массива
// бинарных КП
// Input: массив КП в табличной форме: (id_кп – номер КП, Mn –
// бинарная КП)
// Output: KP – очередность КП, образующих серию

P=len(Mn) // количество КП в исходном массиве
Hd(P, P) = {} // обнуление двумерного массива расстояний
// по Хеммингу
for i=1:P for j=1:P
    Hd(i, j)=Hamming(Mn(i), Mn(j)) // двумерный массив
// расстояний по Хеммингу между парами КП (i, j)
end end
KPh={} // вспомогательный массив
for i=1:P for j=1:P
if Hd(i, j)>Hmax
KPh=KPh+(Mn(i), Mn(j), n=0) // массив пар КП (i, j),
// различающихся по Хеммингу на величину большую, чем Hmax
end end
L=len(KPh) // количество пар в массиве
k1=rand*L // случайный выбор первой КП
k2=KPh(k1,2) // номер следующей КП
for k=1:L
    k1= find(KPh(j)==k2 & KPh(i)<>k1 & KPh(n)=0); // поиск
// не использованных ранее строк в массиве пар КП
    s=len(k1) // количество пар КП, удовлетворяющих
// условию поиска
    k1=k1(rand*s) // случайный выбор номера пары
    KP=KP +KPh(k1) // добавление найденной КП
// в формируемый массив KP
    KPh(n)=KPh(n)+1 // увеличение счетчика использований
// выбранной КП
    k2=KPh(k1,2) // номер следующей КП в паре
end
return KP
    
```

Результат применения алгоритма для формирования шумоподобной серии из 800 сигналов из исходного массива в 126 КП при $Hmax = 20$ проиллюстрирован на рис. 7. Для каждой КП (i) показано, сколько раз (S) она выбиралась алгоритмом в процессе формирования серии.

Сравнительные параметры шумоподобности серии сигналов, образованной m -последователь-



■ Рис. 7. Серия из 800 сигналов
 ■ Fig. 7. Series of 800 signals

■ Таблица 5. Сравнительные характеристики шумоподобных серий
 ■ Table 5. Comparative characteristics pseudorandom noise series

Параметр	m -последовательность	Предлагаемый алгоритм
Мощность массива КП	90	>126
Уравновешенность (вероятность появления символа в КП)	$P(\llcorner-1\lrcorner) = 0,516$ $P(\llcorner1\lrcorner) = 0,484$	$P(\llcorner-1\lrcorner) = 0,499$ $P(\llcorner1\lrcorner) = 0,501$
Значения $PSLp$ КП	6–3	2
Среднее значение БЛ функции кросс-корреляции	25	10

ностью и предлагаемым алгоритмом из КП длины $N = 31$, приведены в табл. 5. Последовательность Лежандра для $N = 31$ существует в единственном числе и поэтому не может быть использована для формирования серии сигналов.

Заключение

В статье предложен алгоритм формирования массива бинарных КП, отвечающих требованиям, предъявляемым к максимальным значениям БЛ их апериодической АКФ. Рассматриваемый подход имеет ряд преимуществ по сравнению с известными алгоритмическими способами формирования бинарных КП, таких как m -последовательности и последовательности Лежандра. Предлагаемый алгоритм позволяет получить массив КП большей мощности с меньшими значениями БЛ апериодической АКФ. Серия зондирующих сигналов, сформированная предлагаемым алгоритмом, имеет лучшие характеристики шумоподобности по сравнению с серией m -последовательностей. Алгоритм целесообразно использовать в некоторых режимах функционирования радиолокационных систем летательных аппаратов для обнаружения объектов на фоне подстилающей поверхности.

Литература

1. Levanon N., Mozeson E. *Radar Signals*. Chichester, John Wiley& Sons, 2005. 411 p.
2. Сергеев М. Б., Ненашев В. А., Сергеев А. М. Вложенные кодовые конструкции Баркера — Мерсенна — Рагхаварао. *Информационно-управляющие*

- системы, 2019, № 3, с. 71–81. doi:10.31799/1684-8853-2019-3-71-81
3. **Чепруков Ю. В., Соколов М. А.** Квазидополнительные бинарные кодовые последовательности. *Информационно-управляющие системы*, 2016, № 3, с. 72–78. doi:10.15217/issn1684-8853.2016.3.72
 4. **Ипатов В. П.** Широкополосные системы и кодовое разделение сигналов. *Принципы и приложения*. М., Техносфера, 2007. 486 с.
 5. **Хасанов М. С., Курганов В. В.** Методы определения коэффициентов квазиоптимального КИХ-фильтра свертки псевдослучайной бинарной последовательности. Проблемы разработки перспективных микро- и наноэлектронных систем — 2014: сб. тр. / под общ. ред. акад. РАН А. Л. Стемпковского. М., ИППМ РАН, 2014. Ч. IV. С. 133–136. <http://www.mes-conference.ru/data/year2014/pdf/d145.pdf> (дата обращения: 28.08.2019).
 6. **Леухин А. Н., Шувалов А. С.** Аналитический подход к решению задачи синтеза импульсных последовательностей. http://www.mivlgu.ru/section1/3-Leuhin_Shuvailov.pdf (дата обращения: 28.08.2019).
 7. **Потехин Е. Н., Леухин А. Н.** Методы оптимизации задачи полного поиска бинарных аperiodических оптимальных последовательностей. *Программные системы и вычислительные методы*, 2013, № 2, с. 192–198. doi: 10.7256/2305-6061.2013.2.7600
 8. **Гантмахер В. Е., Быстров Н. Е., Чеботарев Д. В.** Шумоподобные сигналы. Анализ, синтез, обработка. СПб., Наука и техника, 2005. 400 с.
 9. **Skolnik M.** Radar handbook. 3rd edition. Mc Graw-Hill, 2008. 1352 p.
 10. **Cook C., Bernfeld V.** Radar signals. An introduction to theory and application. Academic Press, 1967. 568 p.
 11. **Шаров С. Н., Соловьева В. В.** Особенности использования бинарного квантования по времени и бинарного фазового детектора для синтеза и обработки сложных радиолокационных сигналов. *Морская радиоэлектроника*, 2018, № 3(65), с. 48–53.
 12. **Михайлов В. Н.** Эвристические алгоритмы синтеза сигналов с малыми боковыми лепестками автокорреляционной функции. «Цели развития тысячелетия и инновационные принципы устойчивого развития арктических регионов»: материалы международного конгресса. Т. 1. Научно-практическая конференция «Наукоемкие и инновационные технологии в решении проблем прогнозирования и предотвращения чрезвычайных ситуаций и их последствий», Санкт-Петербург, 12–13 ноября 2010 г., СПб., 2010, с. 92–95. Arcticas.ru/docs/kongress_tisyacheletie2010_tom1.pdf (дата обращения: 12.09.2019).
 13. **Ali W. T.** Detraction the clutter for the best binary phase codes that begot by genetic algorithm using wiener filter. *European Journal of Engineering Research and Science (EJERS)*, 2016, vol. 1, no. 1, pp. 9–14.
 14. **Lellouch G., Mishra A. K., Inggs M.** Design of OFDM radar pulses using genetic algorithm based techniques. *IEEE Transaction on Aerospace and Electronic Systems*, 2016, vol. 52, iss. 4, pp. 1953–1966. doi:10.1109/TAES.2016.140671
 15. **Purna Chandra Rao E. N. V., Singh S. P.** One twenty phase code design for radar. *International Journal of Advanced Computer Research*, 2013, vol. 3, iss. 13, no. 4, pp. 230–235.
 16. **Brest J., Boskovic B.** A heuristic algorithm for a low autocorrelation binary sequence problem with odd length and high merit factor. *IEEE Access*, 2018, vol. 6, pp. 4127–4134. doi:10.1109/ACCESS.2018.2789916
 17. **Song J., Babu P., Palomar D. P.** Optimization methods for designing sequences with low autocorrelation sidelobes. *IEEE Transaction Signal Process*, 2015, vol. 63, no. 15, pp. 3998–4009.
 18. **Mow W. H., Du K. L., Wu W. H.** New evolutionary search for long low autocorrelation binary sequences. *IEEE Transaction on Aerospace and Electronic, syst.* 51(1), pp. 290–303.
 19. **Biskin O. T., Akay O.** Design of sequences with low autocorrelation sidelobes using genetic algorithms. *10th International Conference on Electrical and Electronics Engineering (ELECO)*, 2017. ieeexplore.ieee.org/document/8266285 (дата обращения: 12.09.2019).
 20. **Yankevych R., Prudyus I., Miskiv V. M.** Use of genetic algorithm for optimal codes search. *IEEE 15th International Conference on the Experience of Designing and Application of CAD Systems (CADSM)*, 2019. doi:10.1109/CADSM.2019.8779239
 21. **Толмачев С. Г., Шаров С. Н., Соловьева В. В.** Программа формирования массива кодов бинарного квантования произвольной длины с заданным уровнем «боковых лепестков»: свидетельство о государственной регистрации в Реестре программ для ЭВМ. Заявка № 2019617108 от 14 июня 2019 г. Дата гос. регистрации 02.07.2019 г.
 22. **Савельев С. В., Морозова Л. А.** Метод построения хаотических бинарных кодов: сб. тр. II Всероссийской научной конференции по проблемам радиофизики и дистанционного зондирования сред, 2018, Муром, с. 637–641.

UDC 681.391.83

doi:10.31799/1684-8853-2020-1-44-53

Search for binary code sequences with low autocorrelation sidelobes by the evolutionary method

S. N. Sharov^a, Dr. Sc., Tech., Professor, orcid.org/0000-0002-9634-155XS. G. Tolmachev^a, PhD, Tech., orcid.org/0000-0001-9434-1268, tsg17@yandex.ru^aJoint Stock Company «Concern «Granit-Electron», 3, Gospitalnaia St., 191014, Saint-Petersburg, Russian Federation

Introduction: The parameters chosen for complex coded signals used in active radar systems of aircraft for detecting objects largely determines their qualitative characteristics and the possibility of covert operation. An important task in the design of such on-board systems is the formation of ensembles of pseudorandom-noise binary code sequences of a fixed length with predefined characteristics. **Purpose:** Search for PRN binary code sequences of a given length, optimal by the criterion of the minimum level of the sidelobes of the aperiodic autocorrelation function. **Results:** A procedure of search for binary code sequences with specified parameters based on the evolutionary approach is proposed. The minimum level of positive sidelobes of the autocorrelation function is used as a criterion for the selection of code sequences. An additional restriction is imposed on the length of a substring of codes of the same character. The possibility of forming a representative array of sequences with the best ratio of the main peak of the aperiodic autocorrelation function to its maximum positive sidelobe is shown on the example of 31-bit code sequences. An algorithm is proposed for generating a PRN series of signals using the code sequences found. The Hamming distance is used as a measure of the difference between two binary code sequences in the series. The proposed approach is advantageous as compared to the well-known method of generating PRN signals based on pseudorandom m-sequences. **Practical relevance:** The results obtained can be used in algorithms of airborne radar systems with a high range resolution to detect physical objects on the background of an underlying surface, for example, objects on the water surface.

Keywords — code sequence, sidelobe, autocorrelation function, genetic algorithm, recombination, selection.

For citation: Sharov S. N., Tolmachev S. G. Search for binary code sequences with low autocorrelation sidelobes by the evolutionary method. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 44–53 (In Russian). doi:10.31799/1684-8853-2020-1-44-53

References

- Levanon N., Mozeson E. *Radar Signals*. John Wiley & Sons, Chichester, 2005. 411 p.
- Sergeev M. B., Nenashev V. A., Sergeev A. M. Nested code sequences of Barker — Mersenne — Raghavarao. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2019, no. 3, pp. 71–81 (In Russian). doi:10.31799/1684-8853-2019-3-71-81
- Cheprukov Yu. V., Socolov M. A. Quasiadditional binary code sequences. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2016, no. 3, pp. 72–78 (In Russian). doi:10.15217/issn1684-8853.2016.3.72
- Ipatov V. P. *Shirokopolosnye sistemy i kodovoe razdelenie signalov. Principy i prilozheniya* [Broadband systems and code division of signals. Principles and applications]. Moscow, Technosfera Publ., 2007. 486 p. (In Russian).
- Khasanov M. S., Kurganov V. V. *Metody opredeleniya koefitsientov kvazioptimal'nogo KIH-fil'tra svertki psevdosluchajnoj binarnoj posledovatel'nosti*. In: *Problemy razrabotki perspektivnykh mikro- i nanoelektronnykh sistem — 2014* [Methods of determination the coefficients of quasi-optimal FIR-filter for convolution of pseudorandom binary sequence. In: Collection of Proceedings “Problems of perspective micro- and nanoelectronic systems development — 2014”]. Edited by A. Stempkovsky, Moscow, IPPM RAN Publ., 2014. Part 4. Pp. 133–136 (In Russian).
- Leukhin A. N., Chuvalov A. S. Analiticheskij podhod k resheniyu zadachi sinteza impul'snyh posledovatel'nostej [Analytical approach to solving the problem of pulse sequences synthesis]. Available at: http://www.mivlgu.ru/section1/3-Leuhin_Shuvalov.pdf (accessed: 28 August 2019).
- Potekhin E. N., Leukhin A. N. Optimization methods for the complete search problem for binary aperiodic optimal sequences. *Software Systems and Computational Methods*, 2013, no. 2, pp. 192–198 (In Russian). doi:10.7256/2305-6061.2013.2.7600
- Gantmakher V. E., Bistrov N. E., Chebotarev D. V. *Chumopodobnye signali. Analiz, sintez, obrabotka* [Pseudorandom noise signals. Analysis, synthesis, processing]. Saint-Petersburg, Nauka i tehnika Publ., 2005. 400 p. (In Russian).
- Skolnik M. *Radar handbook*. 3rd edition. Mc Graw-Hill, 2008. 1352 p.
- Cook C., Bernfeld V. *Radar signals. An introduction to theory and application*. Academic Press, 1967. 568 p.
- Sharov S. N., Soloveva V. V. And processing binary time quantization and binary phase detector: effects for waveform radar signal synthesis. *Marine Radio electronics*, 2018, no. 3(65), pp. 48–53 (In Russian).
- Mikhailov V. N. Heuristic algorithms for signal synthesis with small sidelobe of autocorrelation function. *Trudy III Mezhdunarodnogo kongressa “Tseli razvitiia tsiyacheletii” i innovatsionnye printsipy ustoychivogo razvitiia arkticheskikh regionov. Tom 1 “Naukoemkie i innovatsionnye tehnologii v rechenii problem prognozirovaniia i predotvrachenii chrezvychaynykh situatsii i ikh posledstviia”* [Proceedings of the International Congress “Millennium Development Goals” and innovative principles of sustainable development of the Arctic regions”. Vol. 1. Scientific-Practical Conference “High-tech and innovative technologies in solving the problems of forecasting and prevention of emergency situations and their consequences”]. Saint-Petersburg, 2010, pp. 92–95 (In Russian). Available at: arcticas.ru/docs/Kongress_tsiyacheletie2010_tom1.pdf (accessed 12 September 2019).
- Ali W. T. Detraction the clutter for the best binary phase codes that begot by genetic algorithm using wiener filter. *European Journal of Engineering Research and Science (EJERS)*, 2016, vol. 1, no. 1, pp. 9–14.
- Lellouch G., Mishra A. K., Inggs M. Design of OFDM radar pulses using genetic algorithm based techniques. *IEEE Transaction on Aerospace and Electronic Systems*, 2016, vol. 52, iss. 4, pp. 1953–1966. doi:10.1109/TAES.2016.140671
- Purna Chandra Rao E. N. V., Singh S. P. One twenty phase code design for radar. *International Journal of Advanced Computer Research*, 2013, vol. 3, no. 4, iss. 13, pp. 230–235.
- Brest J., Boskovic B. A heuristic algorithm for a low autocorrelation binary sequence problem with odd length and high merit factor. *IEEE Access*, 2018, vol. 6, pp. 4127–4134. doi:10.1109/ACCESS.2018.2789916
- Song J., Babu P., Palomar D. P. Optimization methods for designing sequences with low autocorrelation sidelobes. *IEEE Transaction Signal Process*, 2015, vol. 63, no. 15, pp. 3998–4009.
- Mow W. H., Du K. L., Wu W. H. New evolutionary search for long low autocorrelation binary sequences. *IEEE Transaction on Aerospace and Electronic*, 2015, syst. 51(1), pp. 290–303.
- Biskin O. T., Akay O. Design of sequences with low autocorrelation sidelobes using genetic algorithms. *10th Interna-*

- tional Conference on Electrical and Electronics Engineering (ELECO)*, 2017. Available at: ieeexplore.ieee.org/document/8266285 (accessed 12 September 2019).
20. Yankevych R., Prudyus I., Miskiv V. M. Use of genetic algorithm for optimal codes search. *IEEE 15th International Conference on the Experience of Designing and Application of CAD Systems (CADSM)*, 2019. doi:10.1109/CADSM.2019.8779239
 21. Tolmachev S. G., Sharov S. N., Soloveva V. V. Program of formation of an array of binary quantization codes of arbitrary length with a given level of “sidelobes”. Certificate of state registration in the Register of computer programs. Application No. 2019617108 June 14, 2019. Date of state registration 02.07.2019.
 22. Savelyev S. V., Morozova L. A. Method of construction of chaotic binary codes. *Trudy II Vserossijskoj nauchnoj konferencii po problemam radiofiziki i distancionnogo zondirovaniya sred* [Proceedings of the II All-Russian Scientific Conference on Radiophysics and Remote Sensing of Environments], 2018, Murom, pp. 637–641.

ПАМЯТКА ДЛЯ АВТОРОВ

Поступающие в редакцию статьи проходят обязательное рецензирование.

При наличии положительной рецензии статья рассматривается редакционной коллегией. Принятая в печать статья направляется автору для согласования редакторских правок. После согласования автор представляет в редакцию окончательный вариант текста статьи.

Процедуры согласования текста статьи могут осуществляться как непосредственно в редакции, так и по e-mail (ius.spb@gmail.com).

При отклонении статьи редакция представляет автору мотивированное заключение и рецензию, при необходимости доработать статью — рецензию.

Редакция журнала напоминает, что ответственность за достоверность и точность рекламных материалов несут рекламодатели.

UDC 621.371

doi:10.31799/1684-8853-2020-1-54-62

Analysis of total signal decay and capacity of information data in wireless atmospheric communication links. Part 2

Juwiler I.^a, PhD, Senior Lecturer, orcid.org/0000-0002-0669-7828

Bronfman I.^a, Assistant, orcid.org/0000-0001-6195-069X

Blaunstein N.^b, Dr. Sc., Phys.-Math., Professor, orcid.org/0000-0003-2945-9379,
nathan.blaunstein@hotmail.com

^aElectrical and Electronics Engineering Department, Shamoon College of Engineering, Jabotinsky St., 84, Ashdod, 77245, Israel

^bBen-Gurion University of the Negev, P.O.B. 653, 1, Ben-Gurion St., Beer-Sheva, 74105, Israel

Introduction: Analysis of total signal decay is based on prognosis of the total path loss occurring in the atmospheric communication links, accounting for effects of gaseous structures attenuation and scattering, hydrometeors (rain, snow and clouds) absorption and attenuation, and turbulent structures fast fading on radio and optical signals passing atmospheric channels with fading. **Purpose:** To perform a novel methodology of definition and estimation of effects of decay, absorption, scattering, and fading of radio and optical signals propagating in atmospheric channels in various meteorological conditions. **Results:** Was analyzed the impact of gaseous structures, hydrometeors and turbulent structures in total path loss for link budget design and in degradation of data stream parameters, such as capacity, spectral efficiency and bit-error-rate, which lead in loss of information data signals passing such kinds of channels with fast fading and decrease of quality of service. An optimal algorithm was found of the total path loss prediction for various meteorological situations occurring in the real atmosphere at different heights and for various frequencies of radiated signals. A method was proposed of how to evaluate the data stream parameters, capacity, spectral efficiency and bit-error-rate, accounting for the effects of atmospheric turbulence impact on fast fading, which corrupts information passing such kinds of channels. All practical tests were illustrated by the use of the MATLAB utility. A new methodology was proposed on how to evaluate and estimate the capacity, the spectral efficiency, and the loss in energy and in the information data stream for different scenarios of radio and optical signals propagation via atmospheric channels with fading caused by different meteorological conditions. **Practical relevance:** The results obtained allow to achieve better accuracy of prognosis and increase quality of service in atmospheric communication channels.

Keywords – absorption, attenuation, bit-error rate, capacity, clouds, fast fading, gaseous structures, hydrometeors, rain, Ricean factor K , snow, scintillation index, spectral efficiency, turbulence.

For citation: Juwiler I., Bronfman I., Blaunstein N. Analysis of total signal decay and capacity of information data in wireless atmospheric communication links. Part 2. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 54–62. doi:10.31799/1684-8853-2020-1-54-62

Ending.

Start in *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2019, no. 6, pp. 43–53,
doi:10.31799/1684-8853-2019-6-43-53

Total path loss in atmospheric communication links

Path loss in free space

The path loss defined as the ratio or logarithmic difference between the amplitudes, $P(r)$, or intensity (power), $P(r)$, at any two different points r_1 and r_2 , the transmitter point and receiver point accordingly. It is usually expressed in decibels [dB] and denoted by L [3]:

$$L = 10 \log \left(\frac{P(r_2)}{P(r_1)} \right) = 10 \log \frac{A^2(r_2)}{A^2(r_1)}. \quad (45)$$

For non-isotropic sources (antenna, laser) placed in the free space the path loss is given by

$$L = 10 \log \frac{P_T}{P_R} = 10 \log \left[\left(\frac{4\pi r}{\lambda} \right)^2 / G_T G_R \right], \quad (46)$$

where P_T and P_R are the power, W, of the transmitter and the receiver which have directivity gain of G_T , G_R , respectively; r is distance, km. From (46) yields

$$L = L_0 + 10 \log \left[\frac{1}{G_T G_R} \right]. \quad (47)$$

Here L_0 is the path loss of isotropic point source ($G_T = G_R = 1$) in free space and can be presented in decibels as

$$\begin{aligned} L_0 &= 10 \log \left(\frac{4\pi f r}{c} \right)^2 = 20 \log \left(\frac{4\pi f r}{c} \right) = \\ &= 32.44 + 20 \log(r) + 20 \log(f), \end{aligned} \quad (48)$$

where f — frequency, MHz.

All the above formulas are related to the well-known Friis formula discussed in [3, 4]. As of now we can obtain the path loss between two directive

antennas (receiver and transmitter) located in free space (FS) as

$$L_{FS} = 32.44 + 20\log(r) + 20\log(f) - 10\log(G_T) - 10\log(G_R). \quad (49)$$

Fading effects estimation

Usually, fading effects can be estimated by use of K -parameter of fading as an additional contribution to LOS, accounting the multipath effect on signal components:

$$K = \frac{\text{LOS-component power}}{\text{Multipath-component power}}. \quad (50)$$

The most comprehensive distribution to describe the fast fading effects is the Ricean distribution because it includes both line-of-sight (LOS) together with scattering and diffraction with non-line-of-sight (NLOS) and is defined as [4]

$$PDF(r) = \frac{r}{\sigma^2} \exp\left[-\frac{(r^2 + A^2)}{2\sigma^2}\right] I_0\left(\frac{Ar}{\sigma^2}\right), \quad A > 0, r \geq 0, \quad (51)$$

where A is the peak strength; σ is standard deviation of the signal envelope; I_0 is the modified Bessel function of the first kind and zero order. Using (50) and (51), the distribution function in decibels can be derived. The signal deviation from the mean on a dB-scale can be calculated using the following equation:

$$y = 20\log(r/A). \quad (52)$$

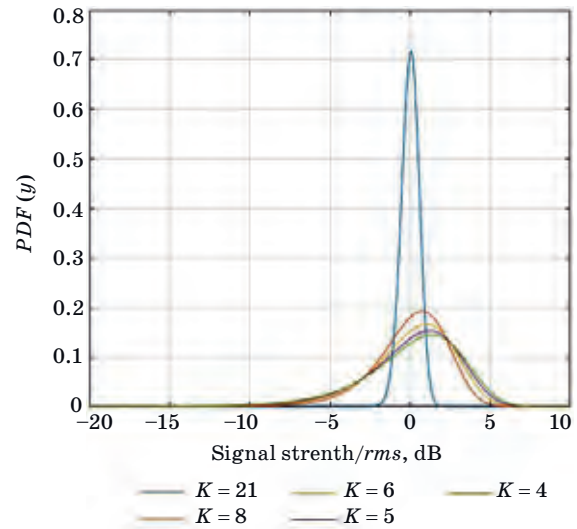
The resulting probability density function (PDF) of y is given by

$$PDF(y) = 2K \ln 10 \frac{10^{2y/20}}{20} \times e^{(-2K(10^{2y/20} + 1))} I_0(2K \cdot 10^{y/10}). \quad (53)$$

Figure 11 shows the $PDF(y)$ for various values of K for various fluctuations. When $K \rightarrow \infty$ the Rician distribution fading approaches a Gaussian one, producing “Dirac-delta function”, while for $K \rightarrow 0$, the worst scenario of the fading channel is described by Rayleigh PDF.

For our computations, the smallest K that had been calculated was approximately 4 and the largest was approximately 121. The fast fading loss was calculated from Fig. 11 by comparing the signal strength [dB] of the maximum value of the PDF:

$$y[\text{dB}] = 10\log\left(\frac{L_{FF}}{rms}\right) [\text{dB}], \quad (54)$$



■ Fig. 11. PDF distribution versus signal to rms [dB] for values of Ricean parameter K of fading

while the rms is equal $\sqrt{2}\sigma$, so the fast fading loss (L_{FF}) is equal to

$$L_{FF} = y + 10\log(rms) [\text{dB}]. \quad (55)$$

Link budget design

The total path loss is difficult to be measured directly, since various losses and gains in the radio system also need to be considered. These are best accounted for by constructing a *link budget*, which is usually the first step in the analysis of a wireless communication system [9]. The link budget is the calculation of signal power, noise powers and/or signal-to-noise ratios (SNR) for a complete communication system or links.

Link budget is simply the maximum acceptable path loss and is usually split into two components, one of which is given by the distance-dependent path loss model plus a fade margin, which is included to allow the system some resilience against the practical effects of signal fading beyond the value predicted by the model:

$$\begin{aligned} &\text{Maximum acceptable propagation loss} = \\ &= \text{Predicted loss} + \text{Fade margin} [\text{dB}]. \end{aligned} \quad (56)$$

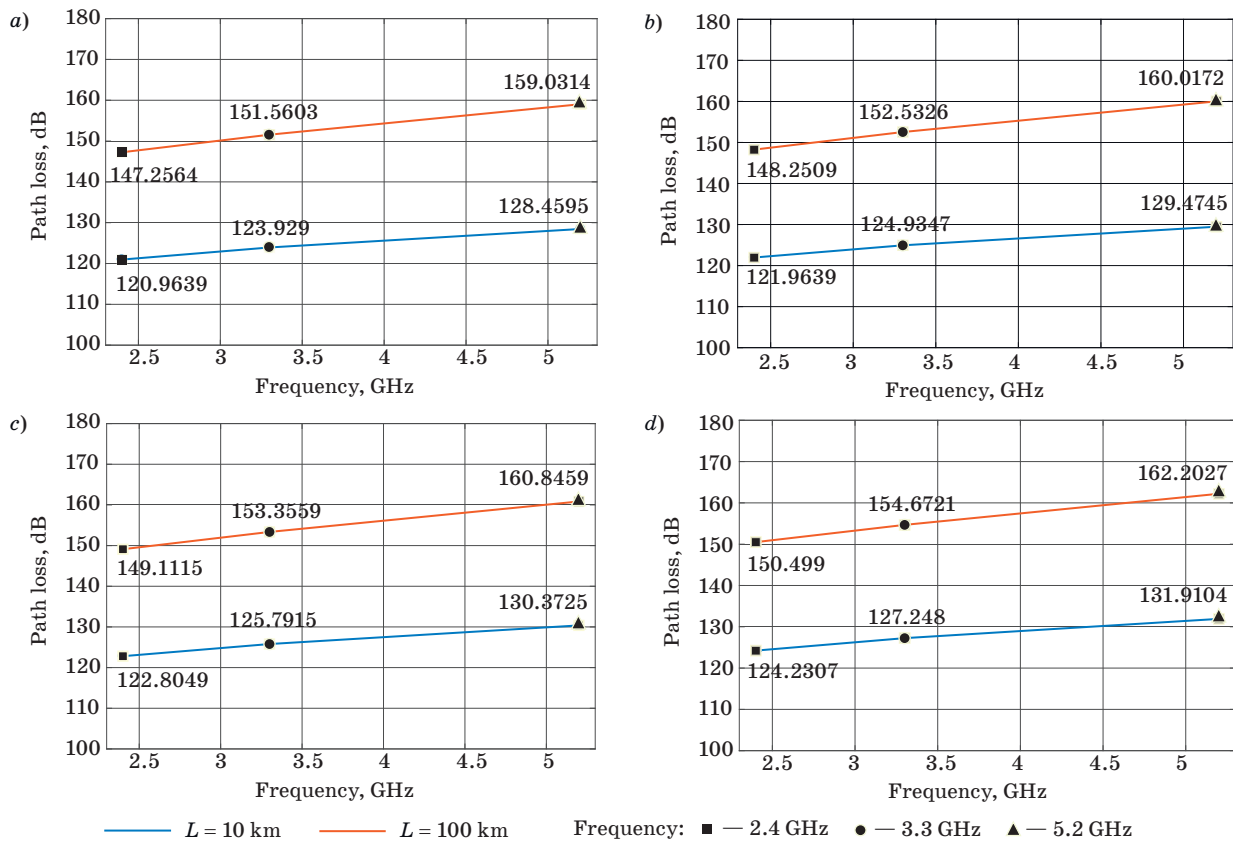
For the tropospheric link the total link budget is the sum of all the predicted losses such as the transmission line loss and the attenuation from the hydrometeors such as rain, clouds and fog. Included in this are the factors of fast fading caused by atmospheric turbulence and multipath phenomena caused by diffuse scattering. Finally, subtracting from this the gains of the antennas G_1 and G_2 , the link budget can be given as

■ **Table 1.** Budget line in the troposphere at $L = 10$ km

Parameter, dB	Link budget in the troposphere for f														
	2.4 GHz					3.3 GHz					5.2 GHz				
	at the height of aircraft antennas, km														
	1	5	7	10	1	5	7	10	1	5	7	10			
Free space loss	120.0952	121.0211	121.7839	123.0623	122.8613	123.7872	124.55	125.8284	126.8111	127.7369	128.4997	129.7781			
Cloud loss	0.0175	0.0039	0.003	0.0025	0.033	0.0073	0.0057	0.0046	0.082	0.0182	0.0142	0.0115			
Molecular loss	0.0727	0.0809	0.0883	0.1023	0.0781	0.0869	0.0949	0.1099	0.0908	0.101	0.1103	0.1278			
Rain loss	0.0238	0.0258	0.0277	0.0314	0.0478	0.0512	0.0548	0.0621	0.2907	0.3119	0.3323	0.3725			
Fast fading (turbulence weak)	0.0014	0.00154	0.00167	0.00191	0.00168	0.00185	0.00201	0.0023	0.00219	0.00242	0.00262	0.003			
Fast fading (turbulence moderate)	0.31204	0.34407	0.37291	0.42678	0.37574	0.41431	0.44904	0.5139	0.48988	0.54016	0.58544	0.67001			
Fast fading (turbulence strong)	0.44129	0.48659	0.52737	0.60355	0.53137	0.58592	0.63503	0.72676	0.69279	0.7639	0.82794	0.94753			
Total path loss	120.9639	121.9639	122.8049	124.2307	123.929	124.9347	125.7915	127.248	128.4595	129.4745	130.3725	131.9104			

■ **Table 2.** Budget line in the troposphere at $L = 100$ km

Parameter, dB	Link budget in the troposphere for f														
	2.4 GHz					3.3 GHz					5.2 GHz				
	at the height of aircraft antennas, km														
	1	5	7	10	1	5	7	10	1	5	7	10			
Free space loss	140.0952	141.0211	141.7839	143.0623	142.8613	143.7872	144.55	145.8284	146.8111	147.7369	148.4997	149.7781			
Cloud loss	0.1739	0.2348	0.3249	0.4175	0.3287	0.3658	0.4171	0.4352	0.8156	0.8633	0.9168	0.9823			
Molecular loss	0.7232	0.724	0.7249	0.7268	0.7771	0.7781	0.779	0.781	0.9034	0.9045	0.9056	0.9079			
Rain loss	0.0626	0.0627	0.0627	0.0629	0.1258	0.1259	0.126	0.1262	0.7654	0.766	0.7666	0.7678			
Fast fading (turbulence weak)	0.0115	0.0115	0.0115	0.0115	0.0138	0.0138	0.0138	0.0139	0.018	0.018	0.018	0.018			
Fast fading (turbulence moderate)	2.564	2.5668	2.5696	2.5756	3.0874	3.0908	3.0942	3.1014	4.0253	4.0297	4.0341	4.0435			
Fast fading (turbulence strong)	3.626	3.63	3.634	3.6424	4.3662	4.371	4.3758	4.386	5.6926	5.6988	5.7051	5.7051			
Total path loss	147.2564	148.2509	149.1115	150.499	151.5603	152.5326	153.3559	154.6721	159.0314	160.0172	160.8459	162.2027			



■ Fig. 12. Total path loss versus frequency for several ranges between the antennas: a — $h = 1$ km; b — $h = 5$ km; c — $h = 7$ km; d — $h = 10$ km

$$L_{total} = \bar{L} + L_{SF} + L_{FF} + \frac{S}{N_0} - G_T - G_R, \quad (57)$$

where L_{SF} — slow fading loss due to diffraction of clouds; L_{FF} — fast fading loss due to effects of turbulence caused by scattering; $\frac{S}{N_0}$ — SNR of the

Gaussian noise channel; \bar{L} is the average path loss and is equal to the sum of free space attenuation and NLOS condition attenuation, that is

$$\bar{L} = L_{FS} + L_{NLOS}. \quad (58)$$

Here L_{FS} — free space path loss; L_{NLOS} — attenuation of hydrometeors such as rain, snow and clouds.

As examples on how to design link budget for atmospheric communication links, we will build our link budget for aircraft height of 1, 5, 7 and 10 km, for three frequencies, $f = (2.4, 3.3, 5.2)$ GHz, corresponding to what is usually used in 4th generation Wi-Fi Technology. In the Tables 1, 2 we will conclude all the losses from hydrometeors, turbulence and free space. The gains of the transmission antenna and the aircraft antenna [dB] will be described as G_1 and G_2 , L is the horizontal distance.

In Figs. 12, a–d we examine the link budget for aircraft height antenna of 1, 5, 7 and 10 km for distance L equal to 10 and 100 km.

As follows from Fig. 12, the computations carried out for the specific case correspond with the information presented by in Tables 1, 2. For aircraft height antenna of 5 km for distance $L = 10$ km, the path loss exceeds 121.9639, 124.9347 and 129.4745 dB for frequencies of 2.4, 3.3 and 5.2 GHz respectively.

Effects of turbulence on signal data passing atmospheric communication links

Characteristics of information signal data in atmospheric communication links

According to the classical approach, the *capacity* of the channel with Additive White Gaussian Noise (AWGN) of bandwidth B_w is based on the Shannon — Hartley formula, which defines the relationship between the maximum data rate via any channel, called the capacity, the bandwidth B_w [Hz], and the signal-to-noise ratio (SNR $\equiv N_{add}$) (see also [4, 5]):

$$C = B_w \log_2 \left[1 + \frac{S}{N_0 B_w} \right], \quad (59)$$

where in our notations, the power of additive noise in the AWGN channel is $N_{add} = N_0 B_w$, whereas S is the signal power, and N_0 is the signal power spectrum, W/Hz.

According to [3–5], SNR equals the ratio between the signal power measured at the input of the receiver, P_R , and its inner white noise N_R :

$$SNR = 10 \log_{10} \left(\frac{P_R}{N_R} \right) = P_R - N_R \text{ [dB]}. \quad (60)$$

Usually, in radio and optical communication, another characteristic, called the *spectral efficiency*, is utilized:

$$\tilde{C} = \frac{C}{B_w} = \log_2 \left[1 + \frac{S}{N_0 B_w} \right]. \quad (61)$$

Based on the second approach (called the *approximate* [4, 5], accounting for the fading phenomena, flat or multi-selective, we can now introduce in (61) the multiplicative noise by introducing the Ricean K -factor of fading, defined above, as the ratio of the coherent and multipath (incoherent) components of signal intensity, that is, $K = I_{co}/I_{inc}$, or following special definitions made in [4–6], $K = S/N_{mult}$. Using these notations, we finally get the capacity as a function of the K -factor and the signal to additive noise ratio (SNR_{add}):

$$\begin{aligned} C &= B_w \log_2 \left(1 + \left(SNR_{add}^{-1} + K^{-1} \right)^{-1} \right) = \\ &= B_w \log_2 \left(1 + \frac{K \cdot SNR_{add}}{K + SNR_{add}} \right). \end{aligned} \quad (62)$$

Consequently, it is easy to obtain from (62) the spectral efficiency of the channel with fading as a source of multiplicative noise:

$$\tilde{C} = \frac{C}{B_w} = \log_2 \left(1 + \frac{K \cdot SNR_{add}}{K + SNR_{add}} \right), \quad (63)$$

where the bandwidth B_w changes according to the system under investigation. In a comparison, made in [4, 6], between the two approaches, classical and approximate, it was shown that formulas (61) with $N_{add} = N_0 B_w$ and (63), are the same description of the channel/system capacity, when the K -factor is larger than SNR_{add}.

Finally, we can relate the strength of the scintillation introduced above (called the *scintillation index*), with the K -factor of fading. In expression (44), we presented this characteristic, following [4–6], for zero-mean random process. For the convenience of understanding the subject, we present this relation again:

$$\langle \sigma_I^2 \rangle = \frac{\langle [I - \langle I \rangle]^2 \rangle}{\langle I \rangle^2} = \frac{I_{inc}^2}{I_{co}^2} \equiv K^{-2}. \quad (64)$$

Dependence of K -factor of fading versus the signal intensity scintillation σ_I^2 , was presented in Fig. 10 (see part 1) based on computations made in (44).


The range $\langle \sigma_I^2 \rangle$ of the scintillation index variations, from 0.2 to 0.8, was obtained from numerous experiments, where relations between this parameter and the refractivity of the turbulence in the irregular atmosphere were taken into account (see also Fig. 7–9). Thus, from experiments described there, it was estimated $\sim C_n^2 \approx 10^{-15} \text{ m}^{-2/3}$ and $\sim C_n^2 \approx 10^{-13} \text{ m}^{-2/3}$, for a nocturnal and a diurnal atmosphere at the height around 1–2 km, respectively. As follows from Fig. 10, for such values of $\langle \sigma_I^2 \rangle$, fading parameter K indicates the existence of strong direct visibility between both terminals, the source and the detector, accompanied by weak additional effects of multipath phenomena caused by multiple scattering of signals at the turbulent structures, formed in the disturbed atmospheric regions, observed experimentally [4, 5].

Having now information about the K -factor, we can predict deviations of the parameters of the data stream (i. e., the signal) in the multipath channels passing through strong turbulence that occurs in the non-homogeneous atmosphere.

Thus, the capacity or spectral efficiency described versus K -factor by Eq. (63) and (64), respectively, can easily account for various scenarios occurring in the atmospheric channel and for different conditions of the inner noise of the transmitter as well as the receiver inside the link under consideration. One of the computed examples is presented in Fig. 13, for different additive SNRs and for a “point” receiver (with respect to the range of 1 km between the terminals).

We took the K -parameter much wider, varying in the interval from 0.1 to 500, that is: to cover the “worst” case when $K \ll 1$ which is described by Rayleigh law passing the quasi-LOS case; when $K \approx 1$; and finally achieving a situation where $K \gg 1$ (ideal LOS case in propagation, described by Delta-shape Gaussian law). As can be seen, in the strong disturbed irregular atmosphere (with strong turbulence), when $1 < K < 10$, the spectral efficiency is around (0.7–1.1) for SNR = 1 dB; around 0.7–1.7 for SNR = 5 dB; and around 0.95–2.55 for SNR = 10 dB.

Now, since the optical signal can be considered as a carrier of digital information, as a set of bits, effects of multipath fading in any wireless communication channel leads to errors in bits character-



■ Fig. 13. Spectral efficiency vs. K -factor for point receiver

ized by the special parameter defined as BER. Thus, using the Rayleigh distribution for worst cases of strong fading, we can determine the probability of bit error occurring in the multipath channel by the following formula [3–5]:

$$P_r(e) = \frac{1}{\sigma^2} \int_{r_T}^{\infty} r e^{-\left[\frac{r^2}{2\sigma_N^2}\right]} dr = e^{-\left[\frac{r_T^2}{2\sigma_N^2}\right]}, \quad (65)$$

where $P_r(e)$ represents evaluated probability of a bit error; σ_N^2 is the intensity of interference at the optical receiver (usually determined as the multiplicative noise [3–6]), r_T determines the threshold between detection without multiplicative noise (defined as a “good case” [3–6]), and with multiplicative noise (defined as a “worst case” [4, 5]).

In our investigations, we present BER as a function of the Ricean K -factor of fading, following results obtained in [4, 5], based on Ricean PDF, as more commonly used with respect to Rayleigh PDF. Thus, following [3–6] and using a classical formula for BER, according to [3] we finally get

$$BER = \frac{1}{2} \int_0^{\infty} p(x) \operatorname{erfc}\left(\frac{SNR}{2\sqrt{2}} x\right) dx, \quad (66)$$

where $p(x)$ is the probability density function, which in our case the Ricean one was taken, and $\operatorname{erfc}(\cdot)$ is the well-known error function [3–6]. Using the BER definition (66), where the SNR includes also the multiplicative noise, we finally get for BER the following equation:

$$BER\left(K, \frac{S}{N_{add}}, \sigma\right) = \frac{1}{2} \int_0^{\infty} \frac{x}{\sigma^2} e^{-\frac{x^2}{2\sigma^2}} e^{-Kx} \times$$

$$\times I_0\left(\frac{x}{\sigma}\sqrt{2K}\right) \operatorname{erfc}\left(\frac{K\frac{S}{N_{add}}}{2\sqrt{2}\left(K + \frac{S}{N_{add}}\right)} x\right) dx. \quad (67)$$

This is an important formula, which gives the relation between the BER and the additive SNR, the Ricean parameter K describes the multipath fading phenomena occurring within the multipath land-satellite communication link passing the ionosphere, and the probability of BER of the information data stream inside such a channel.

Relations between signal data parameters in atmospheric links

We can now enter into detailed analysis of the key parameters of the wireless atmospheric channel, radio or optic, and the information data, based on the approximate approach proposed above according to [3–6].


We should emphasize that the proposed approach is based on formulas (40), (41), (62)–(64) and (67). This means that with knowledge of the experimentally obtained refractive index structure parameter, C_n^2 , that characterizes strength of atmospheric turbulence, one can estimate the scintillation index σ_I^2 based on Rytov’s law (41). The later can be evaluated based on the relation between σ_I^2 and K by use of the relation (64) between them. Considering these parameters, finally using (62)–(64), (67), the BER can be evaluated for various situations occurring in the land-atmosphere or atmosphere-land wireless channels with fading caused by turbulent structure of the troposphere at altitudes from 1 to 10 km.

Thus, we analyze effects of fading (e. g., the changes of the K -parameter) on BER conditions within the turbulent wireless communication link consisting of weak and strong turbulences. As shown in [6, 25, 26], depending on what kind of turbulence — strong turbulence (with $\langle C_n^2 \rangle = 5 \cdot 10^{-14}$) occurring at paths up to 100–200 m, or weak turbulence (with $\langle C_n^2 \rangle = 4 \cdot 10^{-16}$), occurring at altitudes of 1–2 km — the effects of fading become stronger in the first case, and weaker in the second case. In other words, at higher atmospheric altitudes for the horizontal atmospheric channels, where the LOS-component exceeds the multipath (NLOS) component (i. e., for $K > 1$), the BER-characteristic becomes negligible and can be ignored as well as other fading characteristics in design of land-atmospheric or pure atmospheric links. This result is clearly illustrated by computations presented in Figs. 14, a and b for various SNR and for scintillation index.

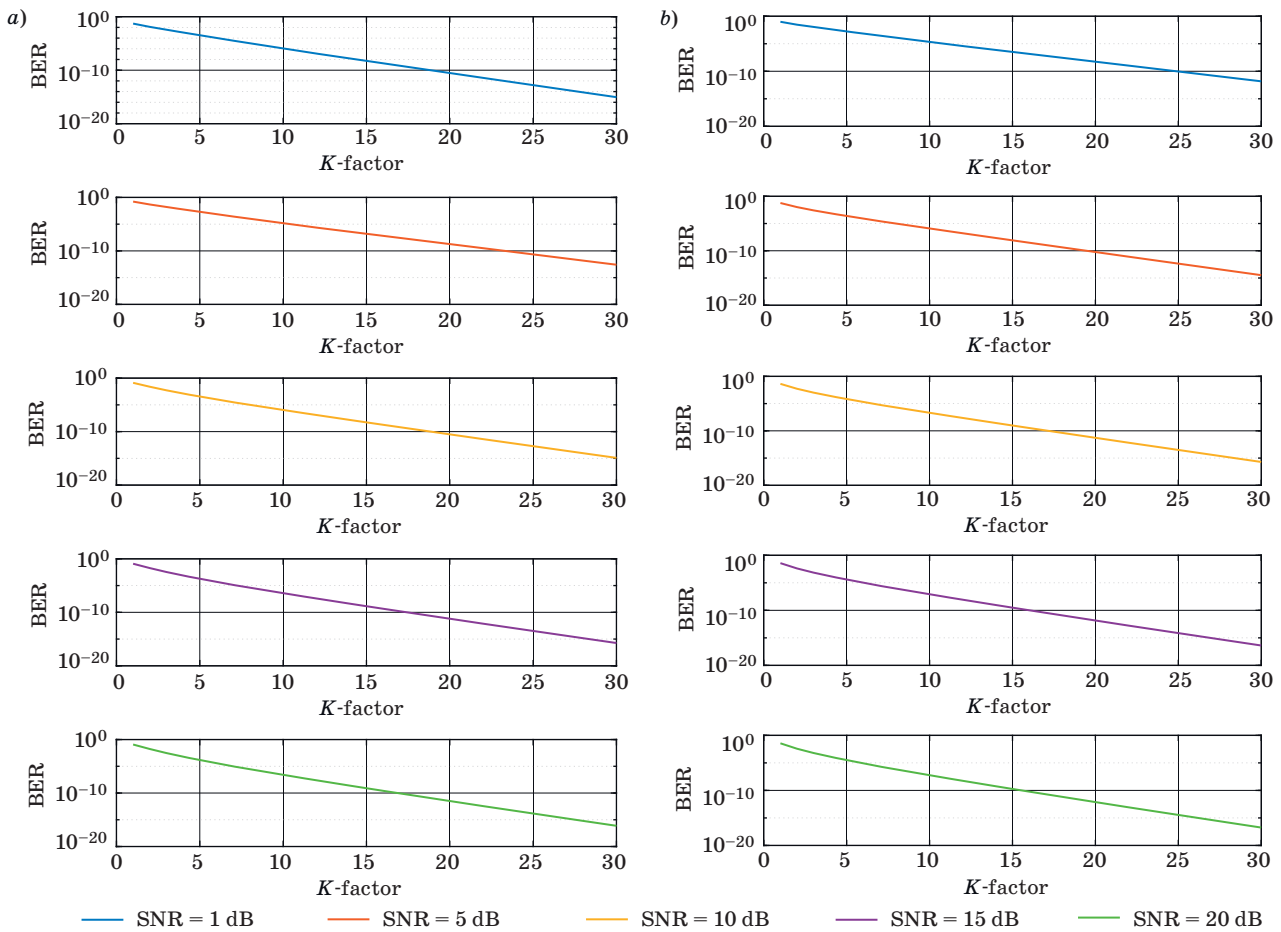
As seen from Figs. 14, strong turbulent atmospheric conditions, defined by $C_n^2 \approx 10^{-13} \text{ m}^{-2/3}$ (and

therefore — by $K < 2$) result in a relatively great BER. This tendency depends also on increases of SNR inside the wireless system. Thus, for an SNR increase of 15 dB, the BER decreases accordingly. So, strong turbulent conditions play a major role in fading effects caused by turbulence, which fully

corresponds with results obtained experimentally and theoretically in [25, 26]. Therefore, these are subjects of particular value for estimation of optical communication parameters, such as BER and SNR and prediction of maximal losses, caused by strong turbulence.



■ Fig. 14. BER computed by formula (67) vs. K -factor for various SNRs: $a - \sigma = 2$ dB; $b - \sigma = 5$ dB



■ Fig. 15. BER vs. K -factor for SNR_{add} : $a - \sigma = 2$ dB; $b - \sigma = 5$ dB

Finally, in [4–6] an optimal algorithm for minimization of the BER of signals was constructed for different situations occurring in wireless atmospheric communication links and for different SNRs occurring in AWGN channels. Thus, taking some measured data, presented in [4–6], we can show here some examples. The results of computations obtained from the relations between σ and K are shown in Fig. 15, *a* and *b*.

As seen from Fig. 15 with an increase of the K parameter; that is, when the LOS component becomes predominant with respect to NLOS multipath components, it is found that BER decreases essentially from 10^{-2} for $K \sim 1-2$ to 10^{-6} for $K \sim 5-6$ (i. e., for the atmospheric link at altitudes of 100–1000 m filled by turbulent structures [4–6]).

The above results were obtained both for strong and for weak turbulence via measuring of the scintillation index, which allows to estimate deviations of the parameter of fading K : from $K < 1-2$ — strong fading, to $K \sim 5-6$ — weak fading, and to $K \sim 10$ — absence of fading. Variations of SNR — from 1 to 20 dB, can only slightly improve a situation with fading.

Summary

In this work, we investigated tropospheric effects occurring in the corresponding communication channels, relating to the effects of hydrometeors (rain, clouds, etc.) as well as gaseous structures

with turbulence, and their main impact on total path loss and fading prediction in the process of total link budget design. We analyzed separately the impact of hydrometeors on attenuation; and turbulence on scattering (e. g. fast fading) of signals with data passing tropospheric wireless communication links.

A link budget was performed for more attractive frequencies used in Wi-Fi communication links (from 2.3 to 5.3 GHz) for different distances between the ground-based subscriber antenna and flying subscriber antenna. Some specific examples were presented for close and far ranges between the terminal antennas at 10 and 100 km.

Using obtained relations between the K -factor of fading and the scintillation index, usually applicable in turbulent atmosphere, one can a-priori predict the rate of information data signals, the BER, and the spectral efficiency of each atmospheric channel based on “reaction” of the atmospheric environment and its features on signal data stream passing the atmospheric wireless channel.

Finally, we can conclude that accounting for different impacts of atmospheric features and structures, a designer of wireless atmospheric communication links can more precisely predict the total path loss and, consequently, can design the link budget and arrange the terminal antennas with the prescribed correct amplification, so as to overcome and obey all losses and fading phenomena met in such kinds of links.

References

- Zuev V. E., and G. M. Krekov. *Optical Methods in the Atmosphere*. Leningrad, Gidrometeoizdat Publ., 1986. 256 p. (In Russian).
- Kopeika N. S. *A System Engineering Approach to Imaging*, Billingham, WA, SPIE Press, 1998. 704 p.
- Saunders S. R. *Antennas and Propagation for Wireless Communication Systems*. John Wiley & Sons, New York, 2007. 546 p.
- Blaunstein N., and Ch. Christodoulou. *Radio Propagation and Adaptive Antennas for Wireless Communication Links: Terrestrial, Atmospheric and Ionospheric*. Wiley InterScience, NJ, 2007. 614 p.
- Blaunstein N., and Ch. Christodoulou. *Radio Propagation and Adaptive Antennas for Wireless Communication Networks: Terrestrial, Atmospheric and Ionospheric*. Wiley, NJ, 2014. 704 p.
- Blaunstein N., Arnon Sh., Zilberman A., and Kopeika N. *Applied Aspects of Optical Communication and LIDAR*. New York, CRC Press, Taylor & Francis Group, 2010. 262 p.
- Optical Waves and Laser Beams in the Irregular Atmosphere*. Ed. by N. Blaunstein, and N. Kopeika. Boca Raton, FL, CRC Press, Taylor & Francis Group, 2018. 334 p.
- d’Almeida G. A., Koepke P., Shettle E. P. *Atmospheric Aerosols. Global Climatology and Radiative Characteristics*. Deepak Publishing, Hampton, 1991. 561 p.
- Deirmendjian D. *Electromagnetic Scattering on Spherical Polydispersions*. American Elsevier, New York, 1969. 318 p.
- Seinfeld J. H. *Atmospheric Chemistry and Physics of Air Pollution*. John Wiley & Sons, New York, 1986. 768 p.
- Attenuation due to clouds and fog. *ITU-R Recommendation International Telecommunication Union*, 1992, pp. 840–842.
- Chou M. D. Parametrizations for cloud overlapping and shortwave single scattering properties for use in general circulation and cloud ensemble models. *J. Climate*, 1998, vol. 11, pp. 202–214.
- Wei Zhang. Scattering of radiowaves by a melting layer of precipitation in backward and forward directions. *IEEE Transactions on Antennas and Propagation*, 1994, vol. 42, no. 3, pp. 347–356.
- Crane R. K. Prediction of attenuation by rain. *IEEE Trans. Commun*, 1980, vol. 28, pp. 1717–1733.
- Lin D. P., and Chen H. Y. An empirical formula for the prediction of rain attenuation in frequency range 0.6–100 GHz. *IEEE Trans. on Antennas Propagat*, 2002, vol. 50, pp. 545–551.

16. ITU-R Recommendation International Telecommunication Union "Specific attenuation model for rain for use in prediction methods", Geneva, 1992, p. 838.
17. Kooi P.-S., Leong M.-S., Li L.-W., et al. Microwave attenuation by realistically distorted raindrops: Part II — predictions. *IEEE Transactions on Antennas and Propagation*, 1995, vol. 43, pp. 821–828.
18. Jaenicke R. *Aerosol Physics and Chemistry*. In: *Physical Chemical Properties of the Air, Geophysics and Space Research*, vol. 4 (b). Ed. G. Fisher. Berlin, Springer-Verlag, 1988.
19. Rosen J. M., and Hofmann D. J. Optical modeling of stratospheric aerosols: present status. *Appl. Opt.*, 1986, vol. 25(3), pp. 410–419.
20. ITU-R International Telecommunication Union, ITU-R Recommendation "Attenuation by atmospheric gases", 1997, pp. 676–683.
21. ITU-R Recommendation International Telecommunication Union "Propagation data and prediction methods required for the design of terrestrial line-of-sight systems", 1997, pp. 530–537.
22. ITU-R Recommendation International Telecommunication Union "Characteristics of precipitation for propagating modeling", 1992, p. 837.
23. Ishimaru A. *Wave Propagation and Scattering in Random Media*. Academic Press, New York, 1978. 272 p.
24. Andrews L. C., and Phillips R. L. *Laser Beam Propagation through Random Media*. 2nd Ed. SPIE Press, Bellingham, WA, USA, 2005. 808 p.
25. Bendersky S., Kopeika N., and Blaunstein N. Prediction and modeling of line-of-sight bending near ground level for long atmospheric paths. *Proc. of SPIE Int. Conf.*, San Diego, August 3–8, 2004, pp. 512–522.
26. Bendersky S., Kopeika N., and Blaunstein N. Atmospheric optical turbulence over land in middle-east coastal environments: prediction, modeling and measurements. *J. Applied Optics*, 2004, vol. 43, pp. 4070–4079.

УДК 621.371

doi:10.31799/1684-8853-2020-1-54-62

Анализ полных потерь сигнала и пропускной способности информации в атмосферных беспроводных каналах связи. Часть 2

И. Джувилер^а, PhD, старший преподаватель, orcid.org/0000-0002-0669-7828И. Бронфман^а, ассистент, orcid.org/0000-0001-6195-069XН. Блаунштейн^б, доктор физ.-мат. наук, профессор, orcid.org/0000-0003-2945-9379, nathan.blaunstein@hotmail.com^аТехнический колледж им. Сами Шамуна, ул. Жаботинского, 84, Ашдод, 77245, Израиль^бНегевский университет им. Бен-Гуриона, П.О.Б. 653, Бен-Гуриона ул., 1, Беэр-Шева, 74105, Израиль

Введение: анализ полного затухания сигнала основан на прогнозе полных потерь, имеющих место в атмосферных каналах связи, учитывающем эффекты затухания и рассеяния на газообразующих структурах, поглощения и потерь от гидрометеоров (дождя, снега, облаков), быстрого фединга турбулентных структур на радио- и оптические сигналы, распространяющиеся в атмосферных каналах с федингом. **Цель исследования:** разработка новой методологии определения и оценки эффектов затухания, поглощения, рассеяния, и фединга радио- и оптических сигналов, распространяющихся в атмосферных каналах в различных метеорологических условиях. **Результаты:** проанализирован вклад газообразующих структур, гидрометеоров и турбулентных структур в полные потери сигнала для дизайна бюджета канала и в деградацию параметров информационного потока данных, таких как пропускная способность, спектральная эффективность и скорость потерь в битах, которые в итоге приводят к потере информационных сигналов, распространяющихся в каналах связи с быстрым федингом, и к уменьшению качества сервиса. Найден оптимальный алгоритм прогноза полных потерь для различных метеорологических условий, имеющих место в реальной атмосфере на различных высотах, и для различных частот излучаемых сигналов. Предложен метод оценки параметров потока информации, таких как пропускная способность, или емкость, спектральная эффективность и скорость потерь в битах. Данный метод учитывает эффекты вклада атмосферной турбулентности в быстрый фединг, который разрушает информацию, проходящую через каналы такого типа. Все практические тесты проиллюстрированы с использованием программирования на MATLAB. Предложена новая методика определения и оценки пропускной способности, спектральной эффективности и потерь в энергии и в потоке информационных битов при различных сценариях прохождения информационных сигналов, радио и оптических, через атмосферные беспроводные каналы связи с федингом, вызванным различными метеорологическими условиями. **Практическая значимость:** полученные результаты позволяют добиться улучшенной точности прогноза и повысить качество сервиса в атмосферных каналах связи.

Ключевые слова — быстрый фединг, газообразующие структуры, гидрометеоры, дождь, емкость (пропускная способность), затухание, индекс сцинтилляции, K -фактор Райса, облака, поглощение, скорость битовой ошибки, снег, спектральная эффективность, турбулентность.

Для цитирования: Juwiler I., Bronfman I., Blaunstein N. Analysis of total signal decay and capacity of information data in wireless atmospheric communication links. Part 2. *Информационно-управляющие системы*, 2020, № 1, с. 54–62. doi:10.31799/1684-8853-2020-1-54-62

For citation: Juwiler I., Bronfman I., Blaunstein N. Analysis of total signal decay and capacity of information data in wireless atmospheric communication links. Part 2. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 54–62. doi:10.31799/1684-8853-2020-1-54-62

Способ частотно-пространственной селекции радиоизлучений с помощью триортогональной антенной системы

С. В. Дворников^а, доктор техн. наук, профессор, orcid.org/0000-0002-4889-0001, practicdsv@yandex.ru

В. С. Конюховский^а, канд. физ.-мат. наук, профессор, orcid.org/0000-0002-7001-3048

А. Н. Симонов^а, канд. техн. наук, доцент, orcid.org/0000-0002-8826-8700

^аВоенная академия связи им. Маршала Советского Союза С. М. Буденного, Тихорецкий пр., 3, Санкт-Петербург, 194064, РФ

Введение: в настоящее время в средствах радиомониторинга нерешенной проблемой остается разделение перекрывающихся по спектру радиоизлучений от различных источников в условиях, когда ограничения на габариты антенной системы не позволяют обеспечить необходимое пространственное разрешение. **Цель:** разработка моделей радиоизлучений и процедур их обработки для селекции сигналов от различных источников из аддитивной смеси на входе малогабаритной антенной системы. **Методы:** использована точечная линейная регрессия для разложения результирующего поля на входе триортогональной антенной системы на базисные функции, согласованные с частотными параметрами радиоизлучений. **Результаты:** на геометрической основе, с использованием матрицы преобразования координат, за счет вращения системы отсчета предложены модели радиоизлучений с различной поляризацией для плоской электромагнитной волны с заданным направлением прихода. Особенностью разработанных моделей является выделение амплитудных и фазовых параметров в отдельные множители. Разработаны процедуры разделения аддитивной смеси радиоизлучений в триортогональной антенной системе на составляющие, относящиеся к различным источникам. Новизна представленного решения заключается в использовании геометрической интерпретации задачи точечной линейной регрессии, когда результирующий вектор электрического поля суммы двух радиоизлучений раскладывается на линейно независимые векторы, составленные из базисных функций, выбор которых определяется частотными параметрами сигналов. Кроме собственно селекции сигналов, обеспечивается анализ пространственных и поляризационных параметров радиоизлучений. **Практическая значимость:** реализация способа в технических средствах радиомониторинга в условиях сложной сигнальной обстановки при ограничениях на массу и габариты аппаратуры.

Ключевые слова – пространственно-поляризационная обработка, селекция радиоизлучений, модель радиоизлучения, интерференция радиоизлучений.

Для цитирования: Дворников С. В., Конюховский В. С., Симонов А. Н. Способ частотно-пространственной селекции радиоизлучений с помощью триортогональной антенной системы. *Информационно-управляющие системы*, 2020, № 1, с. 63–72. doi:10.31799/1684-8853-2020-1-63-72

For citation: Dvornikov S. V., Konyukhovskiy V. S., Simonov A. N. Method of frequency-spatial selection of radio emissions using a triorthogonal antenna system. *Informatsionno-upravlyaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 63–72 (In Russian). doi:10.31799/1684-8853-2020-1-63-72

Введение

Радиопеленгование является основой определения координат источников радиоизлучений (ИРИ) в угломерных системах определения местоположения [1, 2]. При ведении радиомониторинга пространственные параметры источников, в отличие от информационных, которые могут быть умышленно скрыты или искажены, остаются объективными, надежными и достоверными [3].

Классические амплитудные, фазовые, частотные методы радиопеленгования и варианты их реализации хорошо изучены и описаны в технической литературе [1–3]. В настоящее время наиболее распространенными становятся корреляционные пеленгаторы [3]. Большой интерес проявляется к перспективным собственно-струк-

турным методам оценивания направления на источники радиоизлучений [4].

Рост числа радиоизлучающих средств и источников помех приводит к усложнению сигнально-помеховой обстановки на входе радиопеленгатора и возникновению интерференции радиоизлучений, попадающих в полосу приема. Вследствие того, что при пеленговании все принятые радиоизлучения могут являться полезными, возникает необходимость оценивать пеленг на каждый источник и в дальнейшем выделять отдельные сигналы из принятой аддитивной смеси.

Существуют методы, обеспечивающие одновременное пеленгование и оценивание параметров нескольких ИРИ [5]. Такие методы подразумевают значительные апертуры антенных систем и продолжительное время накопления сигналов. Поэтому представляет интерес решение задачи

одновременного пеленгования нескольких ИРИ и пространственного разделения радиоизлучений от них с использованием малогабаритной антенной системы в условиях интерференции.

Основы поляризационного пеленгования


Традиционные амплитудные, фазовые, частотные и корреляционные методы радиопеленгования основаны на различии задержек на апертуре антенной системы, обусловленном ортогональностью плоскости фазового фронта к направлению распространения волны. Вместе с тем существуют методы [6–17], опирающиеся на свойство ортогональности векторов магнитного и электрического полей к направлению распространения, которые позволяют определять пеленг на источники радиоизлучений, используя поляризацию в качестве координатно-информативного параметра.

Разработан подход к пеленгованию источников радиоизлучений, основанный на сосредото-

ченной триортогональной антенной системе, способной определять поляризацию радиосигнала в точке приема [18, 19] (рис. 1, а).


Мгновенное пространственное положение вектора напряженности электрического поля \mathbf{E} в моменты времени t_i определяется по его проекциям E_{xi} , E_{yi} , E_{zi} путем измерения электродвижущих сил (ЭДС) в антенных элементах $A\mathcal{E}_x$, $A\mathcal{E}_y$, $A\mathcal{E}_z$ (рис. 1, а, б). Для определения пеленга, т. е. для нахождения азимута θ и угла места β , измеряют два значения вектора \mathbf{E}_i и \mathbf{E}_j в различные моменты времени t_i и t_j (рис. 1, б, в), строят перпендикулярные к этим векторам плоскости положения Ω_i и Ω_j и на их пересечении получают направляющий вектор \mathbf{L} на ИРИ как результат векторного произведения векторов \mathbf{E}_i и \mathbf{E}_j (рис. 1, в).

Данный подход был применен [20] для пеленгования в условиях интерференции двух эллиптически поляризованных радиоизлучений (рис. 2, а), имеющих частотные различия, когда результирующий вектор поля описывает в точке приема сложную объемную фигуру (рис. 2, б).



■ **Рис. 1.** Триортогональная антенная система (а); наведенные ЭДС (б); геометрические основы поляризационного пеленгования (в)

■ **Fig. 1.** Triorthogonal antenna system (а); induced electromotive force (б); geometric principles of polarization direction finding (в)



■ **Рис. 2.** Исходные радиоизлучения (а); результат их интерференции (б); вращение объемной фигуры (в); удачный ракурс (г)

■ **Fig. 2.** The original radio emission (а); the result of their interference (б); rotation of a volumetric figure (в); good view (г)

Нахождение пеленгов на ИРИ основано на решении системы уравнений, описывающих суммарное поле, что графически эквивалентно поиску удачного ракурса (рис. 2, в), при котором указанная фигура проецируется в параллелограмм (рис. 2, з), нормали к сторонам которого указывают направления на интерферирующие радиоизлучения.

Имеющиеся частотные различия дают вторую степень свободы плоской электромагнитной волны. При этом первой степенью свободы являются измеренные значения векторов напряженности электрического поля. В этом случае появляется возможность разделения полученной аддитивной смеси на отдельные радиоизлучения, что и является предметом данной статьи. Для решения поставленной задачи в первую очередь необходимо разработать модель радиоизлучения, а затем найти эффективные процедуры частотно-пространственной обработки.


Модель радиоизлучения

Пусть радиоизлучение, наблюдаемое в заданной точке дальней зоны источника, находящегося на направлении, совпадающем с осью Oz_1 , представляет собой плоскую волну с круговой поляризацией (рис. 3). Тогда вектор поля в картинной плоскости, совпадающей с плоскостью x_1Oy_1 , будет описываться выражением

$$\mathbf{r}(t) = U(\cos \omega t \quad \sin \omega t \quad 0)^T,$$

где U — амплитуда поля; ω — круговая частота излучения; t — текущее время.

Опишем математическую модель радиоизлучения путем вращения опорной системы координат



■ **Рис. 3.** Радиоизлучение в декартовой системе координат

■ **Fig. 3.** Radio emission in a Cartesian coordinate system

нат к направлению на ИРИ. Указанные вращения осуществляются с использованием матрицы преобразования координат (x_1, y_1, z_1) в (x, y, z) . Напомним, что поворот относительно оси Ox на угол $\alpha = \frac{\pi}{2} - \beta$ и поворот относительно оси Oz на угол θ описываются матрицами $\mathbf{R}_x(\alpha)$ и $\mathbf{R}_z(\theta)$ соответственно:

$$\mathbf{R}_x(\alpha) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \alpha & \sin \alpha \\ 0 & -\sin \alpha & \cos \alpha \end{pmatrix};$$

$$\mathbf{R}_z(\theta) = \begin{pmatrix} \cos \theta & \sin \theta & 0 \\ -\sin \theta & \cos \theta & 0 \\ 0 & 0 & 1 \end{pmatrix}.$$

Последовательные повороты относительно оси Ox и относительно оси Oz получают матрицей

$$\mathbf{R}_{zx}(\alpha, \theta) = \mathbf{R}_z(\theta) \mathbf{R}_x(\alpha) = \begin{pmatrix} \cos \theta & \sin \theta \cos \alpha & \sin \theta \sin \alpha \\ -\sin \theta & \cos \theta \cos \alpha & \cos \theta \sin \alpha \\ 0 & -\sin \alpha & \cos \alpha \end{pmatrix}. \quad (1)$$

Вектор поля в координатах (x, y, z) получают умножением $\mathbf{r}(t)$ на матрицу преобразования (1)

$$\mathbf{u}_k(t, \alpha, \theta) = \mathbf{R}_{zx}(\alpha, \theta) \mathbf{r}(t) = U \begin{pmatrix} \cos \theta & \sin \theta \cos \alpha & \sin \theta \sin \alpha \\ -\sin \theta & \cos \theta \cos \alpha & \cos \theta \sin \alpha \\ 0 & -\sin \alpha & \cos \alpha \end{pmatrix} \begin{pmatrix} \cos \omega t \\ \sin \omega t \\ 0 \end{pmatrix} = U \begin{pmatrix} \cos \theta \cos \omega t + \sin \theta \cos \alpha \sin \omega t \\ -\sin \theta \cos \omega t + \cos \theta \cos \alpha \sin \omega t \\ -\sin \alpha \sin \omega t \end{pmatrix}. \quad (2)$$

Анализ выражения (2) показывает, что его можно разделить на множители, первый из которых учитывает амплитуду соответствующей пространственной составляющей, а второй учитывает фазу:

$$\mathbf{u}_k(t, \alpha, \theta) = U \begin{pmatrix} A_x(\alpha, \theta) \cos(\omega t - \varphi_x(\alpha, \theta)) \\ A_y(\alpha, \theta) \cos(\omega t - \varphi_y(\alpha, \theta)) \\ A_z(\alpha, \theta) \cos(\omega t - \varphi_z(\alpha, \theta)) \end{pmatrix}, \quad (3)$$

где

$$A_x(\alpha, \theta) = \sqrt{\cos^2 \theta + \sin^2 \theta \cos^2 \alpha},$$

$$\varphi_x(\alpha, \theta) = \text{sign}(\sin \theta \cos \alpha) \arccos \frac{\cos \theta}{A_x(\alpha, \theta)};$$

$$A_y(\alpha, \theta) = \sqrt{\sin^2 \theta + \cos^2 \theta \cos^2 \alpha},$$

$$\varphi_y(\alpha, \theta) = \text{sign}(\cos \theta \cos \alpha) \arccos \frac{-\sin \theta}{A_y(\alpha, \theta)};$$

$$A_z(\alpha, \theta) = |\sin \alpha|, \quad \varphi_z(\alpha, \theta) = \text{sign}(-\sin \alpha) \frac{\pi}{2} -$$

амплитуда и начальная фаза пространственных составляющих, расположенных вдоль осей Ox , Oy , Oz , соответственно.

В случае радиоизлучения с эллиптической поляризацией вектор поля $\mathbf{r}(t)$ описывает в плоскости x_1Oy_1 эллипс с полуосями a и b (рис. 4), повернутый относительно оси Ox_1 на угол $\gamma \in [0; \pi]$. Параметрические уравнения эллипса в координатах x_2Oy_2

$$\begin{cases} x_2(t) = a \cos \omega t \\ y_2(t) = b \sin \omega t \end{cases}.$$

Координаты в системе x_1Oy_1 выражаются как

$$\begin{cases} x_1(t) = x_2(t) \cos \gamma - y_2(t) \sin \gamma \\ y_1(t) = x_2(t) \sin \gamma + y_2(t) \cos \gamma \end{cases}. \quad (4)$$

Вектор поля в координатах (x, y, z) имеет вид

$$\begin{aligned} \mathbf{u}(t) &= \mathbf{R}_{zx}(\alpha, \theta) \mathbf{r}(t) = \\ &= \begin{pmatrix} \cos \theta & \sin \theta \cos \alpha & \sin \theta \sin \alpha \\ -\sin \theta & \cos \theta \cos \alpha & \cos \theta \sin \alpha \\ 0 & -\sin \alpha & \cos \alpha \end{pmatrix} \begin{pmatrix} x_1(t) \\ y_1(t) \\ 0 \end{pmatrix}. \end{aligned} \quad (5)$$

Подстановка (4) в (5) дает модель радиоизлучения с эллиптической поляризацией

$$\begin{aligned} \mathbf{u}_s(t, \alpha, \theta, \gamma) &= \begin{pmatrix} \cos \theta & \sin \theta \cos \alpha & \sin \theta \sin \alpha \\ -\sin \theta & \cos \theta \cos \alpha & \cos \theta \sin \alpha \\ 0 & -\sin \alpha & \cos \alpha \end{pmatrix} \begin{pmatrix} a \cos \omega t \cos \gamma - b \sin \omega t \sin \gamma \\ a \cos \omega t \sin \gamma + b \sin \omega t \cos \gamma \\ 0 \end{pmatrix} = \\ &= \begin{pmatrix} a[\cos \theta \cos \gamma + \sin \theta \cos \alpha \sin \gamma] \cos \omega t + b[-\cos \theta \sin \gamma + \sin \theta \cos \alpha \cos \gamma] \sin \omega t \\ a[-\sin \theta \cos \gamma + \cos \theta \cos \alpha \sin \gamma] \cos \omega t + b[\sin \theta \sin \gamma + \cos \theta \cos \alpha \cos \gamma] \sin \omega t \\ -a \sin \alpha \sin \gamma \cos \omega t + b \sin \alpha \cos \gamma \sin \omega t \end{pmatrix}. \end{aligned} \quad (6)$$

Анализ (6) показывает возможность приведения его к виду, аналогичному (3):

$$\mathbf{u}_s(t, \alpha, \theta, \gamma) = \begin{pmatrix} A_x(\alpha, \theta, \gamma) \cos(\omega t - \varphi_x(\alpha, \theta, \gamma)) \\ A_y(\alpha, \theta, \gamma) \cos(\omega t - \varphi_y(\alpha, \theta, \gamma)) \\ A_z(\alpha, \theta, \gamma) \cos(\omega t - \varphi_z(\alpha, \theta, \gamma)) \end{pmatrix}, \quad (7)$$


где

$$A_x(\alpha, \theta, \gamma) = \sqrt{a^2[\cos \theta \cos \gamma + \sin \theta \cos \alpha \sin \gamma]^2 + b^2[-\cos \theta \sin \gamma + \sin \theta \cos \alpha \cos \gamma]^2},$$

$$\varphi_x(\alpha, \theta, \gamma) = \arctg \frac{b[-\cos \theta \sin \gamma + \sin \theta \cos \alpha \cos \gamma]}{a[\cos \theta \cos \gamma + \sin \theta \cos \alpha \sin \gamma]},$$

$$A_y(\alpha, \theta, \gamma) = \sqrt{a^2[-\sin \theta \cos \gamma + \cos \theta \cos \alpha \sin \gamma]^2 + b^2[\sin \theta \sin \gamma + \cos \theta \cos \alpha \cos \gamma]^2},$$

$$\varphi_y(\alpha, \theta, \gamma) = \arctg \frac{b[\sin \theta \sin \gamma + \cos \theta \cos \alpha \cos \gamma]}{a[-\sin \theta \cos \gamma + \cos \theta \cos \alpha \sin \gamma]}.$$



■ **Рис. 4.** Эллипс поляризации
 ■ **Fig. 4.** Ellipse of polarization

$$A_z(\alpha, \theta, \gamma) = \sqrt{\sin^2 \alpha (a^2 \sin^2 \gamma + b^2 \cos^2 \gamma)},$$

$$\varphi_z(\alpha, \theta, \gamma) = \arctg\left(\frac{b}{a} \operatorname{tg} \gamma\right) -$$

так же, как и в (3), амплитуда и начальная фаза пространственных составляющих, расположенных вдоль осей Ox, Oy, Oz , соответственно.

При $a = b = U$ и $\gamma = 0$ из (6) и (7) получают выражения (2) и (3) для модели радиоизлучения с круговой поляризацией.

Модель радиоизлучения с линейной поляризацией получают подстановкой $a = U$ и $b = 0$ в (6)

$$\begin{aligned} \mathbf{u}_L(t, \alpha, \theta) = & \\ = U & \begin{pmatrix} (\cos \theta \cos \gamma + \sin \theta \cos \alpha \sin \gamma) \cos \omega t \\ (-\sin \theta \cos \gamma + \cos \theta \cos \alpha \sin \gamma) \cos \omega t \\ -a \sin \alpha \sin \gamma \cos \omega t \end{pmatrix}. \end{aligned} \quad (8)$$

Постановка задачи селекции радиоизлучений с помощью точечной линейной регрессии

Пусть $f(t)$ — заданная функция, и $\varphi_1(t), \varphi_2(t), \dots, \varphi_m(t)$ — множество базисных функций, которые определены на некотором промежутке $[a; b]$.

Функция $\varphi(t) = \sum_{k=1}^m a_k \varphi_k(t)$ является линейной

комбинацией функций $\varphi_k(t)$ с коэффициентами a_k и называется обобщенным многочленом по системе базисных функций $\varphi_k(t)$.

Выберем на $[a; b]$ произвольно множество точек $D = \{t_1, t_2, \dots, t_n\}$. Требуется найти такие коэффициенты a_k^* обобщенного многочлена

$$\varphi^*(t) = \sum_{k=1}^m a_k^* \varphi_k(t),$$

чтобы сумма квадратов отклонений многочлена $\varphi^*(t)$ от функции $f(t)$ в точках $t_k \in D$ была бы минимальной, т. е. значение целе-

вой функции $Q(\varphi(t)) = \sum_{k=1}^m (f(t_k) - \varphi(t_k))^2$ было бы

минимальным при $\varphi^*(t)$. Многочлен $\varphi^*(t)$ называется многочленом наилучшего среднеквадратичного приближения и является решением задачи линейной регрессии для функции $f(t)$ на множестве функций $\{\varphi_k(t)\}$. Задача допускает геометрическую интерпретацию (рис. 5).

В n -мерном линейном пространстве R^n образуют n -мерные векторы

$$\Phi_k = \begin{pmatrix} \varphi_k(t_1) \\ \varphi_k(t_2) \\ \dots \\ \varphi_k(t_n) \end{pmatrix}, \quad k = 1, 2, \dots, m \quad \text{и} \quad \mathbf{F} = \begin{pmatrix} f(t_1) \\ f(t_2) \\ \dots \\ f(t_n) \end{pmatrix}.$$

Скалярное произведение n -мерных векторов $\mathbf{a} = (x_k)$ и $\mathbf{b} = (y_k)$ находится по формуле $(\mathbf{a}, \mathbf{b}) = \sum_{k=1}^n x_k y_k$, а квадрат нормы вектора находится как $\|\mathbf{a}\|^2 = \sum_{k=1}^n x_k^2$.

как $\|\mathbf{a}\|^2 = \sum_{k=1}^n x_k^2$.


Базисность функций $\varphi_k(t)$ означает линейную независимость векторов Φ_k . Если линейное подпространство L натянуто на базисные векторы Φ_k , то всякий обобщенный многочлен $\varphi_k(t)$, описываемый вектором

$$\mathbf{P} = (\varphi(t_1) \quad \varphi(t_2) \quad \dots \quad \varphi(t_n))^T = \sum_{k=1}^m a_k \Phi_k,$$

принадлежит L .

С учетом сказанного задача линейной регрессии может быть переформулирована следующим образом: найти вектор $\mathbf{P}^* \in L$, для которого норма вектора $\mathbf{H} = \mathbf{F} - \mathbf{P}^*$ является минимальной:

$$\|\mathbf{H}\|^2 = \|\mathbf{F} - \mathbf{P}^*\|^2 = \sum_{k=1}^n (f(t_k) - \varphi^*(t_k))^2 = Q(\varphi^*(t)).$$



■ **Рис. 5.** Геометрическая интерпретация задачи линейной регрессии
 ■ **Fig. 5.** Geometric interpretation of the linear regression problem

Для минимизации $Q(\varphi(t))$ (минимизации длины \mathbf{H}) следует выбрать \mathbf{P}^* как ортогональную проекцию вектора \mathbf{F} на подпространство L . Следовательно, вектор \mathbf{H} должен быть ортогонален подпространству L . Это в свою очередь означает ортогональность \mathbf{H} всем базисным векторам Φ_k .

Условие оптимальности вектора \mathbf{P}^* записывается как

$$(\forall k)[\mathbf{H} \perp \Phi_k] \Leftrightarrow (\forall k)[(\Phi_k, \mathbf{H}) = 0].$$

Скалярное произведение векторов будем вычислять как произведение соответствующих столбцов. Тогда $(\Phi_k, \mathbf{H}) = \Phi_k^T \mathbf{H} = 0$, т. е. $(\forall k)[\Phi_k^T \mathbf{H} = 0]$.

Образуем матрицу Φ , столбцами которой являются векторы Φ_k :

$$\Phi = (\Phi_1 \quad \Phi_2 \quad \dots \quad \Phi_m) = \begin{pmatrix} \varphi_1(t_1) & \varphi_2(t_1) & \dots & \varphi_m(t_1) \\ \varphi_1(t_2) & \varphi_2(t_2) & \dots & \varphi_m(t_2) \\ \dots & \dots & \dots & \dots \\ \varphi_1(t_n) & \varphi_2(t_n) & \dots & \varphi_m(t_n) \end{pmatrix}_{n \times m}.$$

Тогда

$$(\forall k)[\Phi_k^T \mathbf{H} = 0] \Leftrightarrow [\Phi^T \mathbf{H} = \mathbf{0}],$$

где $\mathbf{0}$ — нулевой m -мерный вектор.

Учитывая, что $\mathbf{H} = \mathbf{F} - \mathbf{P}^*$, получим

$$[\Phi^T (\mathbf{F} - \mathbf{P}^*)] = \mathbf{0} \Leftrightarrow [\Phi^T \mathbf{P}^* = \Phi^T \mathbf{F}].$$

Вектор \mathbf{P}^* может быть представлен в виде

$$\mathbf{P}^* = \sum_{k=1}^m a_k^* \Phi_k = \Phi \mathbf{X}^*,$$

где $\mathbf{X}^* = (a_1^* \quad a_2^* \quad \dots \quad a_m^*)^T$ — m -мерный вектор коэффициентов многочлена наилучшего среднеквадратичного приближения.

Таким образом, задача отыскания многочлена наилучшего среднеквадратичного приближения сводится к решению квадратной системы m линейных уравнений

$$\Phi^T \Phi \mathbf{X}^* = \Phi^T \mathbf{F}.$$

Решение может быть теоретически записано в виде

$$\mathbf{X}^* = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{F},$$

но на практике систему решают численными методами, например методом Гаусса.

Если решение системы \mathbf{X}^* найдено, то многочлен наилучшего среднеквадратичного приближения записывается в виде

$$\varphi^*(t) = \sum_{k=1}^m a_k^* \varphi_k(t).$$

Оценка остаточной погрешности сводится к вычислению $\|\mathbf{H}\|$

$$\|\mathbf{H}\|^2 = (\mathbf{H}, \mathbf{H}) = (\mathbf{F} - \mathbf{P}^*, \mathbf{F} - \mathbf{P}^*) = (\mathbf{F}, \mathbf{H}),$$

поскольку $\mathbf{P}^* \perp \mathbf{H}$. Далее получаем

$$\begin{aligned} \|\mathbf{H}\|^2 &= (\mathbf{F}, \mathbf{H}) = (\mathbf{F}, \mathbf{F} - \mathbf{P}^*) = \\ &= \|\mathbf{F}\|^2 - \mathbf{F}^T \Phi \mathbf{X}^* = \|\mathbf{F}\|^2 - (\Phi^T \mathbf{F})^T \mathbf{X}^*. \end{aligned}$$

В качестве оценки погрешности целесообразно использовать среднеквадратичное отклонение

$$\sigma = \sqrt{\frac{\|\mathbf{H}\|^2}{n}} = \sqrt{\frac{1}{n} (\|\mathbf{F}\|^2 - (\Phi^T \mathbf{F})^T \mathbf{X}^*)}.$$

Частотно-пространственная селекция радиоизлучений и анализ их параметров

Пусть поле $\mathbf{u}(t) = \mathbf{u}_1(t) + \mathbf{u}_2(t)$, где поля

$$\mathbf{u}_1(t) = \begin{pmatrix} u_{x_1}(t) \\ u_{y_1}(t) \\ u_{z_1}(t) \end{pmatrix}, \quad \mathbf{u}_2(t) = \begin{pmatrix} u_{x_2}(t) \\ u_{y_2}(t) \\ u_{z_2}(t) \end{pmatrix},$$

$$\mathbf{u}(t) = \begin{pmatrix} u_x(t) \\ u_y(t) \\ u_z(t) \end{pmatrix} = \begin{pmatrix} u_{x_1}(t) + u_{x_2}(t) \\ u_{y_1}(t) + u_{y_2}(t) \\ u_{z_1}(t) + u_{z_2}(t) \end{pmatrix}$$

описываются моделями (3), (7), (8) в зависимости от вида поляризации.

Предположим, что


$$u_{x_1}(t) = A_1 \cos(\omega_1 t - \varphi_1) = a_1 \cos \omega_1 t + b_1 \sin \omega_1 t;$$

$$u_{x_2}(t) = A_2 \cos(\omega_2 t - \varphi_2) = a_2 \cos \omega_2 t + b_2 \sin \omega_2 t,$$

причем частоты ω_1 и ω_2 известны. Тогда

$$\begin{aligned} u_x(t) &= a_1 \cos \omega_1 t + b_1 \sin \omega_1 t + \\ &+ a_2 \cos \omega_2 t + b_2 \sin \omega_2 t. \end{aligned}$$

Если выбрать достаточно большое количество точек отсчета $\{t_1, t_2, \dots, t_n\}$, то коэффициенты a_1, b_1 и a_2, b_2 можно с высокой точностью вычислить методом линейной регрессии по базису:



■ **Рис. 6.** Отселектированные сигналы
 ■ **Fig. 6.** Selected signals

$$\varphi_1(t) = \cos \omega_1 t; \quad \varphi_2(t) = \sin \omega_1 t; \quad \varphi_3(t) = \cos \omega_2 t;$$

$$\varphi_4(t) = \sin \omega_2 t.$$

Это позволяет разделить компоненты поля $u_{x_1}(t)$ и $u_{x_2}(t)$.

Аналогичным способом разделяются компоненты $u_{y_1}(t)$, $u_{y_2}(t)$ и $u_{z_1}(t)$, $u_{z_2}(t)$, а стало быть, и $\mathbf{u}_1(t)$, $\mathbf{u}_2(t)$.

Обобщая предложенный подход, можно предложить следующую трактовку. Пусть дано множество $D = \{\mathbf{d}_k = \mathbf{u}(t_k)\}$ наблюдаемых значений суммарного поля $\mathbf{u}(t) = \mathbf{u}_1(t) + \mathbf{u}_2(t)$, причем известны частоты ω_1 , ω_2 полей $\mathbf{u}_1(t)$ и $\mathbf{u}_2(t)$. Координатное представление суммарного поля: $\mathbf{u}(t) = (u_x(t) \ u_y(t) \ u_z(t))^T$. Координатные функции могут быть представлены линейной комбинацией базисных функций:

$$u_x(t) = a_{x1} \cos \omega_1 t + b_{x1} \sin \omega_1 t +$$

$$+ a_{x2} \cos \omega_2 t + b_{x2} \sin \omega_2 t;$$

$$u_y(t) = a_{y1} \cos \omega_1 t + b_{y1} \sin \omega_1 t +$$

$$+ a_{y2} \cos \omega_2 t + b_{y2} \sin \omega_2 t;$$

$$u_z(t) = a_{z1} \cos \omega_1 t + b_{z1} \sin \omega_1 t +$$

$$+ a_{z2} \cos \omega_2 t + b_{z2} \sin \omega_2 t.$$

Коэффициенты линейных комбинаций находят методом линейной регрессии по некоторому ограниченному набору наблюдаемых значений $\mathbf{d}_k = (d_{x_k} \ d_{y_k} \ d_{z_k})^T$. Тогда компоненты поля допускают представление

$$\mathbf{u}_1(t) = \begin{pmatrix} u_{x_1}(t) \\ u_{y_1}(t) \\ u_{z_1}(t) \end{pmatrix} = \begin{pmatrix} a_{x1} \cos \omega_1 t + b_{x1} \sin \omega_1 t \\ a_{y1} \cos \omega_1 t + b_{y1} \sin \omega_1 t \\ a_{z1} \cos \omega_1 t + b_{z1} \sin \omega_1 t \end{pmatrix};$$

$$\mathbf{u}_2(t) = \begin{pmatrix} u_{x_2}(t) \\ u_{y_2}(t) \\ u_{z_2}(t) \end{pmatrix} = \begin{pmatrix} a_{x2} \cos \omega_2 t + b_{x2} \sin \omega_2 t \\ a_{y2} \cos \omega_2 t + b_{y2} \sin \omega_2 t \\ a_{z2} \cos \omega_2 t + b_{z2} \sin \omega_2 t \end{pmatrix}.$$

Зависимости $u_{x_j}(t)$, $u_{y_j}(t)$, $u_{z_j}(t)$ ($j = 1, 2$), являющиеся проекциями эллиптических полей

на соответствующие оси, представляют собой ЭДС, наведенные в антенных элементах триортогональной антенной системы (см. рис. 1, а, б) радиоизлучением от j -го источника, и для узкополосных сигналов являются квазигармоническими колебаниями (рис. 6).


Для каждого из рассматриваемых полей $\mathbf{u}_j(t)$ ($j = 1, 2$) находятся моменты времени $t_{\max}^{(j)}$ и $t_{\min}^{(j)}$, соответствующие максимуму и минимуму нормы поля:

$$t_{\max}^{(j)} = \arg \max_k |\mathbf{u}_j(t_k)|; \quad t_{\min}^{(j)} = \arg \min_k |\mathbf{u}_j(t_k)|$$

(для простоты далее индекс j в $\mathbf{u}_j(t)$, $t_{\max}^{(j)}$, $t_{\min}^{(j)}$, $\mathbf{u}_{\max}^{(j)}$, $\mathbf{u}_{\min}^{(j)}$ и т. п. будет опущен).

Соответствующие t_{\max} и t_{\min} векторы определяют большую и малую полуоси эллиптического поля (рис. 7):

$$\mathbf{u}_{\max} = \mathbf{u}(t_{\max}); \quad \mathbf{u}_{\min} = \mathbf{u}(t_{\min}).$$



■ **Рис. 7.** Пространственные и поляризационные параметры радиоизлучения

■ **Fig. 7.** Spatial and polarization parameters of radio emission

Полуоси эллиптического поля равны $a = |\mathbf{u}_{\max}|$, $b = |\mathbf{u}_{\min}|$, а эксцентриситет

$$\varepsilon = \sqrt{1 - \left(\frac{b}{a}\right)^2}.$$

Нормаль к плоскости поля вычисляется (с точностью до направления) как векторное произведение векторов полуосей

$$\mathbf{n} = \mathbf{u}_{\max} \times \mathbf{u}_{\min}.$$

Сферические координаты вектора \mathbf{n} соответствуют азимуту θ и углу места $\beta = \frac{\pi}{2} - \alpha$ (см. рис. 7).

Для вычисления угла γ (см. рис. 7) следует найти координаты вектора \mathbf{u}_{\max} в плоскости $x_1 O y_1$, которые вычисляются как

$$\begin{pmatrix} x_1 \\ y_1 \\ z_1 \end{pmatrix} = \mathbf{R}_{zx}^T(\alpha, \theta) \mathbf{u}_{\max} = \begin{pmatrix} \cos\theta & \sin\theta \cos\alpha & \sin\theta \sin\alpha \\ -\sin\theta & \cos\theta \cos\alpha & \cos\theta \sin\alpha \\ 0 & -\sin\alpha & \cos\alpha \end{pmatrix}^T \mathbf{u}_{\max},$$

(z_1 теоретически должно быть равно нулю).

Тогда γ находится как полярный угол вектора $(x_1 \ y_1)^T$. Начальная фаза поля вычисляется на основе соотношения $u(t) = a \cos(\omega t - \varphi)$ при $t = 0$, т. е. $\varphi = -\arccos \frac{u(0)}{a}$. С этой целью сначала вычисляются координаты вектора $\mathbf{u}_{init} = \mathbf{u}(0)$ в системе (x_1, y_1, z_1) :

$$(x_1 \ y_1 \ z_1)^T = \mathbf{R}_{zx}^T(\alpha, \theta) \mathbf{u}_{init},$$

а затем координаты данного вектора в системе $x_2 O y_2$:

$$\begin{pmatrix} x_2 \\ y_2 \end{pmatrix} = \begin{pmatrix} \cos\gamma & \sin\gamma \\ -\sin\gamma & \cos\gamma \end{pmatrix} \begin{pmatrix} x_1 \\ y_1 \end{pmatrix}.$$

Тогда

$$\varphi = -\arccos \frac{x_2}{|\mathbf{u}_{\max}|}.$$

Таким образом, в результате частотно-пространственной селекции получают пространственные θ_j , β_j и поляризационные a_j , b_j , ε_j , γ_j параметры, а также временные зависимости $u_{x_j}(t)$, $u_{y_j}(t)$, $u_{z_j}(t)$ ($j = 1, 2$), соответствующие каждому j -му радиоизлучению.

Выводы

Разработанный способ основан на применении малогабаритной сосредоточенной триортогональной антенной системы и позволяет разделить аддитивную смесь радиоизлучений, используя их частотные различия. Кроме, собственно, решения задачи селекции сигналов обеспечивается возможность оценивания их пространственных и поляризационных параметров. Разделение радиоизлучений обеспечивается при любых поляризации и направлении на источники. Направлением дальнейших исследований является изучение частотно-поляризационно-пространственной разрешающей способности разработанного способа.

Литература

1. Poisel R. A. *Electronic Warfare Target Location Methods*. Artech House, Norwood MA, 2005. 272 p.
2. Симонов А. Н., Волков Р. В., Дворников С. В. *Основы построения и функционирования угломерных систем координатометрии источников радиоизлучений*. СПб., ВАС, 2017. 248 с.
3. Рембовский А. М., Ашихмин А. В., Козьмин В. А. *Автоматизированные системы радиоконтроля и их компоненты*. М., Горячая линия — Телеком, 2017. 424 с.
4. Paulraj A., Kailath T. Eigenstructure methods for direction of arrival estimation in the presence of unknown noise fields. *IEEE Transactions on Acoustics Speech and Signal Processing*, 1986, vol. 34, no. 1, pp. 13–20. doi:10.1109/TASSP.1986.1164776
5. Комарович В. Ф., Никитченко В. В. *Методы пространственной обработки радиосигналов*. Л., ВАС, 1989. 278 с.
6. Nehorai A., Paldi E. Vector-sensor array processing for electromagnetic source localization. *IEEE Transactions on Signal Processing*, 1994, vol. 42, no. 2, pp. 376–398. doi:10.1109/78.275610
7. Козлов А. И., Логвин А. И., Сарычев В. А. *Поляризация радиоволн. Поляризационная структура радиолокационных сигналов*. М., Радиотехника, 2005. 704 с.
8. Пат. 2649097 РФ, МПК Н 01 Q 9/00. *Антенна триортогональная*, И. В. Демичев (РФ), Н. П. Шмаков (РФ), Р. В. Колесников (РФ), А. В. Иванов (РФ). № 2016146582; заявл. 28.11.2016; опублик. 29.03.2018, Бюл. № 10, 11 с.
9. Демичев И. В., Шмаков Н. П., Колесников Р. В., Иванов А. В. Пространственно-поляризационная обработка радиосигналов в гиперкомплексном пространстве. *Наукоемкие технологии*, 2018, т. 19, № 10, с. 25–29.
10. Wong K. Direction finding/polarization estimation — dipole and/or loop triad(s). *IEEE Transactions on*

- Aerospace and Electronic Systems*, 2001, vol. 37, no. 2, pp. 679–684. doi:10.1109/7.937478
11. Kitavi D., Wong K., Zou M., Agrawal K. A lower bound of the estimation error of an emitter's direction-of-arrival/polarization, for a collocated triad of orthogonal dipoles/loops that fail randomly. *IET Microwaves, Antennas & Propagation*, 2017, vol. 11, iss. 7, pp. 961–970. doi:10.1049/iet-map.2016.0918
 12. Chintagunta S., Ponnusamy P. Integrated polarization and diversity smoothing algorithm for DOD and DOA estimation of coherent targets. *IET Signal Processing*, 2018, vol. 12, iss. 4, pp. 447–453. doi:10.1049/iet-spr.2017.0276
 13. Khan S., Wong K. Electrically long dipoles in a crossed pair for closed-form estimation of an incident source's polarization. *IEEE Transactions on Antennas and Propagation*, 2019, vol. 67, no. 8, pp. 5569–5581. doi:10.1109/TAP.2019.2916581
 14. Zheng G. Two-dimensional DOA estimation for polarization sensitive array consisted of spatially spread crossed-dipole. *IEEE Sensors Journal*, 2018, vol. 18, iss. 12, pp. 5014–5023. doi:10.1109/JSEN.2018.2820168
 15. Afraimovich E. L., Chernukhov V. V., Kobzar V. A., Palamartchouk K. Determining polarization parameters and angles of arrival of HF radio signals using three mutually orthogonal antennas. *Radio Science*, 1999, vol. 34, no. 5, pp. 1217–1225. doi:10.1029/1999RS900042
 16. Zhangmeng L. DOA and polarization estimation via signal reconstruction with linear polarization-sensitive arrays. *Chinese Journal of Aeronautics*, 2015, vol. 28, iss. 6, pp. 1718–1724. doi:10.1016/j.cja.2015.09.005.
 17. Raimondi F., Farias R., Michel O., Comon P. Wide-band multiple diversity tensor array processing. *IEEE Transactions on Signal Processing*, 2017, vol. 65, iss. 20, pp. 5334–5346. doi:10.1109/TSP.2017.2725219
 18. Пат. 2624449 РФ, МПК G 01 S 5/04. Способ поляризации пеленгования радиосигналов, С. В. Богдановский (РФ), Р. В. Волков (РФ), В. В. Севидов (РФ), А. Н. Симонов (РФ). № 2016141188; заявл. 19.10.2016; опубл. 04.07.2017, Бюл. № 19, 14 с.
 19. Симонов А. Н., Богдановский С. В., Теслевич С. Ф. Поляризационный метод пеленгования источников радиоизлучения в пространстве. *Наукоёмкие технологии*, 2016, т. 17, № 12, с. 40–43.
 20. Дворников С. В., Конюховский В. С., Симонов А. Н. Способ оценивания пеленгов на источники радиоизлучений в условиях интерференции. *Информация и космос*, 2019, № 1, с. 6–10.

UDC 621.396.663

doi:10.31799/1684-8853-2020-1-63-72

Method of frequency-spatial selection of radio emissions using a triorthogonal antenna systemS. V. Dvornikov^a, Dr. Sc., Tech., Professor, orcid.org/0000-0002-4889-0001, practicsv@yandex.ruV. S. Konyukhovskiy^a, PhD, Phys.-Math., Professor, orcid.org/0000-0002-7001-3048A. N. Simonov^a, PhD, Tech., Associate Professor, orcid.org/0000-0002-8826-8700^aS. M. Budenny Military Academy of Communication, 3, Tikhoretskii Pr., 190064, Saint-Petersburg, Russian Federation

Introduction: An unresolved problem in radio monitoring is the separation of overlapping radio spectrum from different sources when restricted dimensions of the antenna system do not provide the necessary spatial resolution. **Purpose:** Developing models of radio emissions and procedures for their processing in order to select signals from different sources out of their additive mixture at the antenna system input. **Methods:** Point linear regression for the decomposition of the resulting field at the triorthogonal antenna system input into basic functions which are consistent with the frequency parameters of the radio emissions. **Results:** On the geometric basis, using a coordinate transformation matrix, due to the reference system rotation, radio emission models with different polarization are proposed for a plane electromagnetic wave with a given arrival direction. The developed models have the amplitude and phase parameters split into separate factors. Procedures have been developed for separating the additive mixture of radio emissions in the triorthogonal antenna system into components related to different sources. The novelty of the presented solution lies in the use of geometric interpretation of the point linear regression problem, when the resulting vector of the electric field of the sum of two radio emissions is decomposed into linearly independent vectors composed of basic functions whose choice is determined by the frequency parameters of the signals. In addition to the actual selection of the signals, it is possible to analyze the spatial and polarization parameters of the radio emissions. **Practical relevance:** The method can be implemented in radio monitoring equipment with restrictions on the weight and dimensions, for the use in complex signal environments.

Keywords — spatial polarization processing, selection of radio emissions, model of radio emissions, interference of radio emissions.

For citation: Dvornikov S. V., Konyukhovskiy V. S., Simonov A. N. Method of frequency-spatial selection of radio emissions using a triorthogonal antenna system. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 63–72 (In Russian). doi:10.31799/1684-8853-2020-1-63-72

References

1. Poisel R. A. *Electronic Warfare Target Location Methods*. Artech House, Norwood MA, 2005. 272 p.
2. Simonov A. N., Volkov R. V., Dvornikov S. V. *Osnovy postroyeniya i funktsionirovaniya uglomernykh sistem koordinatsionnykh istochnikov radioizlucheniya* [Basics of construction and functioning of triangulation emitters location systems]. Saint-Petersburg, Voennaya akademiya svyazi imeni S. M. Budyonnogo Publ., 2017. 248 p. (In Russian).

metri istochnikov radioizlucheniya [Basics of construction and functioning of triangulation emitters location systems]. Saint-Petersburg, Voennaya akademiya svyazi imeni S. M. Budyonnogo Publ., 2017. 248 p. (In Russian).

3. Rembovsky A. M., Ashikhmin A. V., Kozmin B. A. *Avtomatizirovannye sistemy radiokontrolya i ih komponenty* [Automated radio monitoring systems and their components]. Moscow, Goryachaya Liniya — Telekom Publ., 2010. 624 p. (In Russian).
4. Paulraj A., Kailath T. Eigenstructure methods for direction of arrival estimation in the presence of unknown noise fields. *IEEE Transactions on Acoustics Speech and Signal Processing*, 1986, vol. 34, no. 1, pp. 13–20. doi:10.1109/TASSP.1986.1164776
5. Komarov V. F., Nikitchenko V. V. *Metody prostranstvennoj obrabotki radiosignalov* [Methods of spatial processing of radio signals]. Leningrad, Voennaya akademiya svyazi imeni S. M. Budyonnogo Publ., 1989. 278 p. (In Russian).
6. Nehorai A., Paldi E. Vector-sensor array processing for electromagnetic source localization. *IEEE Transactions on Signal Processing*, 1994, vol. 42, no. 2, pp. 376–398. doi:10.1109/78.275610
7. Kozlov A. I., Logvin A. I., Sarychev V. A. *Polyarizaciya radiovoln. Polyarizacionnaya struktura radiolokacionnyh signalov* [Radiowave polarization. Polarization structure of the radar signals]. Moscow, Radiotekhnika Publ., 2005. 704 p. (In Russian).
8. Demichev I. V., Shmakov N. P., Kolesnikov R. V., Ivanov A. V. *Antenna triortogonal'naya* [Triorthogonal Antenna]. Patent RF, no. 2649097, 2018.
9. Demichev I. V., Shmakov N. P., Kolesnikov R. V., Ivanov A. V. Spatial-polarized processing of radio signals in hypercomplex space. *Science Intensive Technologies*, 2018, vol. 19, no. 10, pp. 25–29 (In Russian).
10. Wong K. Direction finding/polarization estimation — dipole and/or loop triad(s). *IEEE Transactions on Aerospace and Electronic Systems*, 2001, vol. 37, no. 2, pp. 679–684. doi:10.1109/7.937478
11. Kitavi D., Wong K., Zou M., Agrawal K. A lower bound of the estimation error of an emitter's direction-of-arrival/polarization, for a collocated triad of orthogonal dipoles/loops that fail randomly. *IET Microwaves, Antennas & Propagation*, 2017, vol. 11, iss. 7, pp. 961–970. doi:10.1049/iet-map.2016.0918
12. Chintagunta S., Ponnusamy P. Integrated polarization and diversity smoothing algorithm for DOD and DOA estimation of coherent targets. *IET Signal Processing*, 2018, vol. 12, iss. 4, p. 447–453. doi:10.1049/iet-spr.2017.0276
13. Khan S., Wong K. Electrically long dipoles in a crossed pair for closed-form estimation of an incident source's polarization. *IEEE Transactions on Antennas and Propagation*, 2019, vol. 67, no. 8, pp. 5569–5581. doi:10.1109/TAP.2019.2916581
14. Zheng G. Two-dimensional DOA estimation for polarization sensitive array consisted of spatially spread crossed-dipole. *IEEE Sensors Journal*, 2018, vol. 18, iss. 12, pp. 5014–5023. doi:10.1109/JSEN.2018.2820168
15. Afraimovich E. L., Chernukhov V. V., Kobzar V. A., Palamartchouk K. Determining polarization parameters and angles of arrival of HF radio signals using three mutually orthogonal antennas. *Radio Science*, 1999, vol. 34, no. 5, pp. 1217–1225. doi:10.1029/1999RS900042
16. Zhangmeng L. DOA and polarization estimation via signal reconstruction with linear polarization-sensitive arrays. *Chinese Journal of Aeronautics*, 2015, vol. 28, iss. 6, pp. 1718–1724. doi:10.1016/j.cja.2015.09.005
17. Raimondi F., Farias R., Michel O., Comon P. Wideband multiple diversity tensor array processing. *IEEE Transactions on Signal Processing*, 2017, vol. 65, iss. 20, pp. 5334–5346. doi:10.1109/TSP.2017.2725219
18. Bogdanovskij S. V., Volkov R. V., Sevidov V. V., Simonov A. N. *Sposob polyarizacionnogo pelengovaniya radiosignalov* [Method of polarisation deprecation of radiosignals]. Patent RF, no. 2624449, 2017.
19. Bogdanovsky S. V., Simonov A. N., Teslevich S. F. A polarization method of spatial radio source direction finding. *Science Intensive Technologies*, 2016, vol. 17, no. 12, pp. 40–43 (In Russian).
20. Dvornikov S. V., Simonov A. N., Konyukhovskiy V. S. Evaluation method of bearing angles in relation to the radio signal sources under interference conditions. *Information and Space*, 2019, no. 1, pp. 6–10 (In Russian).

Исследование процесса обработки зрительной информации в зависимости от ориентации стимулов по многоканальным записям ЭЭГ

А. К. Куц^а, аспирант, orcid.org/0000-0001-6233-2594

В. А. Максименко^а, канд. физ.-мат. наук, старший научный сотрудник, orcid.org/0000-0002-4632-6896, taximekovl@gmail.com

М. В. Храмова^б, канд. пед. наук, доцент, orcid.org/0000-0002-6392-4580

А. Е. Храмов^а, доктор физ.-мат. наук, профессор, orcid.org/0000-0003-2787-2530

^аУниверситет Иннополис, Университетская ул., 1, Иннополис, 420500, Республика Татарстан, РФ

^бСаратовский национальный исследовательский государственный университет им. Н. Г. Чернышевского, Астраханская ул., 83, Саратов, 410012, РФ

Введение: анализ электрической активности нейронной сети коры головного мозга, связанной с обработкой визуальной информации, является одним из наиболее интересных и актуальных вопросов в современной нейронауке. Особое внимание исследователей в данной области привлекает изучение нейронной активности во время обработки сложных визуальных стимулов. **Цель:** исследование процесса обработки сенсорной информации в коре головного мозга на основании регистрируемых сигналов электрической активности (электроэнцефалограмм). **Результаты:** проведен анализ нейронной активности, связанной с обработкой зрительной информации, путем рассмотрения изменения спектральной энергии электроэнцефалограмм в диапазоне 15÷30 Гц. Исследовано влияние сложности визуальных стимулов на особенности пространственно-временной динамики нейронной активности. Обнаружено, что при низкой сложности спектральная амплитуда электроэнцефалограмм в диапазоне 15÷30 Гц увеличивается главным образом в теменной зоне. При увеличении сложности спектральная амплитуда электроэнцефалограмм увеличивается одновременно в различных участках коры, преимущественно в лобной области. **Практическая значимость:** выявленные особенности нейронной динамики могут быть полезны при разработке пассивных интерфейсов мозг-компьютер, осуществляющих мониторинг когнитивного состояния человека и оценку его когнитивной нагрузки в режиме реального времени.

Ключевые слова — обработка зрительной информации, неоднозначность зрительной информации, бета-частотный диапазон, электроэнцефалограмма.

Для цитирования: Куц А. К., Максименко В. А., Храмова М. В., Храмов А. Е. Исследование процесса обработки зрительной информации в зависимости от ориентации стимулов по многоканальным записям ЭЭГ. *Информационно-управляющие системы*, 2020, № 1, с. 73–80. doi:10.31799/1684-8853-2020-1-73-80

For citation: Kuc A. K., Maksimenko V. A., Khramova M. V., Hramov A. E. Study of sensory information processing depending on visual stimulus complexity based on multichannel EEG signals. *Informatsionno-upravliayushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 73–80 (In Russian). doi:10.31799/1684-8853-2020-1-73-80

Введение

Нейронная активность коры головного мозга связана с такими функциями организма, как память [1] и внимание [2], а также обеспечивает реализацию когнитивных функций (обработку сенсорной информации и принятие решений [3, 4]), необходимых для взаимодействия человека с окружающей средой [5–7].

Согласно результатам нейрофизиологических исследований, сенсорная обработка и принятие решения реализуется в головном мозге посредством различных типов нейронной активности [8]. Как было показано в работе [9], сенсорная обработка происходит в течение первых 130–320 мс после предъявления стимула и ассоциируется с нейронной активностью в затылочной коре, тогда как нейронная активность, связанная с принятием ре-

шений, наблюдается позже и наиболее выражена в теменной и лобной областях [10].

Наряду с активностью отдельных областей мозга в работе [11] подчеркивается важная роль коллективной динамики нейронных ансамблей, расположенных в различных областях коры, во время обработки зрительной информации и принятия решений. В то же время, согласно недавнему обзору [12], большинство исследований в данной области основано на анализе нейронной активности отдельных областей, откуда можно заключить, что глубокого понимания механизмов, координирующих нейронные взаимодействия при сенсорной обработке и принятии решений, на данный момент не существует.

В настоящей работе анализируется пространственно-временная эволюция электрической активности головного мозга в процессе обработки


зрительной информации путем рассмотрения спектральной энергии сигналов электроэнцефалограммы (ЭЭГ) в бета-диапазоне (15–30 Гц). Согласно ранее опубликованным работам, особенность нейронной активности в данном частотном диапазоне, с одной стороны, связана с обработкой визуальной информации [13], а с другой стороны, играет важную роль в процессе принятия решений [14, 15].

В качестве экспериментальной парадигмы используется когнитивная задача, подразумевающая восприятие бистабильных визуальных стимулов и их бинарную классификацию в зависимости от интерпретации [16]. Известно, что увеличение неоднозначности визуального стимула влияет на сложность и на время принятия решения. Однако до сих пор неясно, как изменение неоднозначности влияет на динамику нейронной активности головного мозга на этапе сенсорной обработки.

Дизайн нейрофизиологического эксперимента

В экспериментах приняли участие десять здоровых испытуемых (5 мужчин и 5 женщин) в возрасте от 26 до 35 лет с нормальным или скорректированным до нормального зрением. Все они дали информированное письменное согласие перед участием в эксперименте. Испытуемые были ознакомлены с экспериментальным заданием, но не участвовали в экспериментах по крайней мере в последние 6 месяцев до данного эксперимента. Все испытуемые проходили эксперимент в первой половине дня. Ни у одного из испытуемых не наблюдалось недосыпания в предыдущие дни. Каждый участник соблюдал нормальный цикл работы и отдыха с достаточным количеством сна (приблизительно 8 часов сна каждую ночь) в течение недели перед экспериментом. Кроме того, участники не принимали алкоголь или напитки с кофеином и не принимали участие в физических упражнениях за день до эксперимента. Экспериментальные исследования были проведены в соответствии с Хельсинкской декларацией и одобрены местной этической комиссией Университета Иннополис.

В качестве визуальных стимулов использовался куб Неккера [17, 18] — с прозрачными гранями и видимыми ребрами. Испытуемый воспринимает куб Неккера как 3D-объект из-за особого положения ребер (рис. 1). Бистабильность в восприятии такого изображения заключается в интерпретации этого 3D-объекта как ориентированного либо влево, либо вправо в зависимости от контраста различных внутренних ребер куба. Использование такого неоднозначного изображения популярно во



Уровень неоднозначности a

■ *Рис. 1.* Набор визуальных стимулов (кубы Неккера) с разной степенью неоднозначности a

■ *Fig. 1.* The set of visual stimuli (Necker cubes) with the different degree of ambiguity a

многих психологических экспериментах [19, 20] и теоретических моделях [21, 22]. В качестве управляющего параметра a используется контраст трех средних линий, расположенных в левом среднем углу. Значения $a = 1$ и $a = 0$ соответствуют яркости пикселей средних линий: 0 (черный) и 255 (белый). Поэтому контраст определяется как $a = y/255$, где y — уровень яркости средних линий согласно 8-битной палитре серого цвета. В настоящей работе использовались восемь различных изображений куба Неккера (см. рис. 1). Половина из них, $a = \{0,15; 0,25; 0,4; 0,45\}$ — лево-ориентированные, в то время как остальные, $a = \{0,55; 0,6; 0,75; 0,85\}$ — право-ориентированные. Для $a = 0$ и $a = 1$ ориентация куба Неккера может быть легко интерпретирована как левая или правая соответственно, а для $a \approx 0,5$ идентификация фактической ориентации становится более сложной, поскольку мы имеем дело с сильно неоднозначным изображением.

Во время эксперимента куб Неккера располагался в центре экрана монитора на белом фоне. Красная точка в центре куба использовалась для привлечения внимания испытуемого и предотвращения возможных изменений восприятия из-за движений глаз. Стимулы были продемонстрированы на ЖК-мониторе 24" с пространственным разрешением 1920×1080 пикселей и частотой обновления 60 Гц. Яркость монитора составляла 185 кд/м^2 (для белого) и $0,2 \text{ кд/м}^2$ (для черного), статическая контрастность составляла 919:1. Участники эксперимента располагались на расстоянии 70–80 см от монитора, угол обзора составлял примерно 0,25 рад. Размер куба Неккера на мониторе составлял 14,2 см, угловой размер стимула составлял примерно 0,1 рад.

Весь эксперимент длился около 40 мин для каждого участника, включая короткие записи ЭЭГ в состоянии покоя (≈ 4 мин) до и после основной части эксперимента. Во время экспериментальных сеансов кубы с заранее заданными значениями a (из множества, проиллюстрированного на рис. 1) были случайным образом представлены 400 раз (каждый куб с определенной неоднозначностью был представлен около 50 раз).

Участникам было предложено нажать либо левую клавишу левой рукой, либо правую клавишу

правой рукой, чтобы указать первое впечатление об ориентации каждого куба. Так как при последовательном представлении изображений ранее продемонстрированные кубы могут влиять на восприятие последующих, продолжительность демонстрации стимула варьировалась в диапазоне 1÷1,5 с. Кроме того, случайное изменение параметра a также препятствовало стабилизации восприятия. Наконец, чтобы отвлечь внимание наблюдателя и сделать восприятие следующего куба Неккера независимым от предыдущего, между последующими демонстрациями изображений куба были показаны абстрактные изображения в течение 3–5 с.

Известно, что на восприятие и обработку визуальной информации влияют такие факторы, как исходное психофизиологическое состояние и психоэмоциональный фон испытуемых, динамика пространственных, временных и энергетических характеристик зрения испытуемых, а также характеристики стимульной системы (яркость экрана, контраст изображения, угловые размеры стимулов). Тогда как характеристики стимульной среды могут быть зафиксированы для всех испытуемых в группе, индивидуальные различия характеристик восприятия должны быть учтены при планировании экспериментального исследования. В данном контексте для минимизации эффектов, вызванных индивидуальными особенностями, анализ влияния неоднозначности стимула был осуществлен на основе сравнения зависимых выборок. В этом случае восприятие стимулов с высокой и низкой неоднозначностью рассматривалось в рамках каждого субъекта, а затем полученная разница сопоставлялась с разбросом внутри группы, вызванным индивидуальными особенностями испытуемых. Следует также отметить, что состояние испытуемых может изменяться в процессе прохождения эксперимента. В частности, на восприятие будет влиять когнитивное утомление (mental fatigue) [23], а также эффект тренировки [24], вызванный продолжительным выполнением схожих задач. В целях минимизации этих воздействий визуальные стимулы для двух рассматриваемых наборов были выбраны в случайном порядке и моменты их предъявлений были равномерно распределены в течение всего эксперимента.

Регистрация и предварительная обработка электроэнцефалограммы

Сигналы ЭЭГ были получены с использованием метода монополярной регистрации и классической расширенной системы расстановки электродов 10-10. Электрическая активность регистрировалась с помощью 31 электрода, и два электрода

были референтными и располагались на мочках ушей. Заземляющий электрод был расположен чуть выше лба. В эксперименте использовались чашечковые адгезивные электроды Ag/AgCl, помещенные на пасту Tien-20 (Weaver and Company, Колорадо, США). Непосредственно перед началом эксперимента были проведены все необходимые процедуры для повышения проводимости кожи с помощью абразивного геля NuPrep (Weaver and Company, Колорадо, США). Для усиления и аналого-цифрового преобразования сигналов ЭЭГ использовался электроэнцефалограф «Энцефалан-ЭЭГ-19/26» (ООО НПКФ «Медиком», РФ). ЭЭГ-сигналы фильтровались полосовым фильтром с точками отсечения 1 и 100 Гц и режекторным фильтром (50 Гц) с помощью встроенного аппаратно-программного обеспечения.

Записанные сигналы ЭЭГ были сегментированы на наборы из двух отрезков (0,5 с до и 0,5 с после демонстрации каждого куба). Для уменьшения мышечных артефактов участникам предлагалось принять позу, исключающую чрезмерное напряжение мышц шеи. Артефакты, вызванные движением глаз, мышечной активностью и сердечным ритмом, были скорректированы методом разложения сигнала на эмпирические моды [25].

Анализ экспериментальных данных


Для построения модели, описывающей пространственно-временную динамику электрической активности коры головного мозга, была проанализирована спектральная мощность сигналов ЭЭГ в бета-диапазоне частот (15–30 Гц) при помощи непрерывного вейвлет-преобразования. На первом этапе для каждого канала ЭЭГ $X_n(t)$ [Гц] был рассчитан вейвлетный энергетический спектр в диапазоне частот 1÷30 Гц при помощи соотношения $E^n(f, t) = (W^n(f, t))^2$. Здесь $W^n(f, t)$ — комплекснозначный коэффициент вейвлет-преобразования, вычисляемый как

$$W^n(f, t) = \sqrt{f} \int_{t-4/f}^{t+4/f} X_n(t) \psi^*(f, t) dt, \quad (1)$$

где $n = 1, \dots, N$ — номер канала ЭЭГ ($N = 31$ — общее количество каналов, используемых для анализа); символ «*» означает комплексное сопряжение. В качестве материнской вейвлет-функции $\psi(f, t)$ был выбран вейвлет Морле [26], который определяется как

$$\psi(f, t) = \sqrt{f} \pi^{1/4} e^{j\omega_0 f(t-t_0)} e^{f(t-t_0)^2/2}, \quad (2)$$

где $\omega_0 = 2\pi$ — параметр, характеризующий вейвлет-функцию.



■ **Рис. 2.** Интервалы времени, используемые для анализа сигнала ЭЭГ, связанного с восприятием визуального стимула
 ■ **Fig. 2.** Time intervals taken to analyze the EEG signal associated with visual stimulus perception

Затем для бета-диапазона частот значение амплитуды вейвлет-спектра $E_{\beta}^n(t)$ рассчитывалось как

$$E_{\beta}^n(t) = \frac{1}{\Delta f_{\beta}} \int_{\Delta f_{\beta}} E^n(f', t) df', \quad (3)$$

где $\Delta f_{\beta} = 15 \div 30$ Гц. Полученные значения $E_{\beta}^n(t)$ были нормированы на значения $E^n(f, t)$, проинтегрированные в диапазоне $1 \div 30$ Гц, для того чтобы исключить влияние флуктуаций амплитуды ЭЭГ. Временные ряды (3) были рассчитаны для всего эксперимента и затем разбивались на отрезки $\tau_{pre}^i = 0,5$ с и $\tau_{post}^i = 0,5$ с до и после представления i -го визуального стимула соответственно:

$$\left(E_{\beta}^n\right)_{\tau_{pre}^i, \tau_{post}^i}^i = \int_{\tau_{pre}^i, \tau_{post}^i} E_{\beta}^n(t') dt'. \quad (4)$$

Для каждого визуального стимула с определенным значением параметра a разница между $\left(E_{\beta}^n\right)_{\tau_{pre}^i}^i$ и $\left(E_{\beta}^n\right)_{\tau_{post}^i}^i$ для n -го канала ЭЭГ анализировалась статистически на основе 20 предъявлений с помощью t -критерия для зависимых выборок. Уровень значимости был скорректирован с учетом множественных сравнений методом перестановок.

Зависимость амплитуды вейвлет-спектра (3), полученной для канала R_3 , на интервале, соответствующем обработке зрительного стимула, показана на рис. 2. Видно, что для данного канала наблюдается увеличение амплитуды во время обработки стимула τ_{post}^i по сравнению с пре-стимульным периодом τ_{pre}^i .

Полученные результаты

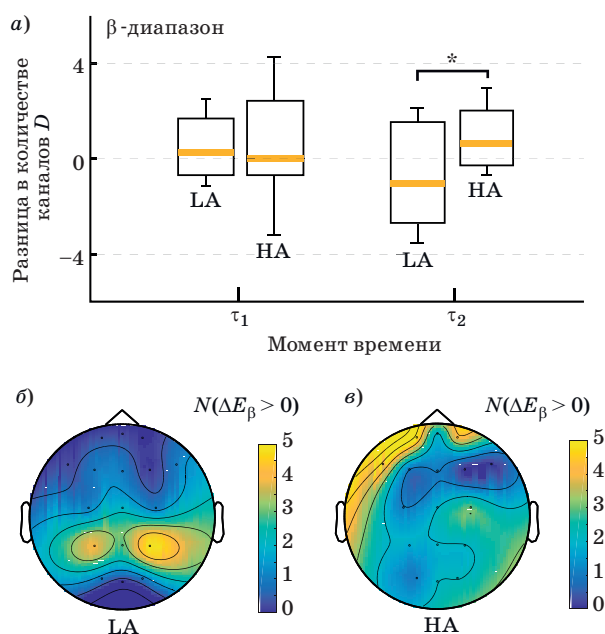
Для исследования влияния сложности визуального стимула все кубы Неккера были разделены на две группы: 1) группа LA, включающая кубы с низкой степенью неоднозначности визуальных стимулов, для которых $a = \{0,15; 0,25; 0,75; 0,85\}$; 2) группа HA, включающая кубы с высокой степенью неоднозначности визуальных стимулов, для которых $a = \{0,4; 0,45; 0,55; 0,6\}$.

При анализе активности головного мозга, связанной с восприятием и обработкой визуального стимула, важным вопросом является корректное определение момента начала ответной реакции на предъявляемый стимул. Для этого используется анализ вызванных потенциалов P300 и N200 [27]. Решение данной задачи наиболее актуально в случае, когда необходимо сопоставить реакцию испытуемого на целевые и нецелевые стимулы [28]. В рамках данной задачи все рассматриваемые стимулы считались целевыми, и было сделано предположение, что изменение характеристик внимания испытуемого равновероятно влияет на восприятие стимулов из двух рассматриваемых наборов. Это предположение основано на том, что стимулы для двух наборов были выбраны случайным образом и равномерно распределены в течение экспериментальной сессии.

Каждая группа включала 80 стимулов (по 20 на каждое значение параметра a). Особенности ЭЭГ были проанализированы и сравнены для стимулов LA и HA в течение двух интервалов времени τ_1 и τ_2 , относящихся к стадии сенсорной обработки (рис. 3). На основе описанного выше метода были выявлены каналы ЭЭГ, демонстрирующие значительное увеличение спектральной амплитуды в бета-диапазоне частот. На рис. 3 показана разница D между числом каналов ЭЭГ, где E_{β} увеличивается, и числом каналов, где E_{β} уменьшается для стимулов LA и HA и двух интервалов времени — τ_1 и τ_2 . Диаграммы отражают распределения этих значений в группе участников (медиана, 25-й и 75-й перцентили) (рис. 3, а).

Видно, что для τ_1 медиана D близка к нулю, что соответствует приблизительно равному числу каналов, характеризующихся увеличением и уменьшением энергии в бета-диапазоне. В этом случае 5/10 испытуемых демонстрируют $D > 0$ для стимулов LA и HA, в то время как 5/10 демонстрируют $D < 0$. Для τ_2 6/10 испытуемых демонстрируют преобладание каналов ЭЭГ с уменьшающейся энергией ($D < 0$) для стимулов LA, и 7/10 испытуемых демонстрируют преобладание каналов ЭЭГ с увеличивающейся амплитудой ($D > 0$) для стимулов HA.

Дисперсионный анализ с коррекцией Гринхауса — Гейсера показывает, что D незначимо изменяется как при изменении сложности



■ **Рис. 3.** Разница D между числом каналов, где амплитуда ЭЭГ в бета-диапазоне E_β увеличивается, и числом каналов, где E_β уменьшается в зависимости от неоднозначности стимулов LA, HA и анализируемого интервала времени τ_1 , τ_2 (a); распределение каналов ЭЭГ, для которых наблюдается увеличение E_β для всех испытуемых в случае восприятия однозначных (б) и неоднозначных (в) стимулов

■ **Fig. 3.** Difference D between the number of EEG channels where beta-activity amplitude E_β increases and those where E_β decreases depending on the ambiguity of the stimuli LA, HA and the time interval τ_1 , τ_2 (a); the distribution of EEG channels, reflecting E_β increase for all subjects for LA (b) and HA (c) stimuli

стимула (HA и LA) ($F_{1,9} = 1,189$, $p = 0,304$), так и между рассматриваемыми интервалами времени ($F_{1,9} = 1,723$, $p = 0,222$). В то же время наблюдается статистически значимый эффект взаимодействия между сложностью стимула и временным интервалом ($F_{1,9} = 10,211$, $p = 0,01$). Это означает, что разница в значениях D для LA- и HA-стимулов различна для рассматриваемых интервалов.

Чтобы оценить изменение D для LA- и HA-стимулов, каждый интервал времени был рассмотрен отдельно с использованием статистического анализа на основе непараметрического критерия Уилкоксона для связанных выборок. В результате было показано, что D незначительно различается между LA- и HA-стимулами в случае τ_1 ($p = 0,919$), но значительно различается для τ_2 ($p = 0,032$). Анализируя каждого испытуемого отдельно, авторы установили, что у 8/10 участников эксперимента наблюдается обнаруженная закономерность.

Полученные результаты свидетельствуют, что динамика амплитуды электрической активности в бета-диапазоне различна при разной сложности визуальных стимулов. Для более сложных стиму-

лов (HA) количество каналов, демонстрирующих увеличение энергии в бета-диапазоне частот, превышает соответствующее количество каналов для более легких (LA) стимулов. Вместе с тем локализация каналов ЭЭГ, для которых обнаружено увеличение амплитуды бета-активности, на поверхности коры также различна для LA- и HA-стимулов. Для однозначных стимулов (LA) (рис. 3, б) спектральная амплитуда ЭЭГ в бета-диапазоне увеличивается главным образом в теменной зоне. В этом случае 8/10 испытуемых демонстрируют увеличение амплитуды бета-активности для каналов P_3 , P_2 , P_4 . Для сложных стимулов (HA) (рис. 3, в) энергия в бета-диапазоне увеличивается одновременно в различных участках коры, преимущественно в лобной области. В этом случае у 7/10 испытуемых этот эффект наблюдается во фронтальной области, у 5/10 — в соматосенсорной области, у 5/10 — в теменно-затылочной области.

Результаты, полученные в рамках данной работы, связаны с нисходящими (top-down) процессами, которые формируются в коре головного мозга и оказывают влияние на процессы восприятия и обработки зрительной информации в более глубоких структурах. Наряду с нисходящими [29], обработка зрительной информации также ассоциируется с восходящими (bottom-up) процессами [30]. Известно, что bottom-up процессы связаны с произвольным вниманием, которое активируется самим по себе фактом появления визуального стимула [31]. Top-down процессы, в свою очередь, связаны с осознанной обработкой стимула. В частности, одним из таких процессов является выборочное внимание (selective attention), которое характеризует способность испытуемого выделять отличительные особенности сенсорной информации, необходимые для принятия решения [32, 33].

Заключение

Результаты проведенных исследований процесса обработки зрительной информации в зависимости от ориентации стимулов (кубов Неккера) по многоканальным записям ЭЭГ выявили следующие закономерности.

1. Для случаев, когда в качестве визуальных стимулов использовались кубы Неккера с низкой степенью неоднозначности, значимое увеличение амплитуды вейвлет-спектра сигналов ЭЭГ в бета-диапазоне наблюдалось в отведениях теменной зоны.

2. Для кубов Неккера с высокой степенью неоднозначности амплитуда вейвлет-спектра сигналов ЭЭГ в бета-диапазоне одновременно увеличивалась в различных областях коры, включая лобную и теменно-затылочную области.

Полученные результаты представляют интерес для фундаментальной нейронауки и имеют потенциал практического использования в контексте реализации пассивных интерфейсов мозг-компьютер, осуществляющих мониторинг когнитивного состояния человека в процессе решения задач, подразумевающих восприятие и обработку зрительной информации.

Литература

1. **Onton J., Delorme A., Makeig S.** Frontal midline EEG dynamics during working memory. *Neuroimage*, 2005, vol. 27(2), pp. 341–356 doi:10.1016/j.neuroimage.2005.04.014
2. **Liu N. H., Chiang C. Y., Chu H. C.** Recognizing the degree of human attention using EEG signals from mobile sensors. *Sensors*, 2013, vol. 13(8), pp. 10273–10286. doi:10.3390/s130810273
3. **Balconi M., Lucchiari C.** Consciousness and arousal effects on emotional face processing as revealed by brain oscillations. A gamma band analysis. *International Journal of Psychophysiology*, 2008, vol. 67(1), pp. 41–46. doi:10.1016/j.ijpsycho.2007.10.002
4. **Sauseng P., Klimesch W., Schabus M., Doppelmayr M.** Fronto-parietal EEG coherence in theta and upper alpha reflect central executive functions of working memory. *International Journal of Psychophysiology*, 2005, vol. 57(2), pp. 97–103. doi:10.1016/j.ijpsycho.2005.03.018
5. **Helfrich R. F., Huang M., Wilson G., Knight R. T.** Prefrontal cortex modulates posterior alpha oscillations during top-down guided visual perception. *Proceedings of the National Academy of Sciences*, 2017, vol. 114(35), pp. 9457–9462. doi:10.1073/pnas.1705965114
6. **Wamain Y., Sahai A., Decroix J., Coello Y., Kalénine S.** Conflict between gesture representations extinguishes μ rhythm desynchronization during manipulable object perception: An EEG study. *Biological Psychology*, 2018, vol. 132, pp. 202–211. doi:10.1016/j.biopsycho.2017.12.004
7. **Kumar G. V., Halder T., Jaiswal A. K., Mukherjee A., Roy D., Banerjee A.** Large scale functional brain networks underlying temporal integration of audio-visual speech perception: An EEG study. *Frontiers in Psychology*, 2016, vol. 7, p. 1558. doi:10.3389/fpsyg.2016.01558
8. **Heekeren H. R., Marrett S., Ungerleider L. G.** The neural systems that mediate human perceptual decision making. *Nature Reviews Neuroscience*, 2008, vol. 9(6), p. 467. doi:10.1038/nrn2374
9. **Mostert P., Kok P., De Lange F. P.** Dissociating sensory from decision processes in human perceptual decision making. *Scientific Reports*, 2015, vol. 5, p. 18253. doi:10.1038/srep18253
10. **Maksimenko V. A., Frolov N. S., Hramov A. E., Runnova A. E., Grubov V. V., Kurths J., Pisarchik A. N.**

Финансовая поддержка

Работа выполнена при поддержке Российского фонда фундаментальных исследований (грант № 18-32-20129), АК персонально поддержан Фондом содействия инновациям (проект № 14346ГУ/2019) в части разработки методов анализа ЭЭГ.

- Neural interactions in a spatially-distributed cortical network during perceptual decision-making. *Frontiers in Behavioral Neuroscience*, 2019, vol. 13, p. 220. doi:10.3389/fnbeh.2019.00220
11. **Siegel M., Engel A. K., Donner T. H.** Cortical network dynamics of perceptual decision-making in the human brain. *Frontiers in Human Neuroscience*, 2011, vol. 5, p. 21. doi:10.3389/fnhum.2011.00021
 12. **Hanks T. D., Summerfield C.** Perceptual decision making in rodents, monkeys, and humans. *Neuron*, 2017, vol. 93(1), pp. 15–31. doi:10.1016/j.neuron.2016.12.003
 13. **Sehatpour P., Molholm S., Schwartz T. H., Mahoney J. R., Mehta A. D., Javitt D. C., Stanton P. K., and Foxe J. J.** A human intracranial study of long-range oscillatory coherence across a frontal-occipital-hippocampal brain network during visual object processing. *Proceedings of the National Academy of Sciences*, 2008, vol. 105(11), pp. 4399–4404. doi:10.1073/pnas.0708418105
 14. **Chand G. B., Dhamala M.** The salience network dynamics in perceptual decision-making. *Neuroimage*, 2016, vol. 134, pp. 85–93. doi:10.1016/j.neuroimage.2016.04.018
 15. **Chand G. B., Dhamala M.** Interactions between the anterior cingulate-insula network and the fronto-parietal network during perceptual decision-making. *Neuroimage*, 2017, vol. 152, pp. 381–389. doi:10.1016/j.neuroimage.2017.03.014
 16. **Maksimenko V. A., Runnova A. E., Zhuravlev M. O., Makarov V. V., Nedayvozov V., Grubov V. V., Pchelintseva S. V., Hramov A. E., Pisarchik A. N.** Visual perception affected by motivation and alertness controlled by a noninvasive brain-computer interface. *PloS One*, 2017, vol. 12(12), p. e0188700. <https://doi.org/10.1371/journal.pone.0188700>
 17. **Kornmeier J., Friedel E., Wittmann M., & Atmanspacher H.** EEG correlates of cognitive time scales in the Necker — Zeno model for bistable perception. *Consciousness and Cognition*, 2017, vol. 53, pp. 136–150. doi:10.1016/j.concog.2017.04.011
 18. **Hramov A. E., Maksimenko V. A., Pchelintseva S. V., Runnova A. E., Grubov V. V., Musatov V. Y., Zhuravlev M. O., Koronovskii A. A., Pisarchik A. N.** Classifying the perceptual interpretations of a bistable image using EEG and artificial neural networks. *Frontiers in Neuroscience*, 2017, vol. 11, p. 674. doi:10.3389/fnins.2017.00674

19. Kornmeier J., Pfäffle M., Bach M. Necker cube: stimulus-related (low-level) and percept-related (high-level) EEG signatures early in occipital cortex. *Journal of Vision*, 2011, vol. 11(9), p. 12. doi:10.1167/11.9.12
20. Pisarchik A. N., Jaimes-Reátegui R., Magallón-García C. A., Castillo-Morales C. O. Critical slowing down and noise-induced intermittency in bistable perception: bifurcation analysis. *Biological Cybernetics*, 2014, vol. 108(4), pp. 397–404. doi:10.1007/s00422-014-0607-5
21. Pisarchik A. N., Bashkirtseva I. A., Ryashko L. B. Controlling bistability in a stochastic perception model. *The European Physical Journal Special Topics*, 2015, vol. 224(8), pp. 1477–1484. doi:10.1140/epjst/e2015-02473-0
22. Pisarchik A. N., Bashkirtseva I., Ryashko L. Stochastic sensitivity of a bistable energy model for visual perception. *Indian Journal of Physics*, 2017, vol. 91(1), pp. 57–62. doi:10.1007/s12648-016-0881-2
23. Langner R., Steinborn M. B., Chatterjee A., Sturm W., Willmes K. Mental fatigue and temporal preparation in simple reaction-time performance. *Acta Psychologica*, 2010, vol. 133(1), pp. 64–72. doi:10.1016/j.actpsy.2009.10.001
24. Yang F., Wu Q., Li S. Learning-induced uncertainty reduction in perceptual decisions is task-dependent. *Frontiers in Human Neuroscience*, 2014, vol. 8, p. 282. doi:10.3389/fnhum.2014.00282
25. Грубов В. В., Руннова А. Е., Храмов А. Е. Адаптивная фильтрация физиологических артефактов на сигналах электроэнцефалограмм человека с использованием разложения по эмпирическим модам. *Журнал технической физики*, 2018, т. 88, № 5, с. 782–790. doi:10.21883/ЖТФ.2018.05.45908.2304
26. Hramov A. E., Koronovskii A. A., Makarov V. A., Pavlov A. N., Sitnikova E. *Wavelets in Neuroscience*. Springer Heidelberg New York Dordrecht London, 2015. 314 p. doi:10.1007/978-3-662-43850-3
27. Джос Ю. С., Калинина Л. П. Когнитивные вызванные потенциалы в нейрофизиологических исследованиях (обзор). *Журнал медико-биологических исследований*, 2018, т. 6(3), с. 223–235. doi:10.17238/issn2542-1298.2018.6.3.223
28. Басюл И. А., Каплан А. Я. Изменения N200 и P300 компонентов потенциалов, связанных с событиями, при варьировании условий внимания в системе ВСИ. *Журнал высшей нервной деятельности им. И. П. Павлова*, 2014, т. 64(2), с. 159. doi:10.7868/S004446771402004X
29. Rock I., Hall S., Davis J. Why do ambiguous figures reverse? *Acta Psychologica*, 1994, vol. 87(1), pp. 33–59. doi:10.1016/0001-6918(94)90065-5
30. Toppino T. C., Long G. M. Selective adaptation with reversible figures: don't change that channel. *Perception & Psychophysics*, 1987, vol. 42(1), pp. 37–48. doi:10.3758/BF03211512
31. Buschman T. J., Miller E. K. Top-down versus bottom-up control of attention in the prefrontal and posterior parietal cortices. *Science*, 2007, vol. 315(5820), pp. 1860–1862. doi:10.1126/science.1138071
32. Gazzaley A., Nobre A. C. Top-down modulation: bridging selective attention and working memory. *Trends in Cognitive Sciences*, 2012, vol. 16(2), pp. 129–135. doi:10.1016/j.tics.2011.11.014
33. Schafer R. J., Moore T. Selective attention from voluntary control of neurons in prefrontal cortex. *Science*, 2011, vol. 332(6037), pp. 1568–1571. doi:10.1126/science.1199892

UDC 612.822.3, 57.087.1

doi:10.31799/1684-8853-2020-1-73-80

Study of sensory information processing depending on visual stimulus complexity based on multichannel EEG signalsA. K. Kuc^a, Post-Graduate Student, orcid.org/0000-0001-6233-2594V. A. Maksimenko^a, PhD, Phys.-Math., Senior Researcher, orcid.org/0000-0002-4632-6896, maximekovl@gmail.comM. V. Khramova^b, PhD, Ped., Associate Professor, orcid.org/0000-0002-6392-4580A. E. Hramov^a, Dr. Sc., Phys.-Math., Professor, orcid.org/0000-0003-2787-2530^aInnopolis University, 1, Universitetskaya St., 420500, Innopolis, Russian Federation^bSaratov State University named after N. G. Chernyshevsky, 83, Astrakhanskaya St., 410012, Saratov, Russian Federation

Introduction: Analysis of electrical activity in the cortical neural network during the processing of visual information is one of the most interesting issues in modern neuroscience. The particular attention of the researchers is attracted by the study of neural activity during complex visual stimuli processing. **Purpose:** Studying the process of sensory information processing in the cortical neural network based on recorded electrical activity signals (EEG). **Results:** We have studied neural activity during visual information processing based on the stimulus-related change in the spectral EEG energy in the 15–30 Hz frequency band. Using the developed approach, we analyzed the influence of the visual stimulus complexity on the features of spatio-temporal neural activity. It has been found that at low complexity the spectral amplitude of the EEG in the range of 15–30 Hz increases mainly in the parietal zone. With increasing complexity, the spectral amplitude of the EEG increases simultaneously in different parts of the cortex, mainly in the frontal region. **Practical relevance:** The identified features of neural dynamics can be used in the development of passive brain-computer interfaces to monitor a person's cognitive state and evaluate the cognitive load in real time.

Keywords — visual information processing, ambiguity of visual information, beta-frequency range, electroencephalogram (EEG).

For citation: Куч А. К., Максимова В. А., Храмова М. В., Храмов А. Е. Study of sensory information processing depending on visual stimulus complexity based on multichannel EEG signals. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 1, pp. 73–80 (In Russian). doi:10.31799/1684-8853-2020-1-73-80

References

- Onton J., Delorme A., Makeig S. Frontal midline EEG dynamics during working memory. *Neuroimage*, 2005, vol. 27(2), pp. 341–356. doi:10.1016/j.neuroimage.2005.04.014
- Liu N. H., Chiang C. Y., Chu H. C. Recognizing the degree of human attention using EEG signals from mobile sensors. *Sensors*, 2013, vol. 13(8), pp. 10273–10286. doi:10.3390/s130810273
- Balconi M., Lucchiari C. Consciousness and arousal effects on emotional face processing as revealed by brain oscillations. A gamma band analysis. *International Journal of Psychophysiology*, 2008, vol. 67(1), pp. 41–46. doi:10.1016/j.ijpsycho.2007.10.002
- Sauseng P., Klimesch W., Schabus M., Doppelmayr M. Fronto-parietal EEG coherence in theta and upper alpha reflect central executive functions of working memory. *International Journal of Psychophysiology*, 2005, vol. 57(2), pp. 97–103. doi:10.1016/j.ijpsycho.2005.03.018
- Helfrich R. F., Huang M., Wilson G., Knight R. T. Prefrontal cortex modulates posterior alpha oscillations during top-down guided visual perception. *Proceedings of the National Academy of Sciences*, 2017, vol. 114(35), pp. 9457–9462. doi:10.1073/pnas.1705965114
- Wamain Y., Sahai A., Decroix J., Coello Y., Kaléline S. Conflict between gesture representations extinguishes μ rhythm desynchronization during manipulable object perception: An EEG study. *Biological Psychology*, 2018, vol. 132, pp. 202–211. doi:10.1016/j.biopsycho.2017.12.004
- Kumar G. V., Halder T., Jaiswal A. K., Mukherjee A., Roy D., Banerjee A. Large scale functional brain networks underlying temporal integration of audio-visual speech perception: An EEG study. *Frontiers in Psychology*, 2016, vol. 7, p. 1558. doi:10.3389/fpsyg.2016.01558
- Heekeren H. R., Marrett S., Ungerleider L. G. The neural systems that mediate human perceptual decision making. *Nature Reviews Neuroscience*, 2008, vol. 9(6), p. 467. doi:10.1038/nrn2374
- Mostert P., Kok P., De Lange F. P. Dissociating sensory from decision processes in human perceptual decision making. *Scientific Reports*, 2015, vol. 5, p. 18253. doi:10.1038/srep18253
- Maksimenko V. A., Frolov N. S., Hramov A. E., Runnova A. E., Grubov V. V., Kurths J., Pisarchik A. N. Neural interactions in a spatially-distributed cortical network during perceptual decision-making. *Frontiers in Behavioral Neuroscience*, 2019, vol. 13, p. 220. doi:10.3389/fnbeh.2019.00220
- Siegel M., Engel A. K., Donner T. H. Cortical network dynamics of perceptual decision-making in the human brain. *Frontiers in Human Neuroscience*, 2011, vol. 5, p. 21. doi:10.3389/fnhum.2011.00021
- Hanks T. D., Summerfield C. Perceptual decision making in rodents, monkeys, and humans. *Neuron*, 2017, vol. 93(1), pp. 15–31. doi:10.1016/j.neuron.2016.12.003
- Sehatpour P., Molholm S., Schwartz T. H., Mahoney J. R., Mehta A. D., Javitt D. C., Stanton P. K., and Foxe J. J. A human intracranial study of long-range oscillatory coherence across a frontal–occipital–hippocampal brain network during visual object processing. *Proceedings of the National Academy of Sciences*, 2008, vol. 105(11), pp. 4399–4404. doi:10.1073/pnas.0708418105
- Chand G. B., Dhamala M. The salience network dynamics in perceptual decision-making. *Neuroimage*, 2016, vol. 134, pp. 85–93. doi:10.1016/j.neuroimage.2016.04.018
- Chand G. B., Dhamala M. Interactions between the anterior cingulate-insula network and the fronto-parietal network during perceptual decision-making. *Neuroimage*, 2017, vol. 152, pp. 381–389. doi:10.1016/j.neuroimage.2017.03.014
- Maksimenko V. A., Runnova A. E., Zhuravlev M. O., Makarov V. V., Nedayvozov V., Grubov V. V., Pchelintseva S. V., Hramov A. E., Pisarchik A. N. Visual perception affected by motivation and alertness controlled by a noninvasive brain-computer interface. *PLoS One*, 2017, vol. 12(12), p. e0188700. <https://doi.org/10.1371/journal.pone.0188700>
- Kornmeier J., Friedel E., Wittmann M., & Atmanspacher H. EEG correlates of cognitive time scales in the Necker — Zeno model for bistable perception. *Consciousness and Cognition*, 2017, vol. 53, pp. 136–150. doi:10.1016/j.concog.2017.04.011
- Hramov A. E., Maksimenko V. A., Pchelintseva S. V., Runnova A. E., Grubov V. V., Musatov V. Y., Zhuravlev M. O., Koronovskii A. A., Pisarchik A. N. Classifying the perceptual interpretations of a bistable image using EEG and artificial neural networks. *Frontiers in Neuroscience*, 2017, vol. 11, p. 674. doi:10.3389/fnins.2017.00674
- Kornmeier J., Pfäffle M., Bach M. Necker cube: stimulus-related (low-level) and percept-related (high-level) EEG signatures early in occipital cortex. *Journal of Vision*, 2011, vol. 11(9), p. 12. doi:10.1167/11.9.12
- Pisarchik A. N., Jaimes-Reátegui R., Magallón-García C. A., Castillo-Morales C. O. Critical slowing down and noise-induced intermittency in bistable perception: bifurcation analysis. *Biological Cybernetics*, 2014, vol. 108(4), pp. 397–404. doi:10.1007/s00422-014-0607-5
- Pisarchik A. N., Bashkirtseva I. A., Ryashko L. B. Controlling bistability in a stochastic perception model. *The European Physical Journal Special Topics*, 2015, vol. 224(8), pp. 1477–1484. doi:10.1140/epjst/e2015-02473-0
- Pisarchik A. N., Bashkirtseva I., Ryashko L. Stochastic sensitivity of a bistable energy model for visual perception. *Indian Journal of Physics*, 2017, vol. 91(1), pp. 57–62. doi:10.1007/s12648-016-0881-2
- Langner R., Steinborn M. B., Chatterjee A., Sturm W., Willmes K. Mental fatigue and temporal preparation in simple reaction-time performance. *Acta Psychologica*, 2010, vol. 133(1), pp. 64–72. doi:10.1016/j.actpsy.2009.10.001
- Yang F., Wu Q., Li S. Learning-induced uncertainty reduction in perceptual decisions is task-dependent. *Frontiers in Human Neuroscience*, 2014, vol. 8, p. 282. doi:10.3389/fnhum.2014.00282
- Grubov V. V., Runnova A. E., Hramov A. E. Adaptive filtration of physiological artifacts in EEG signals in humans using empirical mode decomposition. *Technical Physics*, 2018, vol. 63(5), pp. 759–767. <https://doi.org/10.1134/S1063784218050110>
- Hramov A. E., Koronovskii A. A., Makarov V. A., Pavlov A. N., Sitnikova E. *Wavelets in Neuroscience*. Springer Heidelberg New York Dordrecht London, 2015. 314 p. doi:10.1007/978-3-662-43850-3
- Dzhos Yu. S., Kalinina L. P. Cognitive event-related potentials in neurophysiology research (Review). *Journal of Medical and Biological Research*, 2018, vol. 6(3), pp. 223–235. doi:10.17238/issn2542-1298.2018.6.3.223
- Basyul I. A., Kaplan A. Y. Changes in N200 and P300 components of event-related potentials under varying attention conditions in the BCI system. *I. P. Pavlov Journal of Higher Nervous Activity*, 2014, vol. 64(2), p. 159. doi:10.7868/S004446771402004X
- Rock I., Hall S., Davis J. Why do ambiguous figures reverse? *Acta Psychologica*, 1994, vol. 87(1), pp. 33–59. doi:10.1016/0001-6918(94)90065-5
- Toppino T. C., Long G. M. Selective adaptation with reversible figures: don't change that channel. *Perception & Psychophysics*, 1987, vol. 42(1), pp. 37–48. doi:10.3758/BF03211512
- Buschman T. J., Miller E. K. Top-down versus bottom-up control of attention in the prefrontal and posterior parietal cortices. *Science*, 2007, vol. 315(5820), pp. 1860–1862. doi:10.1126/science.1138071
- Gazzaley A., Nobre A. C. Top-down modulation: bridging selective attention and working memory. *Trends in Cognitive Sciences*, 2012, vol. 16(2), pp. 129–135. doi:10.1016/j.tics.2011.11.014
- Schafer R. J., Moore T. Selective attention from voluntary control of neurons in prefrontal cortex. *Science*, 2011, vol. 332(6037), pp. 1568–1571. doi:10.1126/science.1199892

Памяти

Н. Н. Красильникова



6 февраля 2020 г. на 94-м году ушел из жизни выдающийся ученый, профессор Санкт-Петербургского государственного университета аэрокосмического приборостроения, доктор технических наук Николай Николаевич Красильников.

Его жизненный путь был успешен, но начинался трудно. В годы блокады он остался без родителей и с 15 лет начал самостоятельную жизнь. Школа рабочей молодежи, Ленинградский политехнический институт, который закончил в марте 1950 г. по специальности «Техническая физика», аспирантура Научно-исследовательского института телевидения (в прошлом ВНИИТ). В 1952 г. Н. Н. Красильников, досрочно закончив аспирантуру, защитил кандидатскую диссертацию. В 1954 г. он перешел на должность доцента Ленинградского института авиационного приборостроения (ныне Санкт-Петербургский государственный университет аэрокосмического приборостроения), где затем возглавил кафедру, которой успешно заведовал более 36 лет. В 1963 г. защитил диссертацию на соискание ученой степени доктора технических наук. В 1965 г. был утвержден в ученом звании профессора. На протяжении многих лет Н. Н. Красильников входил в научный совет АН СССР по проблеме «Статистическая радиофизика».

Н. Н. Красильников являлся одним из ведущих в стране специалистов в области теории систем передачи, обработки и восприятия изображений и одним из основателей цифрового телевидения в СССР. На руководимой им кафедре радиопередающих и телевизионных устройств Ленинградского института авиационного приборостроения были организованы две отраслевые лаборатории. Молодые, талантливые преподаватели и научные сотрудники кафедры активно занимались научными исследованиями в области

космического и цифрового телевидения и опытно-конструкторскими разработками. На базе этих научных исследований сотрудниками кафедры было защищено более 20 кандидатских диссертаций, получено более сотни авторских свидетельств на изобретения.

В области разработки телевизионных методов измерения параметров и траекторий движения летательных аппаратов работы велись совместно с Летно-исследовательским институтом им. М. М. Громова. В результате выполненных под его руководством научно-исследовательских работ были существенно улучшены помехоустойчивость и качество информации в системах телевидения, космического телевидения, дистанционного зондирования Земли, технического зрения.

Разработанная Н. Н. Красильниковым модель согласованной фильтрации определила основное направление развития совместных с Институтом физиологии им. И. П. Павлова исследований в области распознавания образов в зрительной системе человека. Эти работы оказали огромное влияние на развитие измерений функциональных возможностей ахроматических и хроматических каналов зрительной системы человека.

Н. Н. Красильников впервые создал математические модели работы механизмов, лежащих в основе психофизических законов зрительной системы. Использование разработанных функциональных моделей зрения позволило Н. Н. Красильникову вывести аналитическим путем формулы для целого ряда законов, установленных ранее экспериментальным путем, среди которых флуктуационный закон, закон Вебера — Фехнера, зависимости, экспериментально полученные Лоури, и др.

Исследования в области построения модели зрения получателя информации были положе-

ны в основу разработанной им статистической теории передачи изображений, что позволило разработать чрезвычайно важный для практического использования метод автоматизированного проектирования систем передачи изображений с учетом свойств зрения наблюдателя.

Николай Николаевич Красильников создал научную школу, получившую широкое международное признание. Для этой школы характерна оригинальность идей, их глубокая проработка от фундаментальных исследований до практического воплощения и внедрения в промышленность, медицину и другие сферы. Огромное значение в становлении специалистов в нашей стране имеют написанные Н. Н. Красильниковым по результатам выполненных им научных исследований книги, в том числе «Помехоустойчивость телевизионных систем», «Статистическая теория передачи изображений», «Теория передачи и восприятия изображений», «Цифровая обработка 2D- и 3D-изображений» и другие. Большой интерес у специалистов всегда вызывали его статьи, публиковавшиеся в таких авторитетных изданиях, как «Оптический журнал», «Автометрия», «Информационно-управляющие системы». Всего из-под его пера вышло около 300 научных публикаций. Ему принадлежат 30 авторских свидетельств на изобретения и разработки. В последние годы он увлеченно занимался исследованиями в области конвертации двумерных изображений и цифрового видео в трехмерный формат. Именно этой проблеме посвящены его статьи последних лет, патент и главы монографии, которая, к сожалению, осталась незавершенной.

Николай Николаевич был высокоодаренным человеком, обладая еще и невероятной работоспособностью. Он мог сформулировать научную задачу, а затем полностью самостоятельно пройти все этапы ее решения, включая написание компьютерных программ и выполнение подчас весьма трудоемких экспериментов.

Н. Н. Красильников был блестящим лектором, прекрасным педагогом, внесшим большой вклад в формирование научного потенциала России и целого ряда стран. Им подготовлены более 25 кандидатов технических наук. Все его выступления и на научных конференциях, и на торжественных мероприятиях были необычайно яркими, привлекающими к себе всеобщее внимание. Участвуя в международных конференциях, он выступал в ведущих университетах Великобритании, Франции, США, Нидерландов, достойно представляя российскую науку.

Он любил работать, а отдыхом для него служили его разносторонние увлечения: в юности — альпинизмом, литературой, в более зрелом возрасте — историей, живописью и классической музыкой. Николай Николаевич был человеком невероятной эрудиции и при этом он всегда был безупречно вежлив и деликатен в общении. Всю жизнь он любил путешествовать и объехал около 30 стран.

Николай Николаевич Красильников награжден пятнадцатью медалями, в том числе медалью «За оборону Ленинграда». В 1992 г. ему было присуждено звание «Заслуженный деятель науки и техники РФ», он занесен в Книгу Почета университета, удостоен почетного звания «Заслуженный профессор ГУАП». В 2009 г. Н. Н. Красильников стал лауреатом премии Правительства РФ в области образования. Научная и педагогическая деятельность Н. Н. Красильникова получили заслуженное мировое признание. Его биография неоднократно включалась в каталоги Who's Who американским издательством Marquis Who's Who, а также Международным биографическим центром в Кембридже, Великобритания. Для всех, кто работал вместе с Николаем Николаевичем, он всегда служил образцом человека безукоризненной честности и высокого достоинства, эталоном блестящего сочетания выдающегося ученого и талантливого педагога.

*Коллеги, друзья, редакция журнала
«Информационно-управляющие системы»*

АБРАМОВ
Павел
Сергеевич



Студент бакалавриата, член научно-учебной группы «Интернет вещей и киберфизические системы» Московского института электроники и математики им. А. Н. Тихонова Национального исследовательского университета «Высшая школа экономики». Является автором пяти научных публикаций. Область научных интересов — Интернет вещей, анализ данных, машинное обучение, обработка естественного языка. Эл. адрес: uncle.decart@gmail.com

АЛЁХИН
Максим
Дмитриевич



Начальник отдела биомедицинской техники и технологий АО «НПО «Электронное приборостроение», Москва. В 2012 году закончил магистратуру Московского государственного технического университета им. Н. Э. Баумана по специальности «Биомедицинская инженерия». В 2014 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором более 90 научных публикаций и патентов. Область научных интересов — системный анализ, распознавание образов, биомедицинская инженерия, эргатические системы, человеческий фактор. Эл. адрес: maksim.alekhin@gmail.com

БЛАУНШТЕЙН
Натан
Шаевич



Профессор-эмеритус кафедры систем связи инженерного факультета Негевского университета им. Бен-Гуриона, Беэр-Шева, Израиль. В 1972 году окончил Томский государственный университет по специальности «Радиофизика и электроника, включая квантовую». В 1991 году защитил диссертацию на соискание ученой степени доктора физико-математических наук. Является автором около 200 научных публикаций, в том числе 12 монографий, пяти патентов и трех изобретений. Область научных интересов — радиофизика, системы проводной и беспроводной связи, радары, оптика и лидары. Эл. адрес: nathan.blaunstein@hotmail.com

БОГОМОЛОВ
Алексей
Валерьевич



Доктор технических наук, профессор, ведущий научный сотрудник Федерального медицинского биофизического центра им. А. И. Бурназяна, Москва, Лауреат премии Правительства РФ в области науки и техники. В 2006 году защитил диссертацию на соискание ученой степени доктора технических наук. Является автором более 200 научных публикаций и более 60 патентов на изобретения и полезные модели. Область научных интересов — прикладная математика, метрология здоровья, обработка информации, медицинская кибернетика, принятие решений, эргономика, радиотехника, системный анализ, информационные технологии. Эл. адрес: a.v.bogomolov@gmail.com

БРАНИЦКИЙ
Александр
Александрович



Старший научный сотрудник лаборатории проблем компьютерной безопасности Санкт-Петербургского института информатики и автоматизации РАН. В 2012 году окончил с отличием Санкт-Петербургский государственный университет по специальности «Математическое обеспечение и администрирование информационных систем». В 2018 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором более 35 научных публикаций. Область научных интересов — искусственный интеллект, компьютерные сети, информационная безопасность, функциональное программирование, теория формальных языков и компиляторов. Эл. адрес: branitskiy@comsec.spb.ru

БРОНФМАН
Ирина



Ассистент инженерного колледжа Шамун, Ашдод, помощник преподавателя кафедры систем связи Негевского университета им. Бен-Гуриона, Беэр-Шева, Израиль. В 2011 году окончила бакалавриат инженерного колледжа Шамун, Ашдод, Израиль, по специальности «Электротехника и электроника со специализацией в системах связи», в 2017 году — магистратуру инженерного факультета Негевского университета им. Бен-Гуриона, Беэр-Шева, Израиль, по специальности «Системы связи». Является автором десяти научных публикаций. Область научных интересов — беспроводная связь, маскирование ошибок при анализе и обработке изображений и видео, спутниковая связь. Эл. адрес: irinamo@post.bgu.ac.il

ВОСКОВ
Леонид
Сергеевич



Старший научный сотрудник научной лаборатории Интернета вещей и киберфизических систем, профессор-исследователь Московского института электроники и математики им. А. Н. Тихонова Национального исследовательского университета «Высшая школа экономики». В 1968 году окончил Московский институт электронного машиностроения по специальности «Счетно-решающие приборы и устройства». В 1974 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором более 100 научных публикаций. Область научных интересов — интернет вещей и киберфизические системы.
Эл. адрес: lvoskov@hse.ru

ГРАЧЕВ
Петр
Григорьевич



Программист факультета информационных технологий и программирования Университета ИТМО, Санкт-Петербург. В 2019 году окончил Национальный исследовательский университет ИТМО по специальности «Прикладная математика и информатика». Является автором пяти научных публикаций. Область научных интересов — рекуррентные нейронные сети, теория автоматов.
Эл. адрес: grachev239@gmail.com

ДВОРНИКОВ
Сергей
Викторович



Профессор кафедры радиосвязи Военной академии связи им. С. М. Буденного, Санкт-Петербург, заслуженный изобретатель Российской Федерации. В 1998 году окончил Военную академию связи им. С. М. Буденного по специальности «Организация применения и эксплуатации радиоэлектронных систем». В 2001 году защитил диссертацию на соискание ученой степени доктора технических наук. Является автором 190 научных публикаций и 100 патентов на изобретения. Область научных интересов — теория связи, помехоустойчивые радиосистемы.
Эл. адрес: practicsdv@yandex.ru

ДЖУВИЛЕР
Ирит



Заведующая кафедрой электротехники и электроники, старший преподаватель Технического колледжа им. Сами Шамуна, Ашдод, Израиль. В 1995 году окончила магистратуру Негевского университета им. Бен-Гуриона, Израиль, по специальности «Электротехника и вычислительная техника». В 2004 году защитила диссертацию на соискание ученой степени доктора наук (PhD) в области электротехники и физической электроники в Тель-Авивском университете. Является автором 30 публикаций. Область научных интересов — нелинейная оптика и нанофотоника.
Эл. адрес: iritj@sce.ac.il

ДОЙНИКОВА
Елена
Владимировна



Старший научный сотрудник лаборатории проблем компьютерной безопасности Санкт-Петербургского института информатики и автоматизации РАН. В 2009 году окончила с отличием Санкт-Петербургский государственный электротехнический университет ЛЭТИ по специальности «Компьютерная безопасность». В 2017 году защитила диссертацию на соискание ученой степени кандидата технических наук. Является автором более 70 научных публикаций. Область научных интересов — безопасность компьютерных сетей, в том числе анализ защищенности и поддержка принятия решений по реагированию на кибератаки, интеллектуальный анализ данных.
Эл. адрес: doynikova@comsec.spb.ru

ИСХАКОВА
Анастасия
Олеговна



Старший научный сотрудник лаборатории киберфизических систем Института проблем управления им. В. А. Трапезникова РАН, Москва. В 2013 году окончила Томский государственный университет управления и радиоэлектроники по специальности «Комплексное обеспечение информационной безопасности автоматизированных систем». В 2016 году защитила диссертацию на соискание ученой степени кандидата технических наук. Является автором более 35 научных публикаций и 10 зарегистрированных программ для ЭВМ. Область научных интересов — информационная безопасность, информационные технологии, интеллектуальная обработка данных, обработка естественного языка, анализа медиаконтента, принятие решений и др.
Эл. адрес: iao@ipu.ru

**КОНЮХОВСКИЙ
Владимир
Самуилович**



Профессор кафедры математики Военной академии связи им. С. М. Буденного, Санкт-Петербург.

В 1961 году окончил Ленинградский политехнический институт по специальности «Технология машиностроения, металлорежущие станки и инструменты».

В 1971 году защитил диссертацию на соискание ученой степени кандидата физико-математических наук.

Является автором 78 научных публикаций и одного патента на изобретение.

Область научных интересов — математическая статистика, методы оптимизации, компьютерная диагностика, нейронные сети.

Эл. адрес:
konukhovsky@yandex.ru

**КОТЕНКО
Игорь
Витальевич**



Профессор, главный научный сотрудник, заведующий лабораторией проблем компьютерной безопасности Санкт-Петербургского института информатики и автоматизации РАН.

В 1983 году окончил Военно-космическую академию им. А. Ф. Можайского по специальности «Математическое обеспечение автоматизированных систем управления», в 1987 году — Военную академию связи по специальности «Инженерная автоматизированных систем управления».

В 1999 году защитил диссертацию на соискание ученой степени доктора технических наук.

Является автором более 500 научных публикаций.

Область научных интересов — безопасность компьютерных сетей, обнаружение компьютерных атак, межсетевые экраны и др.
Эл. адрес: ivkote@comsec.spb.ru

**КУЦ
Александр
Константинович**



Аспирант кафедры информационной безопасности автоматизированных систем Саратовского государственного технического университета им. Гагарина Ю. А. В 2019 году окончил магистратуру Саратовского государственного технического университета им. Гагарина Ю. А. по специальности «Мехатроника и робототехника».

Является автором пяти научных публикаций и одной программы для ЭВМ.

Область научных интересов — методы анализа нейрофизиологических сигналов, нейронаука, методы математического моделирования робототехнических систем.

Эл. адрес: kuc1995@mail.ru

**МАКСИМЕНКО
Владимир
Александрович**



Доцент Саратовского государственного технического университета им. Гагарина Ю. А., старший научный сотрудник научно-образовательного центра «Нелинейная динамика сложных систем».

В 2012 году окончил Саратовский государственный университет им. Н. Г. Чернышевского по специальности «Физика открытых нелинейных систем».

В 2015 году защитил диссертацию на соискание ученой степени кандидата физ.-мат. наук.

Является автором более 50 научных публикаций.

Область научных интересов — анализ устойчивости динамических режимов, реализующихся в пространственно-распределенных системах различной природы, и др.

Эл. адрес:
maximenkovl@gmail.com

**МУРАВЬЕВ
Сергей
Борисович**



Программист факультета информационных технологий и программирования Университета ИТМО, Санкт-Петербург.

В 2016 году окончил Университет ИТМО по специальности «Прикладная математика и информатика».

В 2019 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором десяти научных публикаций и одного свидетельства о регистрации программ для ЭВМ.

Область научных интересов — автоматическое машинное обучение, задачи обучения без учителя, метаобучение.

Эл. адрес: mursmail@gmail.com

**ПОЛЯКОВ
Евгений
Викторович**



Аспирант, эксперт научной лаборатории Интернета вещей и киберфизических систем Московского института электроники и математики им. А. Н. Тихонова Национального исследовательского университета «Высшая школа экономики».

В 2013 году окончил магистратуру Южного федерального университета по специальности «Фундаментальная информатика и информационные технологии».

Является автором более 20 научных публикаций.

Область научных интересов — анализ данных, машинное обучение, обработка естественного языка.

Эл. адрес: epolyakov@hse.ru

**ПОЛЯКОВ
Сергей
Викторович**



Аспирант Национального исследовательского университета «Московский авиационный институт».

В 2014 году окончил магистратуру Таганрогского технологического института Южного федерального университета по специальности «Электроника и нанoeлектроника».

Является автором 10 научных публикаций.

Область научных интересов — анализ данных, машинное обучение, распознавание образов, обработка изображений.

Эл. адрес: s.polyakov@mai.ru

**СИМОНОВ
Алексей
Николаевич**



Докторант Военной академии связи им. С. М. Буденного, Санкт-Петербург.

В 1993 году окончил Киевское высшее инженерное радиотехническое училище противовоздушной обороны по специальности «Радиоэлектронные средства».

В 2003 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором 50 научных публикаций и шести патентов на изобретения.

Область научных интересов — пеленгование и определение координат источников радиоизлучений.

Эл. адрес: sanmailbox@yandex.ru

**ТОЛМАЧЕВ
Сергей
Геннадьевич**



Начальник научно-исследовательской лаборатории ОАО «Концерн «Гранит-Электрон», Санкт-Петербург.

В 1980 году окончил Ленинградский электротехнический институт им. В. И. Ульянова (Ленина).

В 1992 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором 25 научных публикаций и трех патентов на изобретения.

Область научных интересов — представление знаний в информационных системах, интеллектуальные методы обработки информации.

Эл. адрес: cri-granit@peterlink.ru

**ФИЛЬЧЕНКОВ
Андрей
Александрович**



Доцент факультета информационных технологий и программирования, руководитель лаборатории машинного обучения Университета ИТМО, Санкт-Петербург.

В 2010 году окончил Санкт-Петербургский государственный университет по специальности «Математическое обеспечение и администрирование информационных систем».

В 2013 году защитил диссертацию на соискание ученой степени кандидата физико-математических наук.

Является автором 200 научных публикаций и 17 патентов на изобретения.

Область научных интересов — автоматическое машинное обучение, анализ и генерация изображений, анализ социальных данных, выбор признаков.

Эл. адрес: afilchenkov@itmo.ru

**ШАЛЫТО
Анатолий
Абрамович**



Профессор факультета информационных технологий и программирования Университета ИТМО, ученый секретарь НПО «Аврора».

В 1971 году окончил Ленинградский электротехнический институт им. В. И. Ульянова (Ленина) по специальности «Автоматика и телемеханика».

В 1999 году защитил диссертацию на соискание ученой степени доктора технических наук.

Является автором более 250 научных публикаций, трех монографий и 70 изобретений.

Область научных интересов — системы логического управления, автоматное программирование.

Эл. адрес: shalyto@mail.ifmo.ru

**ШАРОВ
Сергей
Николаевич**



Профессор, главный научный сотрудник ОАО «Концерн «Гранит-Электрон», Санкт-Петербург, член-корреспондент Академии электротехнических наук Российской Федерации, Российской академии ракетных и артиллерийских наук.

В 1962 году окончил приборостроительный факультет Ленинградского механического института по специальности «Системы автоматического управления».

В 1981 году защитил диссертацию на соискание ученой степени доктора технических наук. Является автором более 250 научных публикаций, в том числе 13 книг и 130 изобретений.

Область научных интересов — нелинейные системы управления, информационные каналы беспилотных летательных и космических аппаратов.

Эл. адрес: cri-granit@peterlink.ru

ХРАМОВ
Александр
Евгеньевич



Профессор, заведующий лабораторией нейронауки и когнитивных технологий Центра технологических компонентов робототехники и мехатроники Университета Иннополис.

В 1996 году окончил Саратовский государственный университет им. Н. Г. Чернышевского.

В 2005 году защитил диссертацию на соискание ученой степени доктора физико-математических наук.

Является автором более 200 научных публикаций.

Область научных интересов — нейронаука, теория сложных сетей, вейвлет-анализ и его приложения в нелинейной динамике и нейронауке, нейроинтерфейсы.
Эл. адрес: hramovae@gmail.com

ХРАМОВА
Марина
Викторовна



Доцент кафедры информационных систем и технологий в обучении факультета компьютерных наук и информационных технологий Саратовского государственного университета им. Н. Г. Чернышевского.

В 1996 году окончила Тамбовский государственный университет им. Г. Р. Державина по специальности «Математика, информатика и ВТ».

В 2000 году защитила диссертацию на соискание ученой степени кандидата педагогических наук.

Является автором более 100 научных публикаций.

Область научных интересов — методы обработки данных, образовательные технологии, нейропедагогика.

Эл. адрес: mhramova@gmail.com

Уважаемые авторы!

При подготовке рукописей статей необходимо руководствоваться следующими рекомендациями.

Статьи должны содержать изложение новых научных результатов. Название статьи должно быть кратким, но информативным. В названии недопустимо использование сокращений, кроме самых общепринятых (РАН, РФ, САПР и т. п.).

Объем статьи (текст, таблицы, иллюстрации и библиография) не должен превышать эквивалента в 20 страниц, напечатанных на бумаге формата А4 на одной стороне через 1,5 интервала Word шрифтом Times New Roman размером 13, поля не менее двух сантиметров.

Обязательными элементами оформления статьи являются: индекс УДК, заглавие, инициалы и фамилия автора (авторов), ученая степень, звание (при отсутствии — должность), полное название организации, аннотация и ключевые слова на русском и английском языках, ORCID и электронный адрес одного из авторов. При написании аннотации не используйте аббревиатур и не делайте ссылок на источники в списке литературы. Предоставляйте подрисуночные подписи и названия таблиц на русском и английском языках.

Статьи авторов, не имеющих ученой степени, рекомендуется публиковать в соавторстве с научным руководителем, наличие подписи научного руководителя на рукописи обязательно; в случае самостоятельной публикации обязательно предоставляйте заверенную по месту работы рекомендацию научного руководителя с указанием его фамилии, имени, отчества, места работы, должности, ученого звания, ученой степени.

Формулы набирайте в Word, не используя формульный редактор (Mathtype или Equation), при необходимости можно использовать формульный редактор; для набора одной формулы не используйте два редактора; при наборе формул в формульном редакторе знаки препинания, ограничивающие формулу, набирайте вместе с формулой; для установки размера шрифта никогда не пользуйтесь вкладкой Other..., используйте заводские установки редактора, не подгоняйте размер символов в формулах под размер шрифта в тексте статьи, не растягивайте и не сжимайте мышью формулы, вставленные в текст; в формулах не отделяйте пробелами знаки: + = -.

Для набора формул в Word никогда не используйте Конструктор (на верхней панели: «Работа с формулами» — «Конструктор»), так как этот ресурс предназначен только для внутреннего использования в Word и не поддерживается программами, предназначенными для изготовления оригинал-макета журнала.

При наборе символов в тексте помните, что символы, обозначаемые латинскими буквами, набираются светлым курсивом, русскими и греческими — светлым прямым, векторы и матрицы — прямым полужирным шрифтом.

Иллюстрации предоставляются отдельными исходными файлами, поддающимися редактированию:

— рисунки, графики, диаграммы, блок-схемы предоставляйте в виде отдельных исходных файлов, поддающихся редактированию, используя векторные программы: Visio (*.vsd, *.vsdx); Coreldraw (*.cdr); Excel (*.xls); Word (*.docx); Adobe Illustrator (*.ai); AutoCad (*.dxf); Matlab (*.ps, *.pdf или экспорт в формат *.ai);

— если редактор, в котором Вы изготавливаете рисунок, не позволяет сохранить в векторном формате, используйте функцию экспорта (только по отношению к исходному рисунку), например, в формат *.ai, *.esp, *.wmf, *.emf, *.svg;

— фото и растровые — в формате *.tif, *.png с максимальным разрешением (не менее 300 pixels/inch).

Наличие подрисуночных подписей и названий таблиц на русском и английском языках обязательно (желательно не повторяющих дословно комментарии к рисункам в тексте статьи).

В редакцию предоставляются:

— сведения об авторе (фамилия, имя, отчество, место работы, должность, ученое звание, учебное заведение и год его окончания, ученая степень и год защиты диссертации, область научных интересов, количество научных публикаций, домашний и служебный адреса и телефоны, e-mail), фото авторов: анфас, в темной одежде на белом фоне, должны быть видны плечи и грудь, высокая степень четкости изображения без теней и отблесков на лице, фото можно представить в электронном виде в формате *.tif, *.png с максимальным разрешением — не менее 300 pixels/inch при минимальном размере фото 40×55 мм;

— экспертное заключение.

Список литературы составляется по порядку ссылок в тексте и оформляется следующим образом:

— для книг и сборников — фамилия и инициалы авторов, полное название книги (сборника), город, издательство, год, общее количество страниц;

— для журнальных статей — фамилия и инициалы авторов, полное название статьи, название журнала, год издания, номер журнала, номера страниц;

— ссылки на иностранную литературу следует давать на языке оригинала без сокращений;

— при использовании web-материалов указывайте адрес сайта и дату обращения.

Список литературы оформляйте двумя отдельными блоками по образцам lit.dot на сайте журнала (<http://i-us.ru/paperrules>): Литература и References.

Более подробно правила подготовки текста с образцами изложены на нашем сайте в разделе «Правила для авторов».

Контакты

Куда: 190000, Санкт-Петербург,
Б. Морская ул., д. 67, ГУАП, РИЦ

Кому: Редакция журнала «Информационно-управляющие системы»

Тел.: (812) 494-70-02

Эл. почта: [ius.spb@gmail.com](mailto:i-us.spb@gmail.com)

Сайт: www.i-us.ru