

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

ИНФОРМАЦИОННО- УПРАВЛЯЮЩИЕ СИСТЕМЫ

НАУЧНЫЙ ЖУРНАЛ

5 (108) / 2020

5(108)/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

M. Buzdalov,

PhD, Researcher, Saint-Petersburg, Russia

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, Indianapolis, Russia

L. Jain

PhD, Professor, Canberra, Australia

V. Khimenko

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. Sutikno

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. Umnikina**Layout and composition:** Y. Umnikina**Contact information**

The Editorial and Publishing Center, SUAI

67, B. Morskaia, 190000, Saint-Petersburg, Russia

Website: <http://i-us.ru/en>, e-mail: ius.spb@gmail.com

Tel.: +7 - 812 494 70 02

THEORETICAL AND APPLIED MATHEMATICS**Nguyen Nang Hung Van, Pham Minh Tuan, Do Phuc Hao, Pham Cong Thang, Tachibana Kanta.** Human action recognition method based on conformal geometric algebra and recurrent neural network 2**INFORMATION PROCESSING AND CONTROL****Zotin A. G., Favorskaya M. N.** Application of bar coding for digital watermarking of video sequences based on frequency transforms 12**Solovyeva E. B., Abdullah A.** Controlling system based on neural networks with reinforcement learning for robotic manipulator 24**INFORMATION AND CONTROL SYSTEMS****Osipov V. Yu., Miloserdov D. I.** Neural network event forecasting for robots with continuous training 33**SYSTEM AND PROCESS MODELING****Sovetov B. Ya., Tatarnikova T. M., Poymanova E. D.** Storage scaling management model 43**INFORMATION INSTRUMENTATION AND EDUCATION****Kurkin S. A., Grubov V. V., Maksimenko V. A., Pitsik E. N., Khramova M. V., Hramov A. E.** System for monitoring and adjusting the learning process of primary schoolchildren based on the EEG data analysis 50**CONTROL IN MEDICAL AND BIOLOGICAL SYSTEMS****Shcherban I. V., Kosenko P. O., Shcherban O. G., Lobzenko P. V.** Method of automatic search for odor-induced patterns in bioelectric activity of a rat olfactory bulb 62**Lobantsev A. A., Gusarova N. F., Vatian A. S., Kapitonov A. A., Shalyto A. A.** Comparative assessment of text-image fusion models for medical diagnostics 70**INFORMATION ABOUT THE AUTHORS**

80

5(108)/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

М. В. Буздалов,

канд. техн. наук, научный сотрудник, Санкт-Петербург, РФ

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. 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. Самуйлов,

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

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

ТЕОРЕТИЧЕСКАЯ И ПРИКЛАДНАЯ МАТЕМАТИКА

Nguyen Nang Hung Van, Pham Minh Tuan, Do Phuc Hao, Pham Cong Thang, Tachibana Kanta. Human action recognition method based on conformal geometric algebra and recurrent neural network

2

ОБРАБОТКА ИНФОРМАЦИИ И УПРАВЛЕНИЕ

Зотин А. Г., Фаворская М. Н. Применение штрихкодирования для цифрового маркирования видеопоследовательностей на основе частотных преобразований

12

Solovyeva E. B., Abdullah A. Controlling system based on neural networks with reinforcement learning for robotic manipulator

24

ИНФОРМАЦИОННО-УПРАВЛЯЮЩИЕ СИСТЕМЫ

Осипов В. Ю., Миросердов Д. И. Нейросетевое прогнозирование событий для роботов с непрерывным обучением

33

МОДЕЛИРОВАНИЕ СИСТЕМ И ПРОЦЕССОВ

Sovetov B. Ya., Tatarnikova T. M., Poymanova E. D. Storage scaling management model

43

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ И ОБРАЗОВАНИЕ

Kurkin S. A., Grubov V. V., Maksimenko V. A., Pitsik E. N., Khramova M. V., Hramov A. E. System for monitoring and adjusting the learning process of primary schoolchildren based on the EEG data analysis

50

УПРАВЛЕНИЕ В МЕДИЦИНЕ И БИОЛОГИИ

Shcherban I. V., Kosenko P. O., Shcherban O. G., Lobzenko P. V. Method of automatic search for odor-induced patterns in bioelectric activity of a rat olfactory bulb

62

Lobantsev A. A., Gusarova N. F., Vatian A. S., Kapitonov A. A., Shalyto A. A. Comparative assessment of text-image fusion models for medical diagnostics

70

СВЕДЕНИЯ ОБ АВТОРАХ

80

Журнал входит в БД SCOPUS 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 01.09.20. Подписано в печать 19.10.20. Формат 60×84^{1/8}.

Гарнитура SchoolBookC. Печать цифровая.

Усл. печ. л. 10,0. Уч.-изд. л. 13,8. Тираж 1000 экз (1-й завод 50 экз.). Заказ № 352.

Оригинал-макет изготовлен в редакционно-издательском центре ГУАП.

190000, Санкт-Петербург, Б. Морская ул., 67.

Отпечатано с готовых диалогитивов в редакционно-издательском центре ГУАП.

190000, Санкт-Петербург, Б. Морская ул., 67.

UDC 004.93

doi:10.31799/1684-8853-2020-5-2-11

Human action recognition method based on conformal geometric algebra and recurrent neural network

Nguyen Nang Hung Van^a, PhD Student, Specialist, orcid.org/0000-0002-9963-7006, nguyenvan@dut.udn.vn

Pham Minh Tuan^a, PhD, Lecturer, orcid.org/0000-0001-9843-9676, pmtuan@dut.udn.vn

Do Phuc Hao^b, M. Sc., Lecturer, orcid.org/0000-0003-0645-0021, haodp@dau.edu.vn

Pham Cong Thang^a, PhD, Lecturer, orcid.org/0000-0002-6428-102X, pcthang@dut.udn.vn

Tachibana Kanta^c, PhD, Associate Professor, orcid.org/0000-0002-8675-7842, kanta@cc.kogakuin.ac.jp

^aThe University of Danang – University of Science and Technology, Information Technology Faculty, 54 Nguyen Luong Bang St., Da Nang 550000, Vietnam

^bDanang Architecture University, 566 Nui Thanh St., Da Nang 550000, Vietnam

^cKogakuin University, 1-24-2 Nishi-Shinjuku, Shinjuku-ku, Tokyo 163-8677, Japan

Introduction: Deep Learning plays an important role in machine learning and artificial intelligence. It is widely applied in many fields with high dimensional data, including natural language processing and image recognition. High dimensional data can lead to problems in machine learning, such as overfitting and degradation of accuracy. To address these issues, some methods were proposed to reduce dimensions of the data and computational complexity simultaneously. The drawback of these methods is that they only work well on data distributed on the plane. In the case of the data distributed on the hyper-sphere, such as objects moving in space, the processing results are not so good as expected. **Purpose:** The use of Conformal Geometric Algebra in order to extract features and simultaneously reduce the dimensionality of a dataset for human activity recognition using Recurrent Neural Network. **Results:** Human activity data in a 3-dimensional coordinate system is pre-processed and normalized by calculating deviations from the mean coordinate. Next, the data is transformed to vectors in Conformal Geometric Algebra space and its dimensions are reduced to return the feature vectors. Finally, we use the Recurrent Neural Network model to train feature vectors. Empirical results performed on the Motion Capture dataset with eight actions show that the Conformal Geometric Algebra combined with Recurrent Neural Network can give the best test results of 92.5%. **Practical relevance:** In human actions, some actions such as jump or dance will not move in motion and other actions, such as run, walk, will move in space. Therefore, we need a method to standardize actions. In the case of the data distributed on the hyper-sphere, the developed method can help us to extract features and simultaneously reduce the dimensionality of a dataset for human activity recognition using Recurrent Neural Network.

Keywords – activity recognition, Principal Components Analysis, Conformal Geometric Algebra, Deep Learning.

For citation: Nguyen Nang Hung Van, Pham Minh Tuan, Do Phuc Hao, Pham Cong Thang, Tachibana Kanta. Human action recognition method based on conformal geometric algebra and recurrent neural network. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 2–11. doi:10.31799/1684-8853-2020-5-2-11

Introduction

Deep Learning (DL) is a new research trend in recent years for many applications, such as image processing, object detection, and remote control [1–4]. DL has two main models: Convolutional Neural Network (CNN) used to feature extraction in image processing [5, 6], and Recurrent Neural Network (RNN) used to handle sequence identification (sequence/time-series) [7].

The drawback of the Neural Network (NN) model is that each input x event is handled independently and gives the corresponding output y without the exchange of information collected at each input x [8]. The RNN contains internal loops that are able to save the exchanged information and the saved information can be transferred from one step to another of NN. So RNN can be used to input data from image and video converted into sequences for recognition or prediction problems. However, the most challenging problem of DL is still the selection process of data preprocessing and feature extraction techniques for training models.

Some commonly used machine learning models, such as Principal Components Analysis (PCA) [9, 10], Principal Components Regression (PCR) [11], and Multi-class Linear Discriminant Analysis (MLDA) [12], were proposed to reduce dimensions of the data and computational complexity simultaneously for training models. These machine learning method only work well with data distributed on a plane, such as face recognition or image classification [13]. In the case of data distributed on hyper-sphere, eg. moving objects in space, it is difficult to calculate accurately with the above methods. To address this issue, in this paper, we propose to use the Conformal Geometric Algebra (CGA) to extract features and reduce the number of data dimensions during the training of the RNN models.

In recent years, there have been a number of studies that have successfully applied Geometric Algebra (GA) for dimensionality reduction in some applications, such as color image processing, signal processing, and time-Series analysis [14–16]. CGA is part of GA, and a vector in CGA space is called a

conformal vector. Each of conformal vector is represented for $m + 2$ dimensions of hyper-plane and hyper-spheres (see [17–20] for more details).

In this work, we propose to use principal components in $m + 2$ dimensional CGA space. The feature vectors are gotten by eliminating the less relative components. We propose to transfer data from real space \mathbf{R}^m to conformal vectors as a set of points in CGA space $\mathbf{P} \in \mathcal{G}_{m+2,1}$. The selection of principal components determines the eigenvalues and eigenvectors. The eigenvectors of \mathbf{A} (conformal vector) are arranged in descending order. Then, k smallest eigenvectors are removed to reduce the data dimensions. It leads to receive the conformal vectors \mathbf{B} with $m - k$ main components. These conformal vectors \mathbf{B} are used to train an RNN model.

Related works

A growing interest in human action recognition using the DL model has recently arisen. To build a training model, we need to collect data via sensors or cameras [21, 22]. Next, it is important to use some preprocessing and machine learning methods for object feature extraction. Finally, we use the RNN model for action recognition.

Some methods are used in feature extraction for data dimensionality reduction such as PCA, LDA, and PCR. However, these methods are linear and it is hard to perform 3D relationships like linear motion or rotation. For example, a joint moves and rotates around the parent joint. Hence, motion data will be distributed on a sphere (or hyper-sphere) with the center coordinates of the parent joint.

Next, we present some feature extraction methods.

Principal Components Analysis

Principal Components Analysis algorithm [9, 10] is usually used to convert dataset from a multi-dimensional space into a less dimensional space, but the method still ensures that the variance of the input data on each new dimension is the largest.

Given training set $\mathbf{X} = \{\mathbf{x}_i | \mathbf{x}_i \in \mathbf{R}^d\}$, $i = \{1, \dots, n\}$,

where \mathbf{x}_i is a vector in d -dimensional space, and n is the number of vectors in the set \mathbf{X} . PCA will perform a linear transformation to convert data into a new coordinate system. The linear transformation is defined by the scalar product of the vector \mathbf{x} and the unit vector of the weight $\mathbf{w} \in \mathbf{R}^d$ where $\|\mathbf{w}\| = 1$. The problem is transformed into finding weight vectors so that the covariance of the linear transformation $\mathbf{w}^T \mathbf{x}$ is the largest. We need to solve the problem:

$$\max_{\mathbf{w}} \frac{1}{n} \sum_{i=1}^n (\mathbf{w}^T \mathbf{x}_i - \mathbf{w}^T \boldsymbol{\mu})^2 \quad s.t \quad \|\mathbf{w}\|^2 = 1, \quad (1)$$

where the average of all vectors in the \mathbf{X} dataset is defined as follows:

$$\boldsymbol{\mu} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i. \quad (2)$$

Equation (2) is the average of all vectors of the \mathbf{X} dataset. To solve this optimal problem, this paper introduces the Lagrange coefficient $\lambda \geq 0$ for the Lagrange function as follows:

$$L(\mathbf{w}, \lambda) = \frac{1}{n} \sum_{i=1}^n (\mathbf{w}^T \mathbf{x}_i - \mathbf{w}^T \boldsymbol{\mu})^2 - \lambda (\|\mathbf{w}\|^2 - 1). \quad (3)$$

Then, calculate the derivative of $L(\mathbf{w}, \lambda)$ with λ going to zero will get the following formula:

$$\frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^T \mathbf{w} = \lambda \mathbf{w}. \quad (4)$$

So the optimization problem solved by decomposing Eigen is as follows:

$$\mathbf{C} \mathbf{w} = \lambda \mathbf{w}, \quad (5)$$

where

$$\mathbf{C} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^T. \quad (6)$$

Equation (5), \mathbf{C} is the variance matrix of the \mathbf{X} data set. Finally, PCA uses a decrease in the number of dimensions of the data using the first k eigenvectors. These vectors are one that corresponds to the value of the maximum eigenvalues. This means that the original data set is approximated by data with less dimensionality and overview than the original data. The feature $f(\mathbf{x})$ can be extracted from vector \mathbf{x} using the first k eigenvector as follows:

$$f_{\text{PCA}}(\mathbf{x}) = ((\mathbf{x} - \boldsymbol{\mu})^T \mathbf{w}_1, \dots, (\mathbf{x} - \boldsymbol{\mu})^T \mathbf{w}_k)^T, \quad (7)$$

where \mathbf{w}_i is the i^{th} eigenvector, $1 \leq i \leq k$.

The extraction feature method using PCA uses a linear transformation for the input data. Hence, it is only possible to represent accurately the data distributed on the plane. However, the feature extraction results are not good with data distributed on the sphere. Furthermore, PCA mainly uses 3D coordinates during data collection, but it does not go in-depth into an analysis of 3D relationships of objects.

Conformal Geometric Algebra

Given training set $\mathbf{X} = \{\mathbf{x}_i | \mathbf{x}_i \in \mathbf{R}^d\}$, $i \in \{1, \dots, n\}$ represented in real d -dimensional space. A CGA space is extended from the real Euclidean vector space \mathbf{R}^d by adding 2 orthonormal basis vector.

Thus, a CGA space is defined by $d + 2$ basis vectors $\{\mathbf{e}_1, \dots, \mathbf{e}_m, \mathbf{e}_+, \mathbf{e}_-\}$, where \mathbf{e}_+ , \mathbf{e}_- and \mathbf{e}_i , $i \in \{1, \dots, d\}$ are defined as following:

$$\begin{aligned} \mathbf{e}_+^2 &= \mathbf{e}_+ \cdot \mathbf{e}_+ = 1; \\ \mathbf{e}_-^2 &= \mathbf{e}_- \cdot \mathbf{e}_- = -1; \\ \mathbf{e}_+ \cdot \mathbf{e}_- &= \mathbf{e}_+ \cdot \mathbf{e}_i = \mathbf{e}_- \cdot \mathbf{e}_i = 0, \forall i \in \{1, \dots, d\}. \end{aligned} \quad (8)$$

Thus, a CGA can be expressed by $\mathcal{G}_{d+1,1}$. This paper then defines the converted basis vectors \mathbf{e}_0 and \mathbf{e}_∞ as

$$\mathbf{e}_0 = \frac{1}{2}(\mathbf{e}_- - \mathbf{e}_+), \quad \mathbf{e}_\infty = (\mathbf{e}_- + \mathbf{e}_+). \quad (9)$$

From Eq. (8) and (9), it is easy to see that:

$$\begin{aligned} \mathbf{e}_0 \cdot \mathbf{e}_0 &= \mathbf{e}_\infty \cdot \mathbf{e}_\infty = 0; \\ \mathbf{e}_0 \cdot \mathbf{e}_\infty &= \mathbf{e}_\infty \cdot \mathbf{e}_0 = -1; \\ \mathbf{e}_0 \cdot \mathbf{e}_i &= \mathbf{e}_\infty \cdot \mathbf{e}_i = 0, \forall i \in \{1, \dots, d\}. \end{aligned} \quad (10)$$

This training set is re-represented by the set of points $\mathbf{P} \in \mathcal{G}_{d+1,1}$ in CGA space [23, 15] as follows:

$$\mathbf{P}_i = \mathbf{x}_i + \frac{1}{2}\|\mathbf{x}_i\|^2 \mathbf{e}_\infty + \mathbf{e}_0 \in \mathcal{G}_{d+1,1}. \quad (11)$$

Hence, a sphere in CGA space is represented as a conformal vector

$$\mathbf{S} = \mathbf{s} + s_\infty \mathbf{e}_\infty + s_0 \mathbf{e}_0. \quad (12)$$

The estimating process is performed by using the least squares $d^2(\mathbf{P}_i, \mathbf{S})$. The error function is defined as follows:

$$E = \sum_{i=1}^n d^2(\mathbf{P}_i, \mathbf{S}) = \sum_{i=1}^n \left(\mathbf{x}_i \mathbf{s}_j - s_{\infty j} - \frac{1}{2}\|\mathbf{x}_i\|^2 s_{0j} \right)^2. \quad (13)$$

This means that when minimizing the error E function, s can be limited by $\|\mathbf{s}\|^2 = 1$. In this case, the optimization problem becomes as follows:

$$\min \sum_{i=1}^n \left(\mathbf{x}_i \mathbf{s}_j - s_{\infty j} - \frac{1}{2}\|\mathbf{x}_i\|^2 s_{0j} \right)^2 \text{ s.t. } \|\mathbf{s}_j\|^2 = 1. \quad (14)$$

Following [14], the optimal problem is solved by the Eigen decomposition as follows:

$$\mathbf{A}_j \mathbf{s}_j = \lambda_j \mathbf{s}_j, \quad (15)$$

where \mathbf{A} is the variance matrix of the i^{th} training set in CGA space:

$$\mathbf{A} = \sum_{i=1}^n f(\mathbf{x}_i) f^T(\mathbf{x}_i). \quad (16)$$

The function $f(\mathbf{x}_i)$ is defined as follows:

$$f(\mathbf{x}_i) = \mathbf{x} - f_\infty - \|\mathbf{x}\|^2 f_0 \in \mathbf{R}^m, \quad (17)$$

where

$$f_\infty = \frac{-\sum_4 \sum_{i=1}^n \mathbf{x}_i + \sum_2 \sum_{i=1}^n \|\mathbf{x}_i\|^2 \mathbf{x}_i}{\left(\sum_2\right)^2 - n \sum_4}; \quad (18)$$

$$f_0 = \frac{\sum_2 \sum_{i=1}^n \mathbf{x}_i - n \sum_{i=1}^n \|\mathbf{x}_i\|^2 \mathbf{x}_i}{\left(\sum_2\right)^2 - n \sum_4}, \quad (19)$$

$\sum_2 = \sum_{i=1}^n \|\mathbf{x}_i\|^2$ and the sum of the four powers $\sum_4 = \sum_{i=1}^n \|\mathbf{x}_i\|^4$.

An eigenvector \mathbf{s}_j is a conformal eigenvector of a subset \mathbf{X}_j defined in hyper-plane or hyper-sphere $\mathbf{S}_j = \mathbf{s}_j + s_{\infty j} \mathbf{e}_\infty + s_{0j} \mathbf{e}_0$ and eigenvalues λ_j are variance; s and s_0 are the scalar coefficient of the basis vectors \mathbf{e} and \mathbf{e}_0 .

Recurrent Neural Network

Recurrent Neural Network models [7] are mostly used in the fields of natural language processing, speech recognition, and action recognition. The learned model always has the same input size, because the input of each state is the output of the previous state. It allows to use same transition function with same parameters at every step. These properties make it possible to learn the model executing on all steps and all sequence lengths. Hence, RNN is able to generalize the sequence lengths not being in the training set. Therefore, the learned model will be estimated with much fewer data.


In this study, we will introduce RNN with data as human action videos (Fig. 1). These actions will go through PCA and CGA to create the feature vector \mathbf{x} of size n . The calculation will take many to one form of the RNN model, with multiple input and output predicting actions in the data set.

Each input value \mathbf{x}_t is of size n , after passing RNN, there will be an output value \mathbf{y} of size c (number of clustering), for each circle called a state, the input of each state is \mathbf{x}_t and s_{t-1} (which is the output of the previous state). Now output s_t is calculated in the following formula:

$$s_t = \tanh(U\mathbf{x}_t + Ws_{t-1}), \quad (20)$$

where s_i of size m ; U and W is hyperparameter [24]: U of size $(m \times n)$ is a coefficient matrix between \mathbf{x}_{t-1} and \mathbf{x}_t ; W of size $(m \times n)$ is a coefficient matrix connecting s_t and s_{t-1} . In Fig. 1, a V of size $(c \times m)$ is a coefficient matrix converting \mathbf{x}_t to \mathbf{y} .

Because there is only one output value, \mathbf{y} can be determined through the activation function is *softmax*:



■ Fig. 1. Illustrate the many to one problem of the RNN model: a — short RNN model; b — RNN model for application

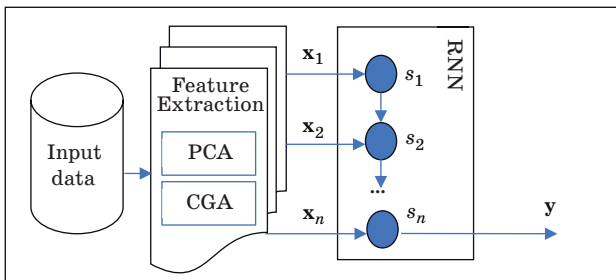
$$y = \text{softmax}(Vs_n). \quad (21)$$

From (21) from the input sequence \mathbf{x} , we also determine the output value quite simply.

Deep Learning has two big models that are CNN and RNN. CNN is a processing model in the problem of image input, and very common applications in computer vision are classification, object detection, and segmentation. However, in human action recognition, the input data of the models is different actions and the model needs to predict the appropriate output action (predict time series). Therefore, in this paper, we choose the many to one model in RNN to apply.

The proposed method

The proposed method is to analyze data of moving objects and human actions with markers with



■ Fig. 2. The overview of proposed RNN model

coordinates in 3D space. Specifically, the proposed use of the CMU (Carnegie Mellon University) [25] motion capture dataset consists of 08 different actions, each action consisting of multiple files and each file consisting of corresponding frames. In each frame there are 41 markers (41 joints), each marker is each coordinates are represented in 3D space.

In this paper, we propose a technique to normalize data by moving the coordinate axes of all joints back to their original coordinates, then using PCA and CGA to extract features. Finally, use these feature vectors to create input values for the RNN (Fig. 2).

Transformation method of coordinates

In human actions, some actions such as *jump* or *dance* will not move in motion and other actions such as *run*, *walk* will move in space. Therefore, we need a method to standardize actions to be similar. In this study, we propose to transform all markers to new coordinates by calculating deviations from the mean coordinate to extract features.

Give a data set:

$$\mathfrak{S} = \{\zeta_i | \zeta_i \in \mathbf{R}^{t(i) \times m \times 3}, i \in \{1, \dots, n\}, \quad (22)$$

where $\zeta_i = [\delta_{i,1}^T, \dots, \delta_{i,t(i)}^T]^T \in \mathbf{R}^{t(i) \times m \times 3}$ is a vector of the i^{th} action; $t(i)$ is frame number of the i^{th} action; $\delta_{i,j} = [\theta_{i,j,1}^T, \dots, \theta_{i,j,m}^T]^T \in \mathbf{R}^{m \times 3}$ is a vector corresponding to the i^{th} frame of action and

$$\theta_{ijk} = \begin{bmatrix} \theta_{ijk1} \\ \theta_{ijk2} \\ \theta_{ijk3} \end{bmatrix} \in \mathbf{R}^3 \text{ is the coordinates of the } i^{th}$$

marker of the j^{th} frame of the i^{th} action.

Then, we convert action ζ_i to the set of vectors as follows:

$$\mathbf{X} = \{\mathbf{x}_{ij} | \mathbf{x}_{ij} \in \mathbf{R}^{m \times 3}, j \in \{1, \dots, t(i)\}, \quad (23)$$

where \mathbf{x}_{ij} is a vector corresponding to features the j^{th} frame, and the i^{th} action:

$$\mathbf{x}_{ij} = [\mathbf{g}^T(\theta_{ij1}), \dots, \mathbf{g}^T(\theta_{ijk}), \dots, \mathbf{g}^T(\theta_{ijm})]^T, \quad (24)$$

where $\mathbf{g}(\theta_{ijk})$ is a transformation of coordinates of the k^{th} marker of the j^{th} frame of the i^{th} action.

In this paper, we can use the function

$$\mathbf{g}^T(\theta_{ijk}) = \theta_{ijk} \quad (25)$$

or transformation method of coordinates

$$g(\theta_{jjk}) = \theta_{jjk} - \hat{\theta}_{ij}, \quad (26)$$

where $\hat{\theta}_{ij} = \frac{1}{m} \sum_{k'=1}^m \theta_{jjk'}$.

So, we have the new set of vector for the training set of PCA and CGA_PCA.

Model combining PCA with RNN

Recurrent Neural Network can combine well with other models to predict in time series (predict time series). However, RNN uses many parameters on each state, which can lead to over-fitting. By combining PCA with RNN, PCA is capable reduce feature dimensions so that network nodes can be reduced but retain the original properties (original information).

The PCA algorithm uses orthogonal transformations to convert the data set from a multi-dimensional space to a new space with less dimension. This transformation is based on finding the axis of the new space so that the method of data projected on that axis is greatest. From Eq. (22) and (23), we have \mathbf{X}_{new} as follows:

$$\mathbf{X} = \{\mathbf{x}_{ij} | \mathbf{x}_{ij} \in \mathbf{R}^{m \times 3}; j \in \{1, \dots, t(i)\}, i \in \{1, \dots, n\}\}. \quad (27)$$

Now, we need to solve the problem:

$$\max_{\mathbf{w}} \frac{1}{\sum_{i=1}^n t(i)} \sum_{i=1}^n \sum_{j=1}^{t(i)} (\mathbf{w}^T \mathbf{x}_{ij} - \mathbf{w}^T \boldsymbol{\mu})^2 \quad s.t \|\mathbf{w}\|^2 = 1, \quad (28)$$

where

$$\boldsymbol{\mu} = \frac{1}{\sum_{i=1}^n t(i)} \sum_{i=1}^n \sum_{j=1}^{t(i)} \mathbf{x}_{ij}. \quad (29)$$

Equation (28), to the optimal problem, this paper introduces the Lagrange coefficient $\lambda \geq 0$ for the Lagrange function as follows:

$$L(\mathbf{w}, \lambda) = \frac{1}{\sum_{i=1}^n t(i)} \sum_{i=1}^n \sum_{j=1}^{t(i)} (\mathbf{w}^T \mathbf{x}_{ij} - \mathbf{w}^T \boldsymbol{\mu})^2 - \lambda (\|\mathbf{w}\|^2 - 1). \quad (30)$$

Then, calculate the derivative of $L(\mathbf{w}, \lambda)$ with λ going to zero will get the following formula:

$$\frac{1}{\sum_{i=1}^n t(i)} \sum_{i=1}^n \sum_{j=1}^{t(i)} (\mathbf{x}_{ij} - \boldsymbol{\mu})(\mathbf{x}_{ij} - \boldsymbol{\mu})^T \mathbf{w} = \lambda \mathbf{w}. \quad (31)$$

Then, the eigenvalues can be obtained via the following function:

$$\mathbf{C}\mathbf{w} = \lambda \mathbf{w}, \quad (32)$$

where

$$\mathbf{C} = \frac{1}{\sum_{i=1}^n t(i)} \sum_{i=1}^n \sum_{j=1}^{t(i)} (\mathbf{x}_{ij} - \boldsymbol{\mu})(\mathbf{x}_{ij} - \boldsymbol{\mu})^T. \quad (33)$$

Equation (32), \mathbf{C} is the variance matrix of the \mathbf{X} data set. Finally, PCA uses a decrease in the number of dimensions of the data using the first k eigenvectors. The feature $f_{\text{PCA}}(\mathbf{x})$ can be extracted from vector \mathbf{x} using the first k eigenvector as follows:

$$f_{\text{PCA}}(\mathbf{x}) = ((\mathbf{x} - \boldsymbol{\mu})^T \mathbf{w}_1, \dots, (\mathbf{x} - \boldsymbol{\mu})^T \mathbf{w}_k)^T, \quad (34)$$

where \mathbf{w}_i is the i^{th} eigenvector, $1 \leq i \leq k$.

Now, we use the transform $f_{\text{PCA}}(\mathbf{x})$ to apply the learning model by converting the data set $\mathbf{T} = \{f_{\text{PCA}}(\mathbf{x}_{ij}), \mathbf{y}_i | \mathbf{x}_i \in \mathbf{R}^{m \times 3}, \mathbf{y}_i \in \{1, \dots, c\}\}, i \in \{1, \dots, n\}$, where $f_{\text{PCA}}(\mathbf{x}_{ij})$ and \mathbf{y}_i are label and feature vector after applying PCA.

Then, we use the data set \mathbf{T} to initialize the input data for the RNN model. From Eq. (20), the formula is rewritten as follows:

$$s_i = \tanh(U\mathbf{x}_{ij} + Ws_{i-1}). \quad (35)$$

Because there is only one output value, \mathbf{y}_i can be determined through the activation function is *softmax* and Eq. (21) is rewritten

$$\mathbf{y}_{\text{PCA},i} = \text{softmax} \frac{1}{\sum_{i=1}^n t(i)} \sum_{i=1}^n \sum_{j=1}^{t(i)} (Vs_i). \quad (36)$$

From Eq. (36) we get the clustering result of each action. Because PCA uses linear methods and assumes that the data is distributed on the plane, in cases where the data is distributed in the hyper-sphere, the PCA will not give a high result. The study further suggests using CGA to combine with the RNN.

Model combining CGA with RNN

This proposal will proceed to build the RNN model on CGA space. From Eq. (22) and (23) data is converted into points in CGA space as follows:

$$\mathbf{P}_{ij} = \mathbf{x}_{ij} + \frac{1}{2} \|\mathbf{x}_{ij}\|^2 \mathbf{e}_\infty + \mathbf{e}_0 \in \mathcal{G}_{m \times 3 + 1, 1}. \quad (37)$$

The process of estimating using least squares $d^2(\mathbf{P}_i, \mathbf{S})$. The error function E as follows:

$$E = \sum_{i=1}^n \sum_{j=1}^{t(i)} d^2(\mathbf{P}_{ij}, \mathbf{S}) = \sum_{i=1}^n \sum_{j=1}^{t(i)} \left(\mathbf{x}_{ij} \mathbf{S} - s_\infty - \frac{1}{2} \|\mathbf{x}_{ij}\|^2 s_0 \right)^2. \quad (38)$$

This means that when minimizing the error E function, \mathbf{s} can be limited by $\|\mathbf{s}\|^2 = 1$:

$$\min \sum_{i=1}^n \sum_{j=1}^{t(i)} \left(\mathbf{x}_{ij} \mathbf{s} - s_{\infty} - \frac{1}{2} \|\mathbf{x}_{ij}\|^2 s_0 \right)^2. \quad (39)$$

Therefore, we might be tempted to express the previous problem using a non-negative Lagrange multiplier λ as the minimization of

$$L(\mathbf{s}, \lambda) = \frac{1}{\sum_{i=1}^n \sum_{j=1}^{t(i)} t(i)} \sum_{i=1}^n \sum_{j=1}^{t(i)} \left(\mathbf{x}_{ij} \mathbf{s} - s_{\infty} - \frac{1}{2} \|\mathbf{x}_{ij}\|^2 s_0 \right)^2 - \lambda (\|\mathbf{s}\|^2 - 1). \quad (40)$$

The optimal result can be solved using Eigen problem

$$\mathbf{A} \mathbf{s} = \lambda \mathbf{s}, \quad (41)$$

where \mathbf{A} is the variance matrix of the i^{th} training set in CGA space:

$$\mathbf{A} = \sum_{i=1}^n \sum_{j=1}^{t(i)} f(\mathbf{x}_{ij}) f^T(\mathbf{x}_{ij}). \quad (42)$$

The function $f_{CGA}(\mathbf{x}_i)$ is defined as follows:

$$f_{CGA}(\mathbf{x}_i) = \mathbf{x}_i - f_{\infty} - \|\mathbf{x}_i\|^2 f_0 \in \mathbf{R}^m, \quad (43)$$

where

$$f_{\infty} = \frac{-\sum_4 \sum_{i=1}^n \sum_{j=1}^{t(i)} \mathbf{x}_{ij} + \sum_2 \sum_{i=1}^n \sum_{j=1}^{t(i)} \|\mathbf{x}_{ij}\|^2 \mathbf{x}_{ij}}{(\sum_2)^2 - \sum_{i=1}^n t(i) \sum_4}; \quad (44)$$

$$f_0 = \frac{\sum_2 \sum_{i=1}^n \sum_{j=1}^{t(i)} \mathbf{x}_{ij} - \sum_{i=1}^n t(i) \sum_{i=1}^n t(i)}{(\sum_2)^2 - \sum_{i=1}^n t(i) \sum_4}. \quad (45)$$

Similar to the PCA model, RNN uses input data is $f_{CGA}(\mathbf{x}_i)$ after using the CGA to extraction feature. From Eq. (20), (21) and (43) can be rewritten as

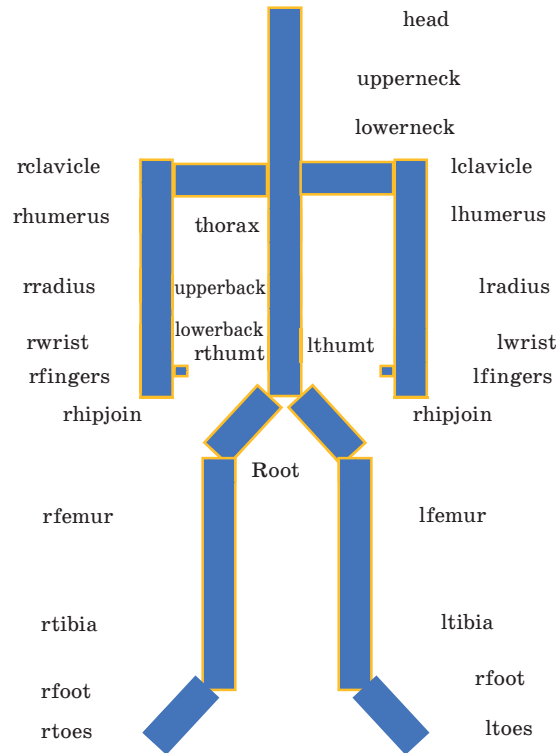
$$y_{CGA,i} = softmax \frac{1}{\sum_{i=1}^n t(i)} \sum_{i=1}^k \sum_{j=1}^{t(i)} (V s_i). \quad (46)$$

This model is implemented on CGA space, i. e. data in real space is transferred to CGA space. With the characteristics of CGA, it is possible to represent objects in space and geometric relationships very well. So movements with complex distributions like human joints use CGA very reasonably.

Experimental

Experimental data

The database of motions of CMU, USA [25] is free for all uses. Motions are captured in a working volume of approximately 3×8 m. In this model, humans wear a black jumpsuit having 41 markers taped on (Fig. 3). The Vicon cameras see the markers in infrared. The images picked up from the various cameras are triangulated to get 3D data.



■ Fig. 3. Illustration model of markers on the body

■ Table 1. Database experiment

Action	Number frame		
	Training	Testing	Total
Dance	3.305	1.577	4.882
Jump	1.198	846	2.044
Kick	1.605	1.163	2.768
Placing Tee	1.487	1.096	2.583
Putt	1.534	974	2.508
Run	452	322	774
Swing	1.324	977	2.301
Walk	1.074	928	2.002
Total	11.979	7.883	19.862

This study uses 8 kinds of human action. They are *dancing, jumping, kicking, placing tea, putt, running, swing, walking*. This paper uses the warehouse file format .c3d and data include total frame is 19.869 frames, divide the number of frames of each action into 2 parts (*train — 60 % and the test — 40 %*). Details are presented in Table 1.

Figure 3 shows the labels of markers, which have 3D coordinates (x, y, z).

Predict with RNN

This experiment is conducted with the original data set on the RNN model with the non-transformation using Eq. (25) and with the proposed transformation using Eq. (26). The parameters of the RNN network are the number of neural = 200, epochs = 20, and classes = 8 (8 kinds of human action), batch_size = 5, and activation function is Tanh.

The results from Table 2 show that when the coordinates are moved closer to the original coordinates, the result is 84.45 %. This result is much higher than when keeping the coordinates is about 70.97 %. However, to improve as well as increase efficiency when using the RNN. In this study, we propose to use many methods of dimensional reduction before putting into the RNN to predict.

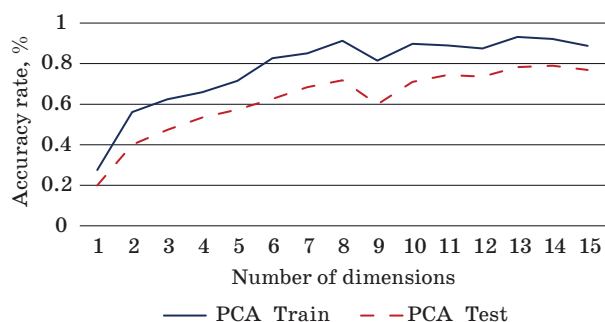
Predict with PCA_RNN

In this experiment, we will conduct coordinate transformation before using PCA to extract features. Results Fig. 4 shows that as the number of dimensions increases, the result gradually increases.

When the number of dimensions is 13, the Train result is 93.12 % and the Test is 78.2 %, the result will not increase and can be considered to have converged at the number of dimensions equal to 14.

■ **Table 2.** Comparison results of two data sets using RNN, %

Part	non-Transformation	Transformation
Train	72.57	87.11
Test	70.97	84.45



■ **Fig. 4.** Results of combining PCA and RNN

Next, research should continue to experiment with the use of CGA to extract features.

Predict with CGA_RNN

In this experiment, we will conduct preprocessing before using CGA to extract features. Fig. 5 shows that the result when using CGA will converge most when receiving the full attributes of the object. At the same time, the results clearly show that if you remove some key attributes, the result will decrease.


The highest train result was 98.1 % with a dimension is 2 and the highest test was 92.52 % with a dimension is 5.

Evaluation of results

The experiment was conducted with 5 times of implementation on the proposed method with the number of neural = 200, epochs = 20, the results achieved in Table 3. The results of using CGA_RNN are much higher than PCA_RNN, this is also true. when using CGA to represent moving objects in space.

In the previous study [26], we used PCA and CGA to extraction feature and predict on data set [25]. The best result is 88.86 %. However, when we use PCR to classify and predict the results, we encounter some limitations such as calculation speed and complexity. So we propose a method of combining CGA with RNN.

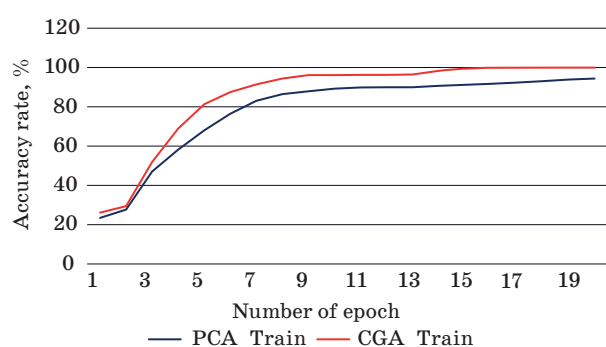
Currently, some studies are using ML models [27–29] and DL in human action recognition [5, 30, 31]. However, these studies only focus on developing RNN and Long Short Term Memory (LSTM) models to predict but do not care about the characteristics of the object and extraction feature methods



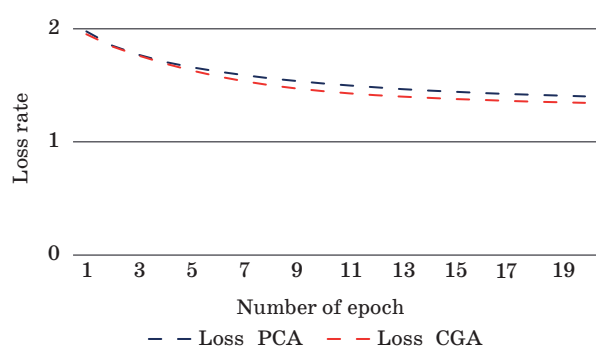
■ **Fig. 5.** Results of combining CGA and RNN

■ **Table 3.** Compares the results of the two proposed methods, %

Part	PCA_RNN	CGA_RNN
Train	85.24	95.59
Test	72.83	88.50



■ **Fig. 6.** Comparison of the results of the two proposed methods



■ **Fig. 7.** The loss rate of the two methods with epoch = 20

of the data (object). In the study [32], the authors used Android phones to collect actionable data and then used the LSTM-RNN model to train and the research results were quite high at 96 %. Although the number of markers (joints) is only 3, this study has the number of markers is 41.

The results of Figs. 4 and 5, the maximum results are achieved by the PCA method with the number of dimension 13, and by the CGA method with the number of dimension 2.

Figure 6 shows that as the number of epochs increases, the recognition accuracy will increase.

When epoch increases, the recognition results can also increase, and when epoch reaches a certain value, the results cannot increase (a straight line or descending).

Figure 7 shows the output loss in each step of RNN. The loss rate decreases, the recognition results increases. This figure also shows that the loss rate of the CGA method is lower than that of PCA during each epoch.

Conclusion

In this paper, we proposed a normalization method for input data by calculating deviations from the mean coordinate, before using PCA and CGA to reduce the number of dimensions and create input data for the RNN network. Experimental results show that the proposed method CGA_RNN has 88.50 % higher results than 72.83 % of PCA_RNN. Theoretically, RNN can learn distant states. However, in reality, RNN only brings the previous states to the later stages.

However, the RNN model only carries a certain number of states after that, it would be vanishing gradients, and this model can only be learned from near states (short term memory). Therefore, it is necessary to apply the proposed model with LSTM to improve the research results. Researching CGA to apply to DL is a direction, creating a basis for analyzing large data of moving objects in space and other applications such as image processing, action recognition, and automatic control in the future.

Acknowledgements

This work was supported by The University of Danang, University of Science and Technology, code number of Project T2019-02-20.

References

1. Rosebrock A. *Deep Learning for Computer Vision*. Py-imageSearch, 2017. 500 p.
2. Arthishwari K., Anand M. Design of LSTM-RNN on a sensor based HAR using Android phones. *International Journal of Recent Technology and Engineering (IJRTE)*, 2020, vol. 8, no. 5, pp. 2277–3878. doi:10.35940/ijrte.E6821.018520
3. Pham C. T., Kopylov A. Multi-quadratic dynamic programming procedure of edgepreserving denoising for medical images. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2015, XL-5/W6, pp. 101–106.
4. Goodfellow I., Bengio Y., and Courville Aaron. *Deep Learning*. MIT Press, 2018. 800 p. doi:10.1007/s10710-017-9314-z
5. Liu H., and Taniguchi T. Feature extraction and pattern recognition for human motion by a deep sparse autoencoder. *IEEE International Conference on Computer and Information Technology*, 2014, pp. 173–181. doi:10.1109/CIT.2014.144
6. Ji S., Xu W., Yang M., and Yu K. 3D convolutional neural networks for human action recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, vol. 35, no. 1, pp. 221–231. doi:10.1109/TPAMI.2012.59
7. Du Y., Wang W., and Wang L. Hierarchical recurrent neural network for skeleton based action recognition.

- IEEE Conference on Computer Vision and Pattern Recognition*, 2015, pp. 1110–1118.
8. Mikolov T., Bengio Y. and Pascanu R. On the difficulty of training recurrent neural networks. *International Conference on Machine Learning*, 2013, vol. 28, pp. 1310–1318. arXiv:1211.5063v2.
 9. Jolliffe I. T. *Principal Component Analysis*. 2nd Ed. New York, Springer-Verlag, 2002. 518 p.
 10. Smith L. I. *A tutorial on Principal Components Analysis*. Cornell University, USA, 2002. 27 p.
 11. Jolliffe I. T. A note on the use of principal components in regression. *Applied Statistics*, 1982, vol. 31, iss. 3, pp. 300–303.
 12. Alan J. I. *Linear Discriminant Analysis*. Springer, 2012. Pp. 1525–1548.
 13. Nixon M. S., and Aguado A. S. *Feature Extraction and Image Processing for Computer Vision*. 3rd Ed. ELSEVIER, 2012. 632 p.
 14. Pham M. T., Tachibana K., Hitzer E. M. S., Buchholz S., Yoshikawa T., and Furuhashi T. Feature Extractions with geometric algebra for classification of objects. *IEEE World Congress on Computational Intelligence*, Hongkong, 2008, pp.
 15. Hildenbrand D., and E. Hitzer. Analysis of point clouds using conformal geometric algebra. *3rd International Conference on Computer Graphics Theory and Applications*, Funchal, Madeira, Portugal, 2008, pp. 69–94.
 16. Minh Tuan Pham, Hao Do Phuc, Kanta Tachibana. Feature extraction for classification method using principal component based on conformal geometric algebra. *IEEE World Congress on Computational Intelligence / International Joint Conference on Neural Network*, 2016, no. 978-1-5090-0620, pp. 4112–4117.
 17. Hestenes D., and Sobczyk G. *Clifford algebra to geometric calculus. A unified language for mathematics and physics*. Springer, Dordrecht, 1984. 309 p. doi:10.1007/978-94-009-6292-7
 18. Doran C., and Lasenby A. *Geometric algebra for physicists*. Cambridge University Press, 2003. 578 p.
 19. Pham M. T., Tachibana K., Hitzer E. M. S., Yoshikawa T., and Furuhashi T. Classification and clustering of spatial patterns with geometric algebra. *AGACSE 2010*, Leipzig, 2010, no. 978-1-84996-107-3, pp. 231–247. doi:10.1007/978-1-84996-108-0_12
 20. Pham M. T., Tachibana K., Yoshikawa T., and Furuhashi T. A clustering method for geometric data based on approximation using conformal geometric algebra. *2011 IEEE International Conference on Fuzzy Systems*, 2011, pp. 2540–2545. doi:10.1109/FUZZY.2011.6007574
 21. Hachaj T., Ogiela M. R., and Piekarczyk M. Dependence of Kinect sensors number and position on gestures recognition with Gesture Description Language semantic classifier. *Computer Science and Information Systems (FedCSIS), Federated Conference*, 2013, pp. 571–575.
 22. Afsar P., Cortez P., and Santos H. Automatic human action recognition from video using hidden Markov model. *IEEE 18th International Conference on Computational Science and Engineering*, 2015, pp. 105–109. doi.org/10.1109/CSE.2015.41
 23. Eckhard Hitzer, Tohru Nitta, and Yasuaki Kuroe. Applications of Clifford’s geometric algebra. *Advances in Applied Clifford Algebras*, 2013, vol. 23, iss. 2, pp. 377–404. arXiv:1305.5663v1.
 24. Goodfellow I., Bengio Y., and Courville A. *Sequence Modeling: Recurrent and Recursive Nets*. In: *Deep Learning*. MIT Press, 2016. Pp. 367–415.
 25. *The Carnegie Mellon University, The Carnegie Mellon University Motion Capture Database*. Available at: <http://mocap.cs.cmu.edu> (accessed 20 April 2020).
 26. Nguyen N. H. V., Pham M. T., Do P. H. Marker selection for human activity recognition using combination of conformal geometric algebra and principal component regression. *Proceedings of the Seventh International Symposium on Information and Communication Technology*, December 8–9, 2016, pp. 274–379. doi:10.1145/3011077.3011133
 27. Md. Al Mehedi Hasan, Omar Faruqe. Face recognition using PCA and SVM. *Anti-counterfeiting, Security, and Identification in Communication, ASID 2009*, pp. 97–101.
 28. Gehrig D., and Schultz T. Selecting relevant features for human motion recognition. *19th International Conference on Pattern Recognition*, Tampa, FL., 2008, pp. 1–4. doi:10.1109/ICPR.2008.4761290
 29. K. G. Manosha Chathuramali, Ranga Rodrigo. Faster human activity recognition with SVM. *The International Conference on Advances in ICT for Emerging Regions*, Colombo, 2012, pp. 197–203.
 30. Wei L., and Shah S. K. Human activity recognition using deep neural network with contextual information. *The 12th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP 2017)*, pp. 34–43.
 31. da Silva R. E., Ondrej J., and Smolic A. Using LSTM for automatic classification of human motion capture data. *14th International Conference on Computer Graphics Theory and Applications, VISIGRAPP 2019*, pp. 236–243.
 32. Arthishwari K., Anand M. Design of LSTM-RNN on a sensor based HAR using Android phones. *International Journal of Recent Technology and Engineering (IJRTE)*, 2020, vol. 8, no. 5, pp. 2277–3878.

УДК 004.93

doi:10.31799/1684-8853-2020-5-2-11

Метод распознавания действий человека на основе конформной геометрической алгебры и рекуррентной нейронной сетиНгуен Нанг Хунг Ван^а, аспирант, Specialist, orcid.org/0000-0002-9963-7006, nguyenvan@dut.udn.vnФам Минь Туан^а, PhD, преподаватель, orcid.org/0000-0001-9843-9676, pmtuan@dut.udn.vnДо Фук Хао^б, M. Sc., преподаватель, orcid.org/0000-0003-0645-0021, haodp@dau.edu.vnФам Конг Тханг^а, PhD, преподаватель, orcid.org/0000-0002-6428-102X, pcthang@dut.udn.vnТатибана Канта^в, PhD, доцент, orcid.org/0000-0002-8675-7842, kanta@cc.kogakuin.ac.jp^аУниверситет Дананга — Университет науки и технологий, факультет информационных технологий, ул. Гнунг Лыонг Банг 54, Дананг, 550000, Вьетнам^бДанангский университет архитектуры, ул. Нуи Тхань 566, Дананг, 550000, Вьетнам^вУниверситет Когакуин, Ниси-Синдзюку 1-24-2, Синдзюку-ку, Токио, 163-8677, Япония

Постановка проблемы: глубокое обучение играет важную роль в машинном обучении и искусственном интеллекте. Оно находит широкое применение во многих областях, где приходится оперировать большими массивами данных, например в обработке естественных языков или распознавании изображений. Высокая размерность данных ведет к таким проблемам машинного обучения, как чрезмерное обучение или падение точности. Для их преодоления предлагаются методы одновременного снижения размерности данных и вычислительной сложности. Недостаток этих методов состоит в их ориентированности на данные, распределенные по плоскости. В случае данных, распределенных по гиперсфере, таких как передвигающийся в пространстве объект, результаты обработки показывают качество ниже ожидаемого. **Цель:** применение конформной геометрической алгебры для одновременного снижения размерности массива данных, необходимых для выделения признаков и распознавания действий человека с использованием рекуррентной нейронной сети. **Результаты:** данные о действиях человека в трехмерной системе координат подвергаются предобработке и нормализации путем вычисления отклонений от средних координат. Далее данные преобразуются в векторы в пространстве конформной геометрической алгебры, а их размерность снижается для извлечения векторов признаков. Наконец, применяется модель рекуррентной нейронной сети для обучения векторов признаков. Опытные результаты, полученные на массиве данных захвата движений для восьми действий, показали, что комбинация конформной геометрической алгебры с рекуррентной нейронной сетью обеспечивает наилучший результат в 92,5 % случаев. **Практическая значимость:** некоторые действия человека, например прыжок или танец, не сопряжены с перемещением в пространстве, в отличие от таких, как бег или ходьба. Поэтому необходим способ стандартизации действий. В случае данных, распределенных по гиперсфере, разработанный метод позволяет выделять признаки с одновременным снижением размерности массива данных для распознавания действий человека посредством рекуррентной нейронной сети.

Ключевые слова — распознавание действий, анализ принципиальных компонент, конформная геометрическая алгебра, глубокое обучение.

Для цитирования: Nguyen Nang Hung Van, Pham Minh Tuan, Do Phuc Hao, Pham Cong Thang, Tachibana Kanta. Human action recognition method based on conformal geometric algebra and recurrent neural network. *Информационно-управляющие системы*, 2020, № 5, с. 2–11. doi:10.31799/1684-8853-2020-5-2-11

For citation: Nguyen Nang Hung Van, Pham Minh Tuan, Do Phuc Hao, Pham Cong Thang, Tachibana Kanta. Human action recognition method based on conformal geometric algebra and recurrent neural network. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 2–11. doi:10.31799/1684-8853-2020-5-2-11

В статье Burkov A. A., Shneer S. V., Turlikov A. M. Lower bound for average delay in unblocked random access algorithm with orthogonal preambles, 2020, № 3, на с. 84 в разделе Acknowledgment вместо project number 19-31-27001

следует читать

project number 19-37-90041.

Применение штрихкодирования для цифрового маркирования видеопоследовательностей на основе частотных преобразований

А. Г. Зотин^а, канд. техн. наук, доцент, orcid.org/0000-0001-9954-9826, zotin@sibsau.ru

М. Н. Фаворская^а, доктор техн. наук, профессор, orcid.org/0000-0002-2181-0454, favorskaya@sibsau.ru

^аСибирский государственный университет науки и технологий им. академика М. Ф. Решетнёва, им. газеты «Красноярский рабочий» пр., 31, Красноярск, 660037, РФ

Постановка проблемы: защита цифровых данных представляет важную задачу для владельцев мультимедийных продуктов. Одним из эффективных путей ее решения является использование цифрового маркирования видеопоследовательностей. Проблема заключается в необходимости повышать устойчивость цифровых водяных знаков к транскодированию при передаче информации по незащищенным каналам связи. **Цель:** разработка метода встраивания информации в видеопоследовательности, обладающего повышенной устойчивостью к транскодированию. **Методы:** новый метод встраивания и извлечения текстовых цифровых водяных знаков основан на штрихкодировании и преобразовании Арнольда. **Результаты:** разработаны схемы слепого маркирования цифровых видеопоследовательностей в хроматических компонентах на основе дискретного вейвлет-преобразования и дискретного косинусного преобразования. Проведено экспериментальное исследование на устойчивость предложенного метода с использованием кодеков H.264 (AVC/H.264) и H.265 (HEVC/H.265). Выполнена оценка влияния транскодинга, которая показала высокую степень устойчивости частотного метода на основе вейвлет-преобразования. Экспериментально установлено, что для случаев транскодирования методом однопроходного сжатия видеопоследовательностей при значении параметра Constant Rate Factor, не превышающем 26, удается полностью восстановить встроенную текстовую информацию. **Практическая значимость:** разработанный метод позволяет надежно встраивать и извлекать текстовую информацию из видеопоследовательностей, подвергающихся сжатию методами высокоэффективного кодирования, при их передаче по незащищенным каналам связи, что является защитой авторских прав владельцев мультимедийных продуктов.

Ключевые слова – цифровой водяной знак, цифровое маркирование видеопоследовательностей, штрихкодирование, преобразование Арнольда, дискретное вейвлет-преобразование, дискретное косинусное преобразование.

Для цитирования: Зотин А. Г., Фаворская М. Н. Применение штрихкодирования для цифрового маркирования видеопоследовательностей на основе частотных преобразований. *Информационно-управляющие системы*, 2020, № 5, с. 12–23. doi:10.31799/1684-8853-2020-5-12-23

For citation: Zotin A. G., Favorskaya M. N. Application of bar coding for digital watermarking of video sequences based on frequency transforms. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 12–23 (In Russian). doi:10.31799/1684-8853-2020-5-12-23

Введение

Защита мультимедийных данных, передаваемых по незащищенным каналам связи, является важной задачей для владельцев мультимедийных продуктов. Она включает два основных направления — шифрование и сокрытие информации. Шифрование подразумевает использование криптографических методов защиты, а сокрытие данных включает стеганографические методы и цифровое маркирование. Основным назначением методов цифрового маркирования являются аутентификация и защита авторских прав. Цифровое маркирование подразумевает внедрение в изображение или видеопоследовательность скрытого цифрового водяного знака (ЦВЗ), позволяющего обнаружить изменения видеоматериала, а также получить встроенную метаданную из мультимедиаконтента. Встраивание ЦВЗ в видеопоследовательности используется для защиты авторских прав, контроля целост-

ности, а также для скрытой передачи служебной информации. Так, в случае защиты авторских прав в ЦВЗ встраивается информация об авторе, используемом программном обеспечении и иная информация, характеризующая авторство.

Подходы к встраиванию информации в видеопоследовательности

От передачи несжатого видеоматериала по незащищенным каналам связи отказались практически сразу ввиду чрезвычайно большого информационного объема и избыточности. Это привело к активному развитию технологий цифрового сжатия видеосигнала. В настоящее время широкое распространение получил стандарт H.264, или AVC (Advanced Video Coding), менее распространенным является формат H.265, или HEVC (High Efficiency Video Coding). При этом потребовалась защита изображений от несанкциониро-

ванного копирования. С 1990-х годов начали активно развиваться методы цифрового маркирования. Причем исследования продолжаются до сих пор, что вызвано появлением новых кодеков для передачи изображений и видеопоследовательностей с высоким и сверхвысоким разрешением, а также выявлением факторов искажения визуального контента в больших наборах данных, предназначенных для обучения глубоких сетей.

Процесс встраивания ЦВЗ в видеопоследовательность можно рассматривать с различных точек зрения. В одном из подходов видеoinформация рассматривается как последовательность битов. При этом в случае сохранения или передачи видеoinформации с использованием контейнеров будут формироваться соответствующие пакеты, зачастую имеющие избыточную информацию. Данная избыточная информация может быть использована в целях внедрения информации в форме ЦВЗ [1, 2].

Другой подход интерпретирует видеопоследовательность как множество последовательных кадров, отображаемых с высокой скоростью. При такой интерпретации можно использовать любой метод встраивания ЦВЗ, разработанный для статических изображений. При этом предполагается независимая обработка каждого кадра видеопоследовательности как во время встраивания, так и в ходе извлечения ЦВЗ. В рамках данного подхода реализуются известные алгоритмы встраивания ЦВЗ без модификации модулей, отвечающих за кодирование/декодирование видеопоследовательности. Однако применение алгоритмов для каждого кадра возможно только для цифрового маркирования видеопоследовательностей, не подвергающихся сжатию.

Также известен подход встраивания ЦВЗ, использующий временную характеристику видеопоследовательности и особенности кодирования, состоящие в том, что множество кадров интерпретируется как набор макроблоков, включающих I-кадры (ключевые кадры), P-кадры (кодирование с предсказанием) и B-кадры (кодирование с предсказанием и бинаправленным кодированием). При этом возможны разные формы реализации механизма встраивания, которые зависят от используемого кодека. Так, существует ряд алгоритмов, позволяющих встраивать ЦВЗ в сжатый поток MPEG напрямую, без процесса кодирования и декодирования [3, 4]. Однако у таких алгоритмов имеется значительное ограничение на объем встраиваемой информации, которое зависит от битрейта (количества бит, используемых для передачи/обработки данных в единицу времени). Помимо этого используется подход к встраиванию ЦВЗ, в рамках которого придется вносить изменения в модули кодирования/декодирования информации, в частности, при ис-

пользовании форматов сжатия AVC/HEVC [5, 6]. Метод встраивания визуальных ЦВЗ в I-кадры видеопоследовательностей предложен в статье [7]. Более полный обзор по цифровому маркированию видеопоследовательностей приведен в работе [8].

Методы цифрового маркирования визуальной информации

Методы цифрового маркирования разделяются на пространственные и частотные. При маркировании в пространственной области встраивание ЦВЗ происходит непосредственно в пиксели. Пространственные алгоритмы внедряют ЦВЗ в исходное изображение посредством изменений параметров яркости или цветовых компонентов. Например, при встраивании могут изменяться младшие биты — метод наименьшего значащего бита (Least Significant Bits — LSB). В методе Куттера — Джордана — Боссена отдельные биты водяного знака многократно внедряются в изображение путем изменения значения синего канала в пикселе. Само изменение пропорционально яркостной компоненте пиксела и может иметь как положительные, так и отрицательные значения в зависимости от значения встраиваемого бита водяного знака [9]. Недостатком пространственных методов является низкая устойчивость к нелегитимным операциям обработки изображения (например, зашумлению, изменению размера, фильтрации, сжатию).

Частотные методы обладают более высокой устойчивостью, так как ЦВЗ внедряется в частотные коэффициенты контейнера (изображения или кадра), которые вычисляются с использованием определенных преобразований. К частотным преобразованиям относят: дискретное преобразование Фурье (Digital Fourier Transform — DFT) [10], дискретно-косинусное и дискретно-синусное преобразования (Digital Cosine Transform — DCT и Digital Sine Transform — DST) [11], дискретное вейвлет-преобразование (Digital Wavelet Transform — DWT) [12], дискретное преобразование Адамара (Digital Hadamard Transform — DHT) [13] и др. Одним из методов, использующих дискретно-косинусное преобразование, является метод (алгоритм) Коха — Жао [14].

Процесс маркирования включает две основные операции: внедрение ЦВЗ в изображение или кадр на стороне отправителя и его извлечение на стороне получателя после передачи по защищенным каналам связи. В алгоритме Коха — Жао внедрение бит встраиваемого сообщения осуществляется за счет изменения двух псевдослучайно выбранных коэффициентов среднечастотной области, сформированных в результате

применения дискретно-косинусного преобразования для неперекрывающихся блоков изображения размером 8×8 пикселей. Предполагается, что битовое представление встраиваемой информации меньше количества потенциально возможных блоков размером 8×8 пикселей. При этом желательно, чтобы исходное изображение имело размеры, кратные восьми пикселям.

Метод встраивания ЦВЗ с применением штрихкодирования

Из-за того, что сжатие видеопоследовательностей часто происходит автоматически с помощью кодека достоверно неизвестно типа, целесообразно выполнять цифровое маркирование I-кадров, отчасти учитывая движение в кадре. Отметим, что при формировании P- и B-кадров сохраняется не только информация о новых участках кадров, но и данные о перемещении блоков. Соответственно, чем больше группа кадров (Group Of Pictures — GOP), тем больше изменяется структура текущего кадра относительно ключевого кадра и сказывается эффект сжатия. По умолчанию в большинстве общедоступных AVC- и HEVC-кодеков максимальный размер GOP составляет 250 кадров, но может изменяться пользователем [15, 16]. Поскольку на уровне API кодеков не представляется возможным жестко установить ключевой кадр и управлять размером GOP в процессе кодирования, то первичным этапом маркирования видеопоследовательности будет выбор кандидатов на роль ключевых кадров [17].

Далее проводится оценка смежных кадров, расположенных за потенциально ключевым кадром, с целью определить потенциальные зоны движения. Кодирование видеопоследовательностей выполняется отдельно для яркостной компоненты и хроматических компонент в цветовом пространстве YCbCr. При этом в зависимости от разрешения кадра применяются различные цветовые схемы согласно рекомендациям сектора радиокommunikаций Международного союза электросвязи (International Telecommunication Union Radiocommunication Sector — ITU-R). В случае стандартного вещания (SD) применяется схема BT.601, для телевидения высокой четкости (HDTV) с разрешением 1920×1080 пикселей применяется схема BT.709, а для видеопоследовательностей, соответствующих стандарту сверхвысокой четкости (UHDTV), когда разрешение кадра достигает 4K (3840×2160 пикселей) или 8K (7680×4320 пикселей), используется схема BT.2020 [18].

В качестве меры изменения блоков взята средняя абсолютная разница с учетом 50 % доли яркостной компоненты (Y) и 25 % на каждую хроматическую компоненту (Cb, Cr). Расчет метрики

для блока BL размером $N \times N$ текущего кадра f происходит с учетом предыдущего кадра $f - 1$ следующим образом:

$$MAD_{BL} = \frac{\sum_{p \in BL} |Y_f(p) - Y_{f-1}(p)|}{2 \times N^2} + \frac{\sum_{p \in BL} |Cb_f(p) - Cb_{f-1}(p)| + \sum_{p \in BL} |Cr_f(p) - Cr_{f-1}(p)|}{4 \times N^2},$$


где p — пиксел, принадлежащий блоку BL .

В случае если значение превышает некоторый порог T_{bc} , то считается, что произошли существенные изменения и, скорее всего, это измененный блок.

Подготовка встраиваемой метainформации

Обычно извлеченный ЦВЗ содержит искажения, вызванные непреднамеренными или преднамеренными атаками. Поэтому требуются механизмы, которые позволили бы восстановить ЦВЗ. Использование обычной графической формы не дает такой возможности из-за неизвестного характера искажений, соответственно, восстановление встроенной информации будет затруднительным. Для большей устойчивости встраиваемой метainформации предлагается использовать штрихкодирование. Штрихкод позволяет повысить вероятность корректного считывания информации, поскольку при потере части информации возможно восстановление полос штрихкода благодаря их известной геометрической форме. Для обеспечения наибольшей емкости встраиваемой информации решено использовать штрихкод Code 128, который учитывает латинские символы, цифры и специальные знаки: «Символы штрихового кода Code 128 состоят из трех штрихов и трех промежутков, имеющих модульное строение. Размер одного штриха и промежутка составляет от одного до четырех модулей. Каждый кодируемый символ представлен 11 модулями. Остановочный (стоп) знак состоит из 13 модулей» [19]. При формировании штрихкода для ЦВЗ решено сделать один модуль эквивалентным одному встраиваемому пикселу. Для восстановления штрихкода важен вертикальный размер полос. Экспериментально выяснено, что высота 16 пикселей является достаточной для реконструкции извлеченного штрихкода.

В целях лучшего сокрытия встраиваемых штрихкодов их отображение изменено следующим образом. Выполняется разделение штрихкода на фрагменты размерностью 32×16 пикселей и происходит склейка в блоки 32×32 пиксела.



■ **Рис. 1.** Подготовка ЦВЗ: *a* — сформированный штрихкод с делением на блоки; *b* — слепок ЦВЗ; *c* — слепок ЦВЗ после преобразования Арнольда; *d* — графическое представление кода ЦВЗ

■ **Fig. 1.** Preparing of digital watermark: *a* — barcode divided into blocks; *b* — mask of a watermark; *c* — mask of a watermark after Arnold transform; *d* — graphic representation of watermark code

Данные блоки изменяются посредством преобразования Арнольда [20]. Для блока размерностью $N \times N$ преобразование Арнольда преобразует координаты (X, Y) элемента в новые координаты (X_{new}, Y_{new}) , используя следующие уравнения:

$$X_{new} = (X + Y) \bmod N;$$

$$Y_{new} = (X + 2 \times Y) \bmod N.$$

Особенностью преобразования Арнольда является то, что после определенного количества итераций получается его оригинальное значение. Для усложнения процесса злоумышленного декодирования информации используется различное количество итераций преобразования Арнольда для каждого ЦВЗ. Количество итераций определяется ключом (паролем). После преобразования блоки собираются в единое целое (слепок ЦВЗ). В дальнейшем с учетом информационной емкости кадра формируется код ЦВЗ, возможно, с циклическим повторением слепка. Пример выполнения этапа подготовки ЦВЗ в кадр размером 1280×720 пикселей представлен на рис. 1, *a-d*.

Оценить размер информационного сообщения (в битах) можно, используя выражение

$$V = (cntSim \times 11 + Fpart) \times LineH,$$

где *cntSim* — количество символов; *LineH* — размер штриха; *Fpart* — размер фиксированной части, определяемый как сумма блоков начала (11), конца (13) и контрольного символа (11).

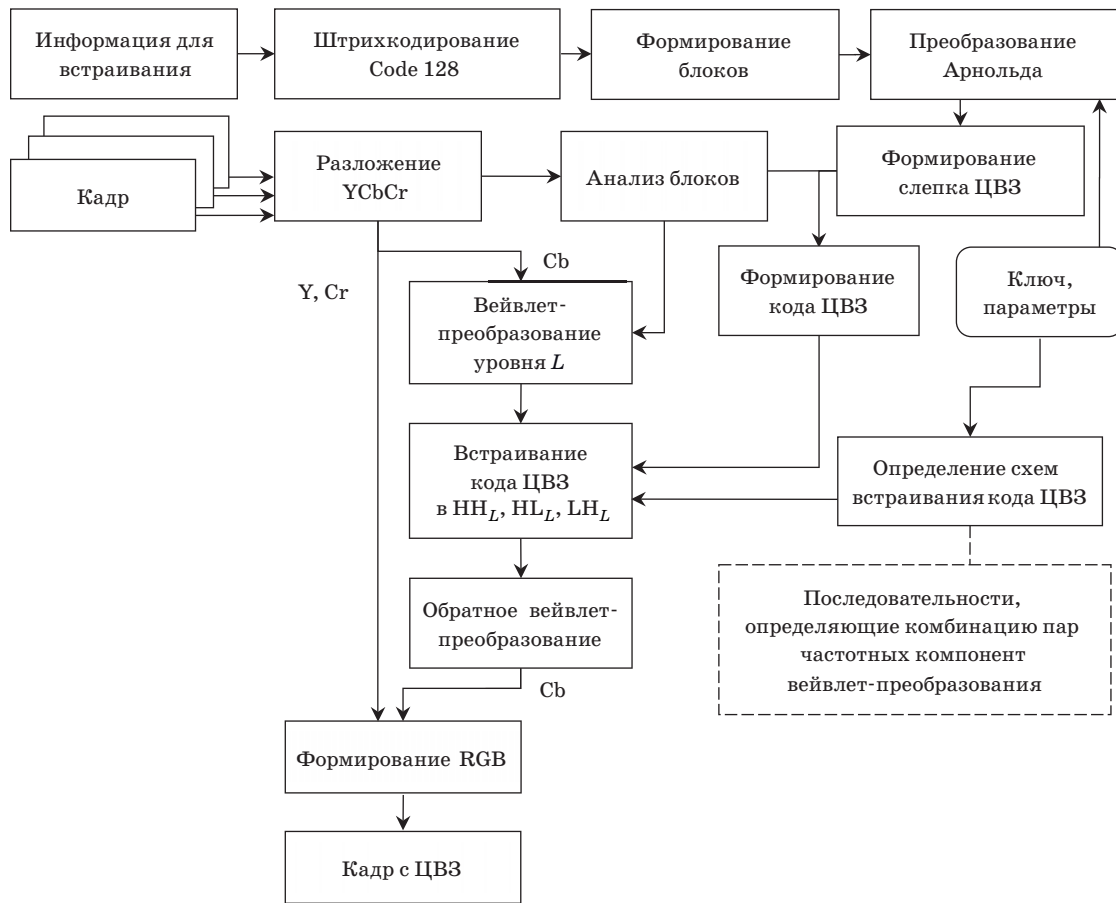
Встраивание ЦВЗ

Схема внедрения ЦВЗ в предполагаемый ключевой кадр изображена на рис. 2. После перево-


да кадров в цветовую модель YCbCr происходит определение потенциальных границ встраивания (количества кадров относительно ключевого кадра). На этом этапе кадр разделяется на блоки и выясняется, сколько блоков было сформировано в результате перемещения (малый вектор движения) и сколько новых блоков появилось. Данный этап необходим, поскольку при формировании Р- и В-кадров сохраняется информация о перемещении/изменении блоков, а не сами блоки.

Разбиение на блоки происходит в зависимости от схемы внедрения и выбранного уровня вейвлет-преобразования. На основе предварительных оценок было решено использовать два уровня вейвлет-преобразования. В рамках второго уровня формируется энергия, характерная для блоков размерностью 8×8 пикселей, которую можно интерпретировать как средние частоты. Третий уровень дает более низкие частоты, что может быть полезно с учетом особенностей кодирования видеопоследовательностей. Так, в случае кодирования кодеками AVC/HEVC информация о кадре (без специального переопределения параметров) передается в виде макropикселей, сформированных по схеме YUV420 и YUV420p16 для 8- и 10-битных режимов соответственно. При такой схеме хроматические компоненты имеют вдвое меньшее разрешение, чем яркостная компонента. В случае использования схемы YUV444 разрешение хроматических компонент будет полностью соответствовать разрешению яркостной компоненты. Схема YUV422 обеспечивает хроматическим компонентам половину горизонтального разрешения и полное вертикальное разрешение. На рис. 3 показаны схемы разложения яркостной и хроматической компонент при формировании макроблоков, где *X* обозначает частоту дискретизации яркостного канала, определяющего ширину макropиксела, *a* — это число выборок хроматических компонент (Cb, Cr) в горизонтальном направлении в первой строке, а число *b* характеризует выборки компонент (Cb, Cr) во второй строке.

Вейвлет-преобразование разделяет сигнал на два компонента равного размера. Первый компонент характеризует низкочастотные области — аппроксимацию (*approximation*), второй компонент — высокочастотные области, описывающие детали (*detail*) или различие (*difference*). Поскольку в программном модуле встраивания ЦВЗ выполняются целочисленные вычисления, то для осуществления прямого и обратного преобразований решено использовать упрощенную реализацию вейвлетов Хаара, адаптированную для хранения в виде байт. В случае обработки одномерного дискретного сигнала $S = \{s_j\}_{j \in Z}$ вычисление компонент *approximation* (*L*) и *detail* (*H*)



■ **Рис. 2.** Схема внедрения ЦВЗ в кадр видеопоследовательности
 ■ **Fig. 2.** Flowchart of watermark embedding in a frame of video sequence



■ **Рис. 3.** Схемы разложения яркостной и хроматической компонент
 ■ **Fig. 3.** Schemes of decomposition of intensity and chromatic components

с учетом целочисленного представления (байт) происходит по формулам

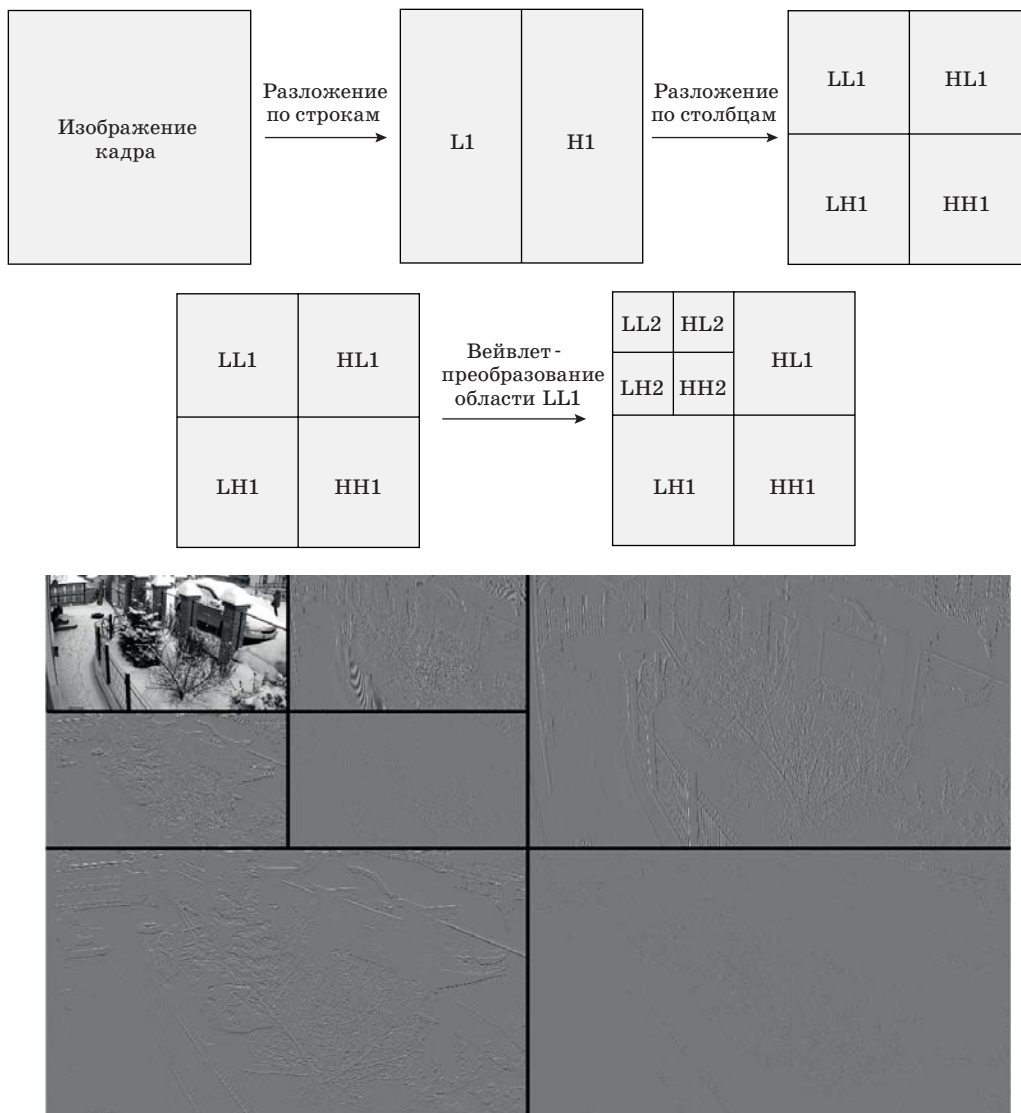
$$L_j = \frac{s_{2j} + s_{2j+1}}{2}; H_j = \frac{s_{2j} - s_{2j+1}}{2} + 128.$$

Обратное вейвлет-преобразование (восстановление сигнала) выполняется следующим образом:

$$s_{2j} = L_j + H_j - 128; s_{2j+1} = L_j - (H_j - 128).$$

В результате применения вейвлет-преобразования к изображению путем поочередного одномерного вейвлет-преобразования строк и столбцов будут сформированы четыре области LL, HL, LH и HH. На рис. 4 показаны схема и пример выполнения вейвлет-разложения изображения для двух уровней. Для формирования третьего уровня разложения будет использоваться область низкочастотных компонент LL2.

Идея алгоритма встраивания в вейвлет-коэффициенты, полученные на заданном уровне разложения L хроматической составляющей C_b , расширяет алгоритм Коха — Жао. Встраивание кода ЦВЗ происходит на основе пар псевдослучайных элементов областей HL_L, HH_L, LH_L . При этом комбинации пар для каждой частотной области будут соответствовать определенной схеме встраивания, сформированной на основе ключа. Поскольку использована упрощенная схема представления частотной области (диапазон $0...255$), то для записи бита информации используется следующее правило:



■ **Рис. 4.** Схема вейвлет-преобразования с разложением на два уровня
 ■ **Fig. 4.** Scheme of wavelet transform with two-level decomposition

$$K_1 > K_2 + St, \text{ если } W_{\text{bit}} = 1;$$

$$K_1 < K_2 - St \times 0,5, \text{ если } W_{\text{bit}} = 0,$$

где K_1 и K_2 — элементы частотной области; St — величина, характеризующая силу различия частотных коэффициентов (значение из диапазона 1...4); W_{bit} — бит встраиваемого сообщения.

В предлагаемом способе изменения коэффициентов при записи бита, в отличие от алгоритма Коха — Жао, предлагается изменять сразу оба коэффициента на идентичную величину, но с разным знаком.

В качестве альтернативной схемы встраивания ЦВЗ, но уже для яркостной компоненты или хроматической компоненты Cr , предлагается применить алгоритм Коха — Жао с использованием дискретно-косинусного преобразования размером

4×4 пикселей для первого уровня вейвлет-преобразования. В случае задействования всех доступных блоков изображения размером $(I_H \times I_W)$ информационная емкость встраиваемого сообщения для классического алгоритма Коха — Жао будет определена как $(I_H \times I_W)/64$, поскольку данный алгоритм предусматривает встраивание одного бита в блок 8×8 пикселей. При использовании только вейвлет-преобразования уровня L максимальная информационная емкость встраиваемого сообщения определяется следующим выражением:

$$V = \frac{(I_H \times I_W)}{2 \times p_{\text{bit}} \times 2^{2 \times L}},$$

где p_{bit} — степень разреженности изменяемых коэффициентов.

Для двух уровней вейвлет-преобразования информационная емкость встраивания сообщения при $p_{bit} = 1$ будет в два раза выше, чем у алгоритма Коха — Жао, а при $p_{bit} = 2$ будет идентичная емкость. Для трех уровней вейвлет-преобразования и степени разреженности, равной 1, информационная емкость будет в два раза ниже по сравнению с алгоритмом Коха — Жао. В случае комбинации вейвлет-преобразования с дискретным косинусным преобразованием области 4×4 пикселей информационная емкость встраивания сообщения вычисляется по формуле

$$V = \frac{(I_H \times I_W)}{16 \times 2^{2 \times L}}$$

При вейвлет-разложении первого уровня емкость встраивания сообщения будет полностью эквивалентна алгоритму Коха — Жао.

Извлечение ЦВЗ

Извлечение информационного ЦВЗ из кадра видеопоследовательности выполняется по схеме, представленной на рис. 5.

Декодированный кадр переводится в цветовую модель YCbCr. Далее выполняется вейвлет-преобразование и считываются коды ЦВЗ из частотных областей HL_L, NH_L, LH_L . Во время счи-

тывания кода ЦВЗ (KD) происходит оценка пар коэффициентов из соответствующей частотной области следующим образом: если ($K_1 > K_2$), то $KD = 1$; если ($K_1 \leq K_2$), то $KD = 0$.

На основе полученных кодов формируется значение кода полного представления штрихкода FKD с учетом количества повторений rpt и размера оригинальной встроенной информации, вычисляемой функцией $size$ (при помощи специального маркера) согласно выражению

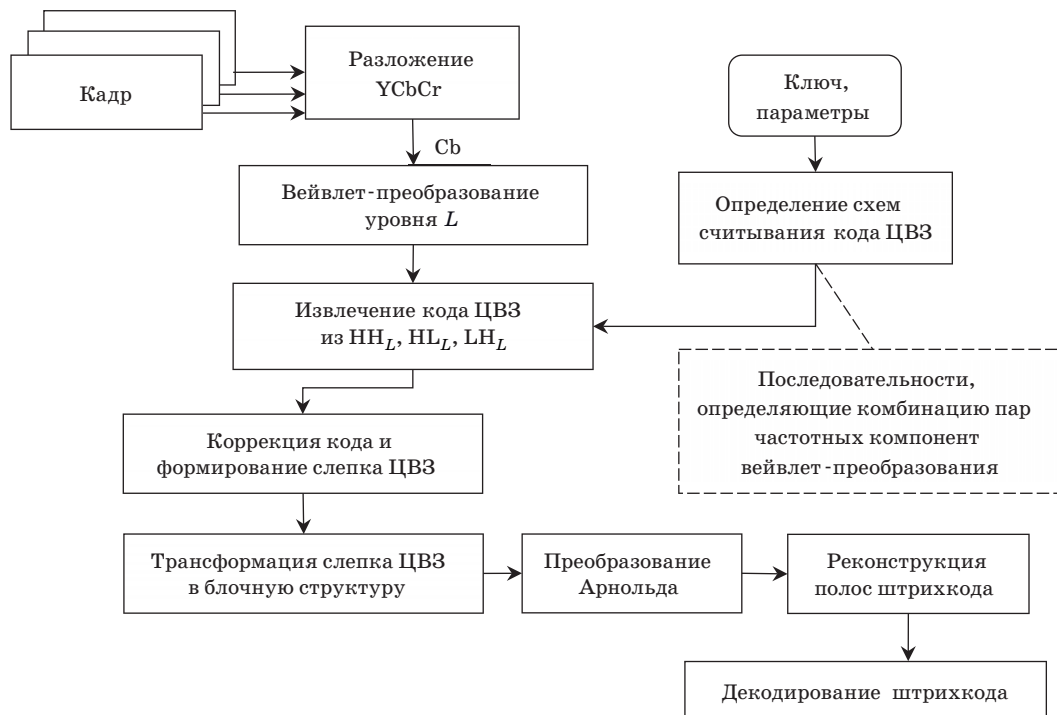
$$FKD_i = \sum_{r=0}^{rpt-1} \sum_{k \in \{HL_L, NH_L, LH_L\}} KD_k (i + r \times size(W)),$$

На основе кода FKD происходит формирование слепка, куда заносится значение 1 в случае, если $FKD_i \geq rpt \times 2$, и значение 0 в противном случае.

Полученный слепок ЦВЗ трансформируется в блочную структуру, для которой выполняется преобразование Арнольда. Для полученного представления штрихкода осуществляется реконструкция, учитывающая половинную высоту штриха.

Экспериментальные исследования

Эксперименты проводились с использованием видеопоследовательностей со следующими разре-



■ Рис. 5. Схема извлечения ЦВЗ на основе хроматической компоненты Cb
 ■ Fig. 5. Flowchart of watermark extraction based on chromatic component Cb

шениями: 1280×720 , 1920×1080 , 2560×1440 и 3840×2160 . Для более достоверной оценки каждая исходная видеопоследовательность обрабатывалась в незакодированной форме с представлением цвета по схеме YUV444p16. Для встраивания ЦВЗ использовалось RGB-представление. В экспериментальном исследовании были задействованы кодеки x264 (AVC) и x265 (HEVC). Кодирование с применением x264 выполнялось в двух режимах — 8 и 10 бит. В случае кодека x265 применялся 10-битный режим. В кодеках использовались настройки по умолчанию с применением предустановленных настроек параметров — схема Medium. Для оценки влияния степени сжатия на устойчивость алгоритма встраивания ЦВЗ был задействован механизм регулировки качества однопроходного кодирования (параметр CRF — Constant Rate Factor), задающий переменный битрейт (Quality-controlled variable bitrate).

Оценка степени изменений в визуальном отображении кадров выполнялась с использованием метрик PSNR (Peak Signal-to-Noise Ratio), PSNR-HVS (Peak Signal-to-Noise Ratio taking into account Contrast Sensitivity Function), SSIM (Structural Similarity), MS-SSIM (Multiscale Structural Similarity) и UIQI (Universal Image Quality Index). Оценка устойчивости предложенного метода встраивания ЦВЗ выполнялась с использованием метрики BER (Bit Error Rate):

$$BER(B1, B2) = \sum_{i=1}^N \frac{p_i}{N}, \quad p_i = \begin{cases} 1, & \text{если } B1_i \neq B2_i; \\ 0, & \text{если } B1_i = B2_i, \end{cases}$$

где $B1$ и $B2$ — последовательности бит до встраивания и после извлечения; N — размер последовательности.

Оценка максимального объема встраиваемой информации для рассматриваемых алгоритмов и используемого видеоматериала приведена в табл. 1.

Для оценки работы алгоритмов встраивания была подобрана комбинация параметров для встраивания ЦВЗ на основе DWT таким образом, чтобы объем встраиваемой информации был сопоставим с алгоритмом Коха — Жао. Так, для предлагаемого метода были определены следующие параметры: для уровня $L = 2$ степень разреженности изменяемых коэффициентов $p_{bit} = 2$; дополнительно в экспериментальных исследованиях была использована комбинация $L = 3$ и $p_{bit} = 1$. Усредненные данные оценок степени искажения кадра после встраивания ЦВЗ приведены в табл. 2.

Среднее время встраивания ЦВЗ для исследуемых реализаций представлено в табл. 3. Время рассчитано для 30 кадров, по каждому из которых сделано по 15 замеров. Замер выполнялся на компьютере с процессором Intel Core i5 3550 (3,3 ГГц).

Превосходство в скорости встраивания ЦВЗ с применением DWT по сравнению с алгоритмом Коха — Жао обусловлено тем, что при осуществлении вейвлет-преобразований не требуется проводить сложные вычисления. В алгоритме Коха — Жао основное время затрачивается на вычисление дискретного косинусного преобразования и обратного дискретного косинусного преобразования.

В ходе экспериментальных исследований с алгоритмом Коха — Жао при использовании видеопоследовательностей с разрешением 1920×1080 пикселей и выше было выяснено, что после сжатия с помощью кодеков x264 и x265 в случае, если показатель CRF выше 20, то восстановление встроеной информации является затруднительным и во многом будет зависеть от контента исходной последовательности. Это обусловлено особенностью кодирования видеопоследовательностей, так как кодек x264 использует макроблоки 16×16 пикселей, а кодек x265 — блоки с древовидной структурой кодирования от 64×64 до

■ Таблица 1. Максимальный объем встраиваемых данных, бит

■ Table 1. Maximum amount of embedded data, bits

Метод встраивания кода ЦВЗ (параметры)	Размер кадра, пиксел			
	1280 × 720	1920 × 1080	2560 × 1440	3840 × 2160
Коха — Жао	14 400	32 400	57 600	129 600
DWT ($L = 2, p_{bit} = 1$)	28 800	64 800	115 200	259 200
DWT ($L = 2, p_{bit} = 2$)	14 400	32 400	57 600	129 600
DWT ($L = 2, p_{bit} = 3$)	9600	21 600	38 400	86 400
DWT ($L = 2, p_{bit} = 4$)	7200	16 200	28 800	64 800
DWT ($L = 3, p_{bit} = 1$)	7200	16 200	28 800	64 800

■ Таблица 2. Оценка искажения кадра при встраивании ЦВЗ
 ■ Table 2. Estimate of frame distortion during watermark embedding

Метод встраивания кода ЦВЗ	Компоненты встраивания ЦВЗ	Размер кадра, пиксел			
		1280 × 720	1920 × 1080	2560 × 1440	3840 × 2160
PSNR					
Коха — Жао	Cb	36,941	36,678	36,675	36,677
	Y	35,743	35,982	35,971	37,079
	RGB	37,851	37,674	37,644	37,659
DWT ($L = 2, p_{bit} = 2$)	Cb	37,615	37,431	37,865	38,045
DWT ($L = 3, p_{bit} = 1$)	Cb	34,481	34,468	34,753	35,019
PSNR-HVS					
Коха — Жао	Cb	100 000	100 000	100 000	100 000
	Y	34,6531	34,4193	34,2877	34,2616
	RGB	39,9231	39,3529	39,3681	39,3758
DWT ($L = 2, p_{bit} = 2$)	Cb	38,1900	37,4128	37,9958	38,0996
DWT ($L = 3, p_{bit} = 1$)	Cb	34,6241	33,8627	33,1627	34,1285
SSIM					
Коха — Жао	Cb	0,9427	0,9600	0,9693	0,9361
	Y	0,9534	0,9663	0,9740	0,9451
	RGB	0,9719	0,9778	0,9837	0,9665
DWT ($L = 2, p_{bit} = 2$)	Cb	0,9727	0,9803	0,9838	0,9698
DWT ($L = 3, p_{bit} = 1$)	Cb	0,9636	0,9720	0,9766	0,9622
MS-SSIM					
Коха — Жао	Cb	0,9393	0,9064	0,8902	0,8819
	Y	0,9304	0,8875	0,8602	0,8575
	RGB	0,9583	0,9272	0,9152	0,9131
DWT ($L = 2, p_{bit} = 2$)	Cb	0,9685	0,9508	0,9422	0,9388
DWT ($L = 3, p_{bit} = 1$)	Cb	0,9622	0,9367	0,9332	0,9293
UIQI					
Коха — Жао	Cb	0,9970	0,9893	0,9923	0,9934
	Y	0,9973	0,9812	0,9866	0,9877
	RGB	0,9974	0,9799	0,9879	0,9872
DWT ($L = 2, p_{bit} = 2$)	Cb	0,9981	0,9894	0,9906	0,9968
DWT ($L = 3, p_{bit} = 1$)	Cb	0,9964	0,9827	0,9846	0,9861


8 × 8 пикселов. Также следует учитывать, что при декодировании используется фильтр уменьшения блочности, что влияет на качество восстановления кадра.

При оценке устойчивости встраивания кода ЦВЗ с применением дискретного вейвлет-преобразования и использования кодека h264 выяснено, что в случае если показатель CRF равен 30, то показатель BER в среднем имеет значение 0,32

(рис. 6). Одновременно с этим возможна реконструкция штрихкода, основанная на использовании повторений. В случае если оригинальная запись сжималась с показателем CRF 18 или менее, то при транскодировании с применением значения CRF до 25 удастся достичь значения BER, не превышающего 0,17, а с учетом цикличности записи слепка ЦВЗ полностью восстановить штрихкод. В случае многократного транскоди-

■ **Таблица 3.** Среднее время встраивания ЦВЗ, мс
 ■ **Table 3.** Average time of watermark embedding, ms

Метод встраивания кода ЦВЗ	Компоненты встраивания ЦВЗ	Размер кадра, пиксел			
		1280 × 720	1920 × 1080	2560 × 1440	3840 × 2160
Коха — Жао	Cb	4634,04	10 498,31	18 789,35	42 148,45
	Y	4616,81	10 483,12	18 862,77	41 969,31
	RGB	14 021,37	31 885,08	57 334,18	126 405,21
DWT ($L = 2, p_{bit} = 2$)	Cb	157,64	298,37	496,57	969,30
DWT ($L = 3, p_{bit} = 1$)	Cb	150,96	294,76	473,34	954,12



■ **Рис. 6.** Показатель BER извлеченного кода ЦВЗ в зависимости от степени сжатия на основе показателя контроля качества CRF

■ **Fig. 6.** BER estimate of extracted watermark code depending on a compression degree based on CRF estimate

рования (2–4 раза) с показателем CRF, не превышающим значения 25, также полностью удалось восстановить штрихкод. При этом значение BER для кода ЦВЗ составило 0,19.

Заключение

Разработан метод внедрения текстового сообщения в видеопоследовательность с применением штрихкодирования и цифрового маркирования на основе дискретного вейвлет-преобразования. Построены схемы внедрения и извлечения ЦВЗ в I-кадр видеопоследовательности, представленный в цветовой модели YCbCr. Показано, что алгоритм Коха — Жао существенно проигрывает

цифровому маркированию на основе штрихкодирования по времени для видеопоследовательностей высокого и сверхвысокого разрешения. Проведенные эксперименты показали высокую устойчивость к транскодированию видеопоследовательности с использованием стандартных параметров кодека. Если оригинальная запись сжималась с показателем CRF 18 или менее, то при транскодировании с применением значения CRF до 25 значение BER не превышает 0,17, а с учетом цикличности записи слепка ЦВЗ штрихкод полностью восстанавливается. В случае многократного транскодирования (2–4 раза) с показателем CRF, не превышающим значения 25, также удалось полностью восстановить штрихкод. При этом значение BER для кода ЦВЗ составило 0,19.

Литература

1. Wang X., Reeves D. S., Ning P., Feng F. Robust network-based attack attribution through probabilistic watermarking of packet flows. *Technical Report TR-2005-10*, 2005, Department of Computer Science, NC State Univ., 15 p.
2. Wolf P., Hauer E., Steinebach M. The video watermarking container: efficient real-time transaction watermarking. *Proc. SPIE 6819, Security, Forensics, Steganography, and Watermarking of Multimedia Contents X*, 2008, pp. 68190K.1–68190K.10. doi:10.1117/12.766544
3. Liu Y., Zhou P. A survey of video watermarking based on motion vector. *2014 International Conference on*

- Computer, Communications and Information Technology (CCIT 2014)*, 2014, pp. 1951–6851. doi:10.2991/ccit-14.2014.71
4. Wang P., Zhang Z., Ying J. A novel video watermark technique in motion vectors. *2008 International Conference on Audio, Language and Image Processing*, 2008, pp. 1555–1559. doi:10.1109/ICALIP.2008.4590271
 5. Stutz T., Uhl A. A survey of H.264 AVC/SVC encryption. *IEEE Transactions on Circuits and Systems for Video Technology*, 2012, vol. 22, no. 3, pp. 325–339. doi:10.1109/TCSVT.2011.2162290
 6. Ogawa K., Ohtake G. Watermarking for HEVC/H.265 stream. *2015 IEEE International Conference on Consumer Electronics (ICCE)*, 2015, pp. 102–103. doi:10.1109/ICCE.2015.7066337
 7. Favorskaya M. N., Buryachenko V. V. *Authentication and copyright protection of videos under transmitting specifications*. In: *Computer Vision in Advanced Control Systems-5*. ISRL. Favorskaya M. N., Jain L. C. (eds). Springer, Cham, 2020. Vol. 175. Pp. 119–160. doi.org/10.1007/978-3-030-33795-7_5
 8. Artru R., Roux L., Ebrahimi T. Digital watermarking of video streams: review of the state-of-the-art. *ArXiv preprint*, 2019, arXiv:1908.02039v2. 33 p.
 9. Lysenko N., Labkov G. Applying of Kutter-Jordan-Bossen steganographic algorithm in video sequences. *2017 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus)*, 2017, pp. 695–696. doi:10.1109/EIConRus.2017.7910651
 10. Ganic E., Dexter S. D., Eskicioglu A. M. Embedding multiple watermarks in the DFT domain using low and high-frequency bands. *Proceedings of the SPIE: Security, Steganography, and Watermarking of Multimedia Contents*, 2005, 5681, pp. 175–184. doi.org/10.1117/12.594697
 11. Briassouli A., Tsakalides P., Stouraitis A. Hidden messages in heavy-tails: DCT-domain watermark detection using alpha-stable models. *IEEE Trans on Multimedia*, 2005, vol. 7, no. 4, pp. 700–715. doi.org/10.1109/TMM.2005.850970
 12. Zheng X.-B., Zhang X.-W., Sun M.-J. A blind digital watermarking algorithm based on wavelet transform. *2011 IEEE International Conference on Computer Science and Automation Engineering*, 2011, pp. 679–682. doi:10.1109/CSAE.2011.5952937
 13. Favorskaya M., Savchina E., Popov A. Adaptive visible image watermarking based on Hadamard transform. *IOP Conference Series: Materials Science and Engineering*, 2018, vol. 450, no. 5, MIST Aerospace, pp. 052003.1–052003.6. doi:10.1088/1757-899X/450/5/052003
 14. Koch E., Zhao J. Towards robust and hidden image copyright labeling. *IEEE Workshop on Nonlinear Signal and Image Processing*, 1995, pp. 452–455.
 15. *X264 Settings*. http://www.chaneru.com/Roku/HLS/X264_Settings.htm (дата обращения: 15.01.2020).
 16. *x265 Documentation*. <https://x265.readthedocs.io/en/default/index.html> (дата обращения: 15.01.2020).
 17. Favorskaya M. N., Buryachenko V. V. *Detecting relevant regions for watermark embedding in video sequences based on deep learning*. In: *Intelligent Decision Technologies. IDT 2020. Smart Innovation, System and Technologies*. Czarnowski I., Howlett R., Jain L. (eds). Springer, Singapore, 2020. Vol. 193. Pp. 129–139. doi:10.1007/978-981-15-5925-9_11
 18. *Broadcasting service (television)*. <https://www.itu.int/rec/R-REC-BT/en> (дата обращения: 15.01.2020).
 19. ГОСТ ISO/IEC 15417-2013. Информационные технологии (ИТ). Технологии автоматической идентификации и сбора данных. Спецификация символика штрихового кода Code 128. М., Стандартинформ, 2014. 31 с.
 20. Li M., Liang T., He Y. Arnold transform based image scrambling method. *Proceedings of 3rd International Conference on Multimedia Technology (ICMT-13)*, 2013, pp. 1309–1316. doi:10.2991/icmt-13.2013.160

UDC 004.932

doi:10.31799/1684-8853-2020-5-12-23

Application of bar coding for digital watermarking of video sequences based on frequency transformsA. G. Zotin^a, PhD, Tech., Associate Professor, orcid.org/0000-0001-9954-9826M. N. Favorskaya^a, Dr. Sc., Tech., Professor, orcid.org/0000-0002-2181-0454, favorskaya@sibsau.ru^aReshetnev Siberian State University of Science and Technology, 31, Krasnoyarsky Rabochy Av., 660037 Krasnoyarsk, Russian Federation

Introduction: Owners of multimedia products face an important problem of protecting their digital data. An effective way to solve it is digital watermarking of video sequences. The challenge is the need to improve the digital watermark tolerance for transcoding when the data are transmitted via unprotected channels. **Purpose:** Development of method for embedding data into a video sequence which would have a higher tolerance for transcoding. **Methods:** We propose a novel method for embedding and extracting textual digital watermarks based on the bar coding and Arnold transform. **Results:** Blind marking schemes have been developed for digital video sequences in chromatic components, based on the discrete wavelet transform and discrete cosine transform. An experimental study has been conducted to check the stability of the proposed method using encoders x264 (AVC/H.264) and x265 (HEVC/H.265). The estimation of transcoding impact has shown that the frequency method based on wavelet decomposition has a high degree of stability. It was discovered during the experiments that for the cases of video transcoding by single-pass compression with a Constant Rate Factor

not exceeding 26, the embedded textual information is fully restorable. **Practical relevance:** The developed method allows you to reliably embed or extract textual data from video sequences compressed using highly efficient coding methods during their transmission via unprotected channels, providing copyright protection for multimedia product owners.

Keywords — digital watermark, digital marking of video sequences, bar coding, Arnold transform, discrete wavelet transform, discrete cosine transform.

For citation: Zotin A. G., Favorskaya M. N. Application of bar coding for digital watermarking of video sequences based on frequency transforms. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 12–23 (In Russian). doi:10.31799/1684-8853-2020-5-12-23

References

1. Wang X., Reeves D. S., Ning P., Feng F. Robust network-based attack attribution through probabilistic watermarking of packet flows. *Technical Report TR-2005-10*, 2005, Department of Computer Science, NC State Univ., 15 p.
2. Wolf P., Hauer E., Steinebach M. The video watermarking container: efficient real-time transaction watermarking. *Proc. SPIE 6819, Security, Forensics, Steganography, and Watermarking of Multimedia Contents X*, 2008, pp. 68190K.1–68190K.10. doi:10.1117/12.766544
3. Liu Y., Zhou P. A survey of video watermarking based on motion vector. *2014 International Conference on Computer, Communications and Information Technology (CCIT 2014)*, 2014, pp. 1951–6851. doi:10.2991/ccit-14.2014.71
4. Wang P., Zhang Z., Ying J. A novel video watermark technique in motion vectors. *2008 International Conference on Audio, Language and Image Processing*, 2008, pp. 1555–1559. doi:10.1109/ICALIP.2008.4590271
5. Stutz T., Uhl A. A survey of H.264 AVC/SVC encryption. *IEEE Transactions on Circuits and Systems for Video Technology*, 2012, vol. 22, no. 3, pp. 325–339. doi:10.1109/TCSVT.2011.2162290
6. Ogawa K., Ohtake G. Watermarking for HEVC/H.265 stream. *2015 IEEE International Conference on Consumer Electronics (ICCE)*, 2015, pp. 102–103. doi:10.1109/ICCE.2015.7066337
7. Favorskaya M. N., Buryachenko V. V. *Authentication and copyright protection of videos under transmitting specifications*. In: *Computer Vision in Advanced Control Systems-5*. ISRL. Favorskaya M. N., Jain L. C. (eds). Springer, Cham, 2020. Vol. 175. Pp. 119–160. doi.org/10.1007/978-3-030-33795-7_5
8. Artru R., Roux L., Ebrahimi T. Digital watermarking of video streams: review of the state-of-the-art. *ArXiv preprint*, 2019, arXiv:1908.02039v2. 33 p.
9. Lysenko N., Labkov G. Applying of Kutter-Jordan-Bossen steganographic algorithm in video sequences. *2017 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus)*, 2017, pp. 695–696. doi:10.1109/EIConRus.2017.7910651
10. Ganic E., Dexter S. D., Eskicioglu A. M. Embedding multiple watermarks in the DFT domain using low- and high-frequency bands. *Proceedings of the SPIE: Security, Steganography, and Watermarking of Multimedia Contents*, 2005, 5681, pp. 175–184. doi.org/10.1117/12.594697
11. Briassouli A., Tsakalides P., Stouraitis A. Hidden messages in heavy-tails: DCT-domain watermark detection using alpha-stable models. *IEEE Trans on Multimedia*, 2005, vol. 7, no. 4, pp. 700–715. doi.org/10.1109/TMM.2005.850970
12. Zheng X.-B., Zhang X.-W., Sun M.-J. A blind digital watermarking algorithm based on wavelet transform. *2011 IEEE International Conference on Computer Science and Automation Engineering*, 2011, pp. 679–682. doi:10.1109/CSAE.2011.5952937
13. Favorskaya M., Savchina E., Popov A. Adaptive visible image watermarking based on Hadamard transform. *IOP Conference Series: Materials Science and Engineering*, 2018, vol. 450, no. 5, MIST Aerospace, pp. 052003.1–052003.6. doi:10.1088/1757-899X/450/5/052003
14. Koch E., Zhao J. Towards robust and hidden image copyright labeling. *IEEE Workshop on Nonlinear Signal and Image Processing*, 1995, pp. 452–455.
15. *X264 Settings*. Available at: http://www.chaneru.com/Roku/HLS/X264_Settings.htm (accessed 15 January 2020).
16. *x265 Documentation*. Available at: <https://x265.readthedocs.io/en/default/index.html> (accessed 15 January 2020).
17. Favorskaya M. N., Buryachenko V. V. *Detecting relevant regions for watermark embedding in video sequences based on deep learning*. In: *Intelligent Decision Technologies. IDT 2020. Smart Innovation, System and Technologies*. Czarnowski L., Howlett R., Jain L. (eds). Springer, Singapore, 2020. Vol. 193. Pp. 129–139. doi:10.1007/978-981-15-5925-9_11
18. *Broadcasting service (television)*. Available at: <https://www.itu.int/rec/R-REC-BT/en> (accessed 25 January 2020).
19. State Standard ISO/IEC 15417-2013. Information technology. Automatic identification and data capture techniques. Code 128 bar code symbology specification. Moscow, Standartinform Publ., 2014. 31 p. (In Russian).
20. Li M., Liang T., He Y. Arnold transform based image scrambling method. *Proceedings of 3rd International Conference on Multimedia Technology (ICMT-13)*, 2013, pp. 1309–1316. doi:10.2991/icmt-13.2013.160

UDC 004.896

doi:10.31799/1684-8853-2020-5-24-32

Controlling system based on neural networks with reinforcement learning for robotic manipulator

E. B. Solovyeva^a, Dr. Sc., Tech., Associate Professor, orcid.org/0000-0001-8204-6632, selenab@hotbox.ru

A. Abdullah^a, Post-Graduate Student, orcid.org/0000-0002-4024-9201

^aSaint-Petersburg Electrotechnical University «LETI», 5, Prof. Popov St., 197376, Saint-Petersburg, Russian Federation

Introduction: Due to its advantages, such as high flexibility and the ability to move heavy pieces with high torques and forces, the robotic arm, also named manipulator robot, is the most used industrial robot. **Purpose:** We improve the controlling quality of a manipulator robot with seven degrees of freedom in the V-REP program's environment using the reinforcement learning method based on deep neural networks. **Methods:** Estimate the action signal's policy by building a numerical algorithm using deep neural networks. The action-network sends the action's signal to the robotic manipulator, and the critic-network performs a numerical function approximation to calculate the value function (Q-value). **Results:** We create a model of the robot and the environment using the reinforcement-learning library in MATLAB and connecting the output signals (the action's signal) to a simulated robot in V-REP program. Train the robot to reach an object in its workspace after interacting with the environment and calculating the reward of such interaction. The model of the observations was done using three vision sensors. Based on the proposed deep learning method, a model of an agent representing the robotic manipulator was built using four layers neural network for the actor with four layers neural network for the critic. The agent's model representing the robotic manipulator was trained for several hours until the robot started to reach the object in its workspace in an acceptable way. The main advantage over supervised learning control is allowing our robot to perform actions and train at the same moment, giving the robot the ability to reach an object in its workspace in a continuous space action. **Practical relevance:** The results obtained are used to control the behavior of the movement of the manipulator without the need to construct kinematic models, which reduce the mathematical complexity of the calculation and provide a universal solution.

Keywords – kinematic control, reinforcement learning, deep learning, robotic manipulator, deep neural network, deep deterministic policy gradient.

For citation: Solovyeva E. B., Abdullah A. Controlling system based on neural networks with reinforcement learning for robotic manipulator. *Informatsionno-upravliayushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 24–32. doi:10.31799/1684-8853-2020-5-24-32

Introduction

The use of deep neural networks has been rising lately in solving many different technical problems in many fields, especially in robotics and automation control, where the aim is to build intelligent systems that can operate without the need of human experts. The progress of unsupervised deep learning has continued to rise in rank, aiming to learn intelligent behavior in complex and dynamic environments [1, 2]. Therefore, we will review the methods of controlling a robotic manipulator using kinematic control and machine learning control in the field of reinforcement learning and examine the problems that can face us in this procedure. Learning control policies in different systems' operations have made reinforcement learning an optimal solution where it fits well with various tasks. In addition, recent work in this field has progressed towards capturing the state of the environment through images, something developers are still trying to achieve but in a different context.

Reducing continuous spaces of action would be poorly scaled, as the number of discrete actions increases exponentially with the action dimensional-

ity, so deep reinforcement learning operates with continuous spaces of action to be convenient with real-world control problems. Furthermore, having a parameterized policy can be beneficial, since it can generalize in the space of action [3].

Reinforcement learning is one of the most popular areas of machine learning [4–6]. Stimulated by human behavior, it allows an agent (the learner and decision-maker) to discover optimal performance by experiment and failure interactions with its enclosing environment to solve the problems of control. The environment is everything outside of the agent that can be associated with, while a learning task is the complete specification of the environment. The first method in the field of reinforcement learning is dynamic programming [6]. Dynamic programming uses value functions to structure the search for good policies but needs a perfect environment model. The need to know the complete model of the environment limits the dynamic programming method, wherein many control problems, knowing the whole aspects of the environment, could be impractical because many problems give rise to huge state sets. The next method is Monte Carlo (MC) one [6]. The model-free MC method enables us to learn from the

environment's sample sequences of states, actions, and rewards. MC method works by equating the sample returns from the environment on an episode by episode base, so we do not require the full model of the environment like in the case of dynamic programming, but in MC method the agent must consider the exploration-exploitation tradeoff in order to get information about the rewards and the environment. It needs to explore by analyzing both previously unused actions and uncertain actions that could lead to negative rewards. A new method of reinforcement learning evolves from both dynamic programming, and MC method. This method is called temporal-difference (TD) learning [6]. TD learning combines dynamic programming's ability to learn through bootstrapping and Monte Carlo's ability to learn directly from examples selected from the environment without access to the Markov decision process. Alternatively, TD method only waits until the next time-step by using temporary errors to notify us how different the new value is from the old prediction. Temporal difference learning led us to a method called state-action-reward-state-action (SARSA) [4–6]. SARSA is an on-policy TD control algorithm. This name is derived from an experience in which the agent starts in certain state performs an action, receives a reward, then transfers to a new state, and decides to do a new action. Based on SARSA, Q -learning method appeared but conversely to SARSA. Q -learning is an off-policy TD control algorithm, which directly approximates the expected reward independent of the policy being followed [4–6].

The main disadvantage of all of the above-mentioned methods is the need for a vast database of samples and their need to train them before we start to perform the process of control. On the other hand, we need an algorithm that can be suitable for continuous spaces, where the algorithm can learn and perform simultaneously with sensor reading and action executions. Deep deterministic policy gradient or deep Q -learning was developed to solve this problem and to overcome all the mentioned methods' disadvantages by developing the architecture of the agent to consist of a critic deep neural network and an actor deep neural network. The critic and the actor can work in parallel to give us the actions and the estimated rewards for these actions while the training process continues.

Hence, we study deep reinforcement learning algorithm, namely, deep deterministic policy gradient [3]. In order for robots to achieve a common advantage purpose, reaching objects is a fundamental ability to learn. Traditionally, human experts are required to analytically produce an algorithm for a particular task under adaptive control using kinematic control and supervised learning control, but this is a challenging and time-consuming ap-

proach. By applying deep learning, we overcome these restrictions in generalizing robotic control and demonstrating how building the actor-network and the critic-network based on convolution neural networks (CNN) increases the quality of the performance compared with fully connected neural networks. We begin by showing the area of interest, machine learning, focusing on deep learning and reinforcement learning, and deep deterministic policy gradient; we describe how to control a robotic arm using deep learning.

Kinematics control of a robotic manipulator

Given the joint rotation angles and the lengths of the manipulator's frames, we represent the forward kinematics [3]

$$\mathbf{X} = F(\mathbf{q}, \boldsymbol{\theta}_{kin}), \quad (1)$$

where \mathbf{X} is the coordinates vector containing the position and orientation of the robot's end effector; \mathbf{q} is a matrix of joints' angles; $\boldsymbol{\theta}_{kin}$ is a vector of fixed kinematic linking parameters. It consists of parameters describing the robotic manipulator lengths and angles, illustrating each joint axis's rotation relative to the previous joint axis.

Closed-form solutions of (1) are favored. However, there are manipulator structures, for which only iterative numerical solutions are possible. From equation (1) we get the equation of the inverse kinematics given as

$$\mathbf{q} = F^{-1}(\mathbf{X}, \mathbf{C}, \boldsymbol{\theta}_{kin}), \quad (2)$$

where \mathbf{C} is a vector containing some information used to select a possible solution, and another alternative is to let \mathbf{C} be the previous solution and choose the new solution as the closest solution.

When the robot's end effector is in a fixed position, there will always be existing values for the joints angles which led the end effector to be in such position and direction, so a closed-form solution for the forward kinematics problem is always assured in comparing with the inverse kinematic making it more comfortable to deal. This solution defines the workspace of a manipulator. On the other hand, there can even exist an infinite number of solutions, like the case of a redundant manipulator [3].

When the dimension of the task-space is smaller than the dimension of the joint space, the kinematic structure is considered redundant. Here the interest is in the inverse problem because we can calculate the angles of the joints that will lead to reaching a point in their workspace. As we can see, the kinematic control needs to know the robot's parameters and environment, which makes it a non-uni-

versal solution for the controlling problem. Each robot needs to rebuild the complete mathematical model and recalculate all the inverse and forward kinematics metrics, which will take a lot of processing each time. The solution for finding a universal solution for the controlling process is by using unsupervised learning.

Advantages of reinforcement learning in controlling a robotic manipulator

In unsupervised learning, we get a lower complexity compared to supervised learning because we are not expected to understand and then mark the input data. This situation happens in real-time so that all the input data must be analyzed and marked, which helps us understand the various training models and sorting of raw data [4–6]. It is easier for us to get unmarked data from a computer than marked data because marked data demands human interface and understanding of the categorization of such data to use in the learning process. Experts should estimate the target output or part of it in order to achieve the learning process. The supervised learning makes this way time-consuming and not flexible for various systems where some changes to the environment or the robot could happen. Nevertheless, there are many systems where we can not estimate the output, and we can not have enough information to build the target output to achieve the learning process.

In supervised learning, we would have a set of coordination of some locations in the workspace and the corresponding angles of the manipulator's joints. We can then feed those input frames through a neural network that, at the output, can produce the angles of the motors or joints by training on the data set from the previous data of the locations and the corresponding angles. Many approaches could be used, like backpropagation, so we can train that neural network to replicate human manual control actions. However, when we want to do supervised learning, we have to create a data set to train [6–8]. On which is not always a straightforward thing to do, and on the other hand, if we train our neural network model to imitate the actions of the human control well only, then by definition, our agent can never be better at executing the right action. When we want to train a neural network to perform by itself a controlling process on a robotics manipulator, where this controlling will take place in different environments, it could face many new problems. On the other hand, the offered method of unsupervised learning achieves this goal [9, 10].

However, the only difference here is that now we do not know the target label. Therefore, we do not know the rotation of the manipulator's joints in any

situation because we do not have a data set to train on, and in reinforcement learning, the network that transforms input frames to output actions is called the policy network [11]. The approach in policy gradients is that we start with a completely random network, we feed that network the coordinates from the environment, and it produces random action. Send that action back to the joints motors and then produces the next frame and this is how the loop continues and the network, in this case, it could be fully connected networks, but we can apply convolution network, in other words, deep neural networks and from this, we get the name "Deep learning". Allowing our agent to randomly explore the environment and discover better rewards and better behavior [12].

Within the task, the learning process is divided into episodes. We usually use each episode as a control for a finite steps model, where it is essential to operate in many steps until we reach the time where we reset and restart.

When we move from a step to another under making an action, the agent receives a reward describing the effectiveness of this step regarding the task. The objective here is to maximize this collective reward during the learning process for the robot [13]. The equation of the collective reward R is given as

$$R = r_1 + r_2 + r_3 + \dots + r_{K+1} = \sum_{k=0}^K r_{k+1}, \quad (3)$$

where r_1 is a reward for moving from the state 0 to the state 1 in the step 1; r_2 is a reward for moving from the state 1 to the state 2 in the step 2; $(K + 1)$ is the number of rewards or steps, which refers to the end of the episode; k is a counter for the sum sign; $(k + 1)$ is a step number.

As we can see from equation (3), the collective reward could increase without any conversion, making it not suitable for all the tasks [14, 15]. Therefore, we define a factor $0 \leq \gamma \leq 1$ that assures the conversion and determines the value of the future rewards that the robot might receive. By adding this discount factor to equation (3) we get the expected collective reward as

$$R = r_1 + \gamma r_2 + \gamma^2 r_3 + \dots + \gamma^K r_{K+1} = \sum_{k=0}^K \gamma^k r_{k+1}, \quad (4)$$

where γ is the discount factor.

We must take extreme caution when choosing an appropriate value of γ in equation (4) because it can often change the form of the optimal solution where different values lead to different performances [16]. If γ is small, the agent could select cases that only increase the reward and lead to lower performance in the long-term. In contrast, if γ is big, the

agent will lose the capacity to differentiate between the policies that will get a reward in the future and those directly get a big reward [17, 18].

Controlling a robotic manipulator using deep learning

Deep learning is a field of reinforcement unsupervised learning involved with deep neural networks. We used two types of deep neural networks each time, the convolution neural network and the fully connected neural network. In convolution neural networks, the connections are between the neuron and its surrounding neurons from the previous layer, and these connections share the same weights and bias [19–21].

Let's consider the method of deep deterministic policy gradient with using deep neural networks as an actor and critic. Set up the following notations and variables: $\pi(\mathbf{s}_j|\xi)$ is the actor-network output calculated on the basis of the actor neural network having the input vector \mathbf{s}_j and the parameters vector ξ ; j is the current step; \mathbf{s}_j is the state vector built by the observation in step j ; ξ is the parameters vector of the actor-network; $Q(\mathbf{s}_{j+1}, \pi(\mathbf{s}_{j+1}|\xi)|\theta)$ is the output of the critic network having the input vector \mathbf{s}_{j+1} , which is obtained from state \mathbf{s}_j after action \mathbf{a}_j of the actor-network, and the parameters vector θ . On the basis of the TD learning, the updated parameters vector θ of the critic-network results from solving the optimization problem [6, 9]

$$L = \frac{1}{M} \sum_{j=1}^M (\mathbf{y}_j - Q(\mathbf{s}_j, \mathbf{a}_j | \theta))^2 \rightarrow \min_{\theta} \quad (5)$$

where L is the loss function; M is the maximum count in the last step; \mathbf{y}_j is the value function target, output vector of deep neural network, which gives the critic signal or the joint angles; \mathbf{a}_j is the action vector in the given state \mathbf{s}_j . This output vector, similar to the solution of the inverse kinematics equation (2), is described as

$$\mathbf{y}_j = r_j + \gamma Q(\mathbf{s}_{j+1}, \pi(\mathbf{s}_{j+1} | \xi) | \theta), \quad (6)$$

where r_j is the reward in step j ; j is the current step.

We train the network to decrease the mean squared error concerning the Q function [22, 23]. However, the dependence of the Q targets on Q itself can lead to instabilities or even divergence during learning. We consider a policy that can be described by parameters very beneficial for control because it allows for learning when the sensory reading and actions executions belong to continuous spaces. The target value function \mathbf{y}_j in (6) is proposed to be a permanent value on learning a neural network by the back-propagation algorithm.

After updating the parameters vector θ of the critic-network, to update the parameters vector ξ of the actor-network we use the following policy gradient when maximizing the expected discounted reward (4) [6, 9]:

$$\nabla_{\xi} J \approx \frac{1}{M} \sum_{j=1}^M \mathbf{G}_{\pi j} \mathbf{G}_{\xi j}, \quad (7)$$

$$\mathbf{G}_{\pi j} = \nabla_{\pi} Q(\mathbf{s}_j, \pi(\mathbf{s}_j | \xi) | \theta),$$

$$\mathbf{G}_{\xi j} = \nabla_{\xi} \pi(\mathbf{s}_j | \xi),$$

where $\nabla_{\xi} J$ is the policy gradient; $\mathbf{G}_{\pi j}$, $\mathbf{G}_{\xi j}$ are the gradient vectors of the critic's and actor's outputs with respect to an actions and parameters of the actor-network respectively; ∇_{π} is the gradient ascent with respect to the policy of the action; ∇_{ξ} is the gradient ascent with respect to the parameters vector ξ of the actor-network.

From equation (7), the resulting policy gradient increases the expected discount reward, and we use it to update the actor-network weights and bias. On the other hand, from equation (5), after minimizing the loss function over all the experiences, we use it to update the critic-network weights and biases. In consideration of the observation, we evaluate the gradient of the critic-network output and the gradient of the output of the actor-network. We perform a smoothing process to update the weights and the biases of the target actor-network and the critic-network:

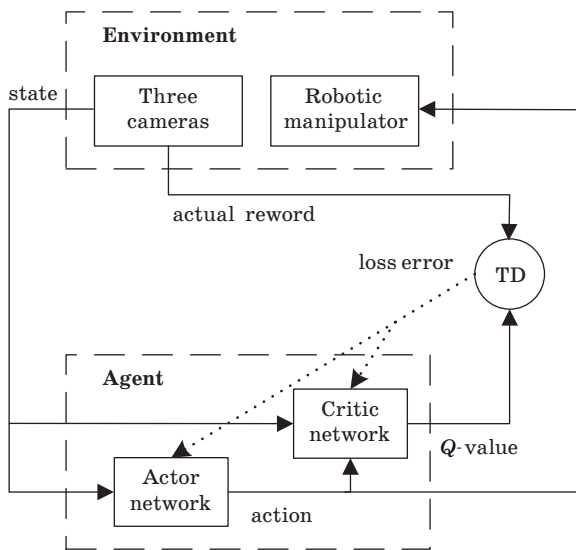
$$\bar{\theta} = \tau \theta + (1 - \tau) \bar{\theta}, \quad \bar{\xi} = \tau \xi + (1 - \tau) \bar{\xi},$$

where τ is a smoothing factor equal to less than one; $\bar{\theta}$, $\bar{\xi}$ are the updated parameters vectors of the critic and actor networks correspondently.

Finally, we repeat performing equation (6) after we get the new observation for a new step in the training until the end of the episode and the beginning of new training episode.

The practical experiment of controlling the robot manipulator

As illustrated in Fig. 1, the learning process starts with taking the coordinates of the end effector and the cube on the three-axis from the cameras, generating the state vector. We send the state vector to the actor-network. The critic network takes both the action generated by the actor-network and the state and gives us the expected reward from this action or the Q -value. In the next steps to improve the performance, when we are in a state, and the actor is proposing a particular action, we take a slightly different action and see if the Q -value a lit-



■ Fig. 1. The block-scheme of the deep deterministic policy gradient used to control the robotic manipulator

the higher we change the action to the new proposed action. The robotic manipulator moves when it gets the action signal. The cameras make the observations, generating a new state vector describing the new situation of the environment. On each axis, if the distance between the end effector and the cube gets smaller than before, we add a positive reward.


On the contrary, if the distance gets bigger, then before we add a negative reward. We sum the rewards to get the actual reward of the current action. We calculate the loss by achieving a TD between the actual reward and the estimated reward generated by the critic (the Q -value). We use the loss in computing the gradient of the Q -value with respect to the action. We back propagate the gradient of the Q -value with respect to the action to train and update the neural networks and to evolve our actor in the right direction.

The simulation environment is built using V-REP program. A robot arm model with seven degrees of freedom (7 DoF manipulator) is used. In addition, three cameras are added in different places to use them in determining the state and the value of the reward function. A linkage library called Remote API is used to connect V-REP program with MATLAB language. This library provides a way to create a connection between the programming language and the simulation program, so it becomes possible to take pictures from the cameras and process them using MATLAB image processing functions. The connection mechanism also allows sending motion commands to the motors on the robot joints, which makes the simulation environment so close to the real implementation environment.

We want to enable our agent to learn entirely by itself. The only feedback that was going to give it

is the distance between its end effector and the object we want the manipulator to reach. Whenever our agent manages to make this distance smaller, it will receive a positive reward. If the gap gets bigger than before, then our agent will receive a penalty of negative reward. The target of the agent is to optimize its policy to earn as much reward as possible. To train our policy network, we will collect a bunch of experiences by selecting random actions to feed them back into the actor and create a whole bunch of random movements in the environment. Since our agent has not learned anything useful yet, it is going to make arbitrary, not accurate movements. Sometimes our agent might get lucky while it is going to random select of action. In this case, when a sequence minimizes the distance, our agent will receive a reward. We should note that every episode, regardless of whether we want a positive or a negative reward, we can compute the gradients that would make the actions that our agent has chosen more likely in the future. Therefore, what policy gradients are going to do is that for every episode where we have a positive reward, we will use the normal gradients to increase the probability of those actions in the future. Whenever we got a negative one, it is going to apply the same gradient, but we are going to multiply it with minus one, and this minus sign will make sure that in the future, all the actions that we took in a bad episode are going to be less likely. The result is that while training our policy network, the actions that lead to negative rewards are slowly going to be reduced, and the actions that lead to positive rewards will increase.

To make observations of the state for the agent of the reinforcement learning (the robotic manipulator), we have used three web cameras that take photos of the manipulator workspace from three perspectives so we can analyse a 3D vision for the environment on the three axes. Because of the limitation of the hardware, we do not have the ability to give the images as input to the neural networks, so we performed image processing using MATLAB to get the coordinates of both the robot and the end effector. We added as well the angles of rotation for each joint to form the state vector (the observations). Thus, using simulated webcams with 128×128 resolution, the environment was observed. Before each action, a picture is taken from each cam. Then using image processing methods of segmentation and detection in MATLAB system, we get the coordinates of the end effector and the object we want to reach to form our state. The original photos from three vision sensors in the environment of V-REP with a resolution of 128×128 showing the robotic arm as a whole and the box we want to reach are depicted in Fig. 2, a. The images obtained after the photos processing in MATLAB and showing two green pints,



■ **Fig. 2.** The original photos from three vision sensors in the environment of V-REP with a resolution of 128×128 to simulate real life web cameras (a) and the images obtained after the photos processing (b)

which are the end effector of the robot and the box, we aim to reach, are depicted in Fig. 2, b.

Let us consider the simulation environment. The robotic manipulator has seven motors; each motor is related to two adjacent digits, respectively. The motor rotates in a clockwise direction if the first digit is bigger than the second one and vice versa. Thus, the number of the action signal parameters is 14. After that, we start taking pictures from the cameras and discovering the green areas in them, because the end effector and the element we want to reach are made in green. Then, we determine the coordinates of these two elements in the three images, as seen in Fig. 2, b. The state contains seven values that reflect the motors' angles, and 12 values reflect a pair of coordinates in each of the three images. The total number of the state signal parameters is 19.

Two kinds of neural networks are chosen to build the actor and the critic networks. In the first case, the actor and critic networks are designed as CNN and, in the second case, as the fully connected neural networks. The actor-network includes four layers and has a size of $200 \times 200 \times 38 \times 14$, where every number means the number of neurons in a layer. The actor-network has 14 output signals to give the rotation of the joints with two pairs for each of

the seven joints. The critic-network comprises four layers and has a size of $200 \times 200 \times 10 \times 1$. The output signal is a value of the Q -function.

The training process of the robot consists of a maximum number of 600 episodes when using convolution neural networks and 1000 when using the fully connected networks, where the episode is all the actions, and the states that come in between an initial-state and a terminal-state and each taken action and state is considered to be one step inside the episode. The episode consists of a maximum number of 600 steps when using the convolution neural networks and 1000 when using the fully connected networks. Each episode ends when the robot achieves the task of reaching the cube or when it reaches its maximum number of steps without being able to reach the cube. After that, a new episode begins with a new initial position for the cube in the workspace of the robot. As a start of the training process during the first step in the first episode, the state vector is constructed by taking the coordinates of the end effector of the robot and the cube (the object we aim to reach) from three images in the initial observations. We send the state vector to the actor-network as its input. The actor-network generates the first action as an output, and we send it to the motors' joints to perform the first movement.

We take the new observations constructing the new state vector, and we send it to the critic-network with the action vector. The critic-network takes the state vector, and the action vector as an input and generates the Q -value as output. At the end of this step, the reward of the taken action is demonstrated by calculating the distance in the three images. Depending on the Q -value and the reward, we update the parameters of the actor-network and the critic-network entering the next step. In the next step, the actor-network gives the new action signal for the joint's motor to rotate depending on the current state vector, and the new observations are taken constructing the new state vector. The new state vector is sent with the action vector to the critic-network repeating the same process. If the taken action in the step leads the robot to move far from the cube, the reward takes a negative value in order to reduce the repetition of such actions, and if the action in the current step reduces the distance moving the robot towards the cube, the rewards take a positive value to ensure repeating such actions. The task is considered to be accomplished when the distance is reduced to a certain level (very small distance) in the three images at the same time. The episode ends, and we give the reward a big positive value, and the robot returns to its initial position, a new position is determined randomly for the cube (the element we want to reach). A new episode starts, and a new action is taken from the output of the actor-network repeating the same process in the previous episodes. The training stops in the final episode, where the parameters of the actor-network always lead the robot to execute the actions, those making it reaching the cube.

In our experiment, we achieved two training process first using convolution neural networks to build the actor and critic networks. The results are represented in Table 1. Then, we repeat the training using the fully connected neural networks to build the actor and critic networks. The results are noted in Table 2.

In table 1 is clear that, the larger the network's size, the higher the learning parameters, the higher the average reward, which leads the robot to execute more likely good actions to reach the cube and to reaching high accuracy and lower elapsed time quickly.

As follows from the analysis of tables 1 and 2, the architecture of the convolution neural networks gives the character to be more specialized and efficient than the fully connected networks. In the architecture of the fully connected neural networks, there are connections between all the neurons in previous layers with each neuron in the next layer, with a unique weight to each connection. This connection pattern increases the network parameters and makes no assumptions about the data's

■ **Table 1.** The number of parameters, average reward and elapsed time on learning the actor and critic networks in the form of convolution neural networks

Sizes of actor and critic-networks	Number of parameters	Average reward	Elapsed time, h
$200 \times 200 \times 38 \times 14$ $200 \times 200 \times 10 \times 1$	3040 412	100.02	5.10
$190 \times 190 \times 38 \times 14$ $190 \times 190 \times 10 \times 1$	2890 392	99.23	5.24
$180 \times 180 \times 38 \times 14$ $180 \times 180 \times 10 \times 1$	2740 372	98.01	5.37

■ **Table 2.** The number of parameters, average reward and elapsed time on learning the actor and critic networks in the form of fully connected neural networks

Sizes of actor and critic-networks	Number of parameters	Average reward	Elapsed time, h
$200 \times 200 \times 38 \times 14$ $200 \times 200 \times 10 \times 1$	48 384 42 221	98.01	5.21
$190 \times 190 \times 38 \times 14$ $190 \times 190 \times 10 \times 1$	44 094 38 211	94.21	5.40
$180 \times 180 \times 38 \times 14$ $180 \times 180 \times 10 \times 1$	40 004 34 401	90.46	5.59

features, increasing the expenses of the memory and the computation. On the other hand, in the convolution neural network's architecture due to its convolutional layers, the connections are between the neuron and its surrounding neurons from the previous and the next layer, and these connections share the same weights. This connection pattern decreases the number of the network parameters affecting its memory use (less memory use), the computation (less time), and increases the accuracy by producing more likely actions that increase the average reward.

We trained the networks using back propagation of the loss error by taking the gradient of the Q -value with respect to the input. However, the training process time depends on many factors; for example, each neural network is initialized with random values of biases and weights, giving different starting points per simulation during the training process. Due to its architecture, fewer connections and weights make convolutional layers relatively cheap in memory and computation (less time). In other words, CNN has a lower number of parameters, making it quicker to achieve the training target.

Convolution neural networks have a connection pattern that increases its accuracy in comparison

with the fully connected network because this pattern provides the characteristic of feature extraction allowing the data to be represented as spatial with the locally and equally possible to occur extracted features at any input. This feature extraction quality produces a lower rate of decreasing the average reward when reducing the parameters of CNN over reducing the parameters of the fully connected networks, which lack this property of the feature extraction.

Conclusion

In robotic control, we trained the robotic arm, using a typical robot with seven joints to move in high action space, using deep reinforcement learning algorithms and deep deterministic policy gradients. These methods have the advantage of allowing our robot to perform actions and train at the same moment. Therefore, we used them to control our robotic manipulator to reach a cube in its workspace; since these methods give the robot the ability to perform in continuous space action (the sensory reading and actions executions belong to continuous spaces).

References

1. **Beysolow T. II** *Introduction to deep learning using R. A step-by-step guide to learning and implementing deep learning models using R*. Berkeley, Apress, 2017. 227 p. doi:10.1007/978-1-4842-2734-3
2. **Ketkar N.** *Deep learning with Python*. Berkeley, Apress, 2017. 226 p. doi:10.1007/978-1-4842-2766-4
3. **Polydoros A. S., Nalpantidis L., Kruger V.** Real-time deep learning of robotic manipulator inverse dynamics. *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Hamburg, Germany, September 28–October 2, 2015, pp. 3442–3448. doi:10.1109/iros.2015.7353857
4. **LeCunn Y., Bengio Y., Hinton G.** Deep learning. *Nature*, 2015, vol. 521, no. 5, pp. 436–444. doi:10.1038/nature14539
5. **El-Amir H., Hamdy M.** *Deep learning pipeline*. Berkeley, Apress, 2019. 551 p. doi:10.1007/978-1-4842-5349-6
6. **Lapan M.** *Deep reinforcement learning hands-on*. Birmingham, Packt Publishing, 2020. 800 p.
7. **Solovyeva E.** Behavioural nonlinear system models specified by various types of neural networks. *Journal of Physics: Conference Series*, 2018, vol. 1015, no. 3, 032139, pp. 1–6. doi:10.1088/1742-6596/1015/3/032139
8. **Solovyeva E.** Recurrent neural networks as approximators of nonlinear filters operators. *Journal of Physics: Conference Series*, 2018, vol. 1141, no. 1, 012115, pp. 1–10. doi:10.1088/1742-6596/1141/1/012115
9. **Brown B., Zai A.** *Deep reinforcement learning in action*. New York, Manning Publications Co., 2020. 360 p.
10. **Sejnowski T. J.** *The deep learning revolution*. Cambridge, The MIT press, 2018. 352 p. doi:10.7551/mitpress/11474.001.0001
11. **Angelova A., Carneiro G., Sünderhauf N., Leitne J.** Special issue on deep learning for robotic vision. *International Journal of Computer Vision*, 2020, vol. 128, pp. 1160–1161. doi:10.1007/s11263-020-01324-z
12. **Gupta A., Eppner C., Levine S., Abbeel P.** Learning dexterous manipulation for a soft robotic hand from human demonstrations. *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Daejeon, Korea, October 9–14, 2016, pp. 3786–3793. doi:10.1109/iros.2016.7759557
13. **Rajeswaran A., Kumar V., Gupta A., Vezzani G., Schulman J., Todorov E., Levine S.** Learning complex dexterous manipulation with deep reinforcement learning and demonstrations. *14th Robotics: Science and Systems XIV*, Pittsburg, USA, June 26–30, 2018, pp. 1–9. doi:10.15607/rss.2018.xiv.049
14. **Pervez A., Mao Y., Lee D.** Learning deep movement primitives using convolutional neural networks. *2017 IEEE-RAS 17th International Conference on Humanoid Robotics (Humanoids)*, Birmingham, UK, November 15–17, 2017, pp. 191–197. doi:10.1109/humanoids.2017.8246874

15. Widmaier F., Kappler D., Schaal S., Bohg J. Robot arm pose estimation by pixel-wise regression of joint angles. *2016 IEEE International Conference on Robotics and Automation (ICRA)*, Stockholm, Sweden, May 16–17, 2016, pp. 616–623. doi:10.1109/icra.2016.7487185
16. Shi J., Xu J., Yao Y., Xu B. Concept learning through deep reinforcement learning with memory-augmented neural networks. *Neural Networks*, 2019, vol. 110, pp. 47–54. doi:10.1016/j.neunet.2018.10.018
17. Rahmatizade R., Abolghasemi P., Boloni L., Levine S. Vision-based multi-task manipulation for inexpensive robots using end-to-end learning from demonstration. *2018 IEEE International Conference on Robotics and Automation (ICRA)*, Brisbane, Australia, May 21–25, 2018, pp. 3758–3765. doi:10.1109/icra.2018.8461076
18. Aref M. M., Mattila J. Deep learning of robotic manipulator structures by convolutional neural network. *2018 Ninth International Conference on Intelligent Control and Information Processing (ICICIP)*, Wanzhou, China, November 9–11, 2018, pp. 236–242. doi:10.1109/icicip.2018.8606719
19. Peiyuan Liao. Deep neural network based subspace learning of robotic manipulator workspace mapping. *2018 International Conference on Control, Artificial Intelligence, Robotics & Optimization (ICCAIRO)*, Athens, Greece, May 19–21, 2018, pp. 109–120. doi:10.1109/iccairo.2018.00027
20. Chien J.-T. *Source separation and machine learning*. Cambridge, London, Elsevier Inc., 2019. 384 p. doi:10.1016/C2015-0-02300-0
21. Solovyeva E. Cellular neural network as a non-linear filter of impulse noise. *2017 20th Conference of Open Innovations Association FRUCT (FRUCT20)*, Saint-Petersburg, Russia, April 3–7, 2017, pp. 420–426. doi:10.23919/FRUCT.2017.8071343
22. Xiang J., Li Q., Dong X., Ren Z. Continuous control with deep reinforcement learning for mobile robot navigation. *2019 Chinese Automation Congress (CAC)*, Hangzhou, China, November 22–24, 2019, pp. 1501–1506. doi:10.1109/cac48633.2019.8996652
23. Ravichandiran S. *Hands-on reinforcement learning with Python. Master reinforcement and deep reinforcement learning using OpenAI Gym and TensorFlow*. Birmingham, Packt Publishing, 2018. 320 p.

УДК 004.896

doi:10.31799/1684-8853-2020-5-24-32

Система управления на основе нейронных сетей при обучении с подкреплением для робота-манипулятораЕ. Б. Соловьева^а, доктор техн. наук, доцент, orcid.org/0000-0001-8204-6632, selenab@hotmail.ruА. Абдуллах^а, аспирант, orcid.org/0000-0002-4024-9201^аСанкт-Петербургский государственный электротехнический университет «ЛЭТИ», Профессора Попова ул., 5, Санкт-Петербург, 197376, РФ

Введение: в силу высокой гибкости и способности перемещать тяжелые предметы с большими вращающимися моментами и усилиями роботизированная рука, называемая роботом-манипулятором, является часто используемым промышленным роботом. **Цель:** повысить качество управления роботом-манипулятором с семью степенями свободы, представленным в среде симулятора V-REP, применяя метод обучения с подкреплением для глубоких нейронных сетей. **Методы:** оценка сигнала политики действия посредством построения численного алгоритма с использованием глубоких нейронных сетей. Сеть актора отправляет сигнал действия в роботизированный манипулятор, а сеть критика выполняет численную аппроксимацию для вычисления оценки функции (Q -оценки). **Результаты:** мы создаем модель робота и его окружающую среду, используя библиотеку обучения с подкреплением в MATLAB и направляя выходной сигнал (сигнал действия) к симулятору робота в программе V-REP. Робот обучается достижению объекта в рабочем пространстве при взаимодействии с окружающей средой и при расчете вознаграждения за это взаимодействие. Модель наблюдения создана с применением трех видеосенсоров. С помощью метода глубокого обучения модель агента, представляющего собой робот-манипулятор, построена на базе четырехслойных нейронных сетей актора и критика. Модель агента обучалась в течение нескольких часов до момента достижения роботом объекта в своем рабочем пространстве с приемлемой точностью. Основное преимущество предлагаемого управления над управлением с учителем заключается в том, что робот одновременно обучается и выполняет перемещение в непрерывном пространстве действий. **Практическая значимость:** полученные результаты применяются для управления движением робота-манипулятора без конструирования кинематических моделей, в результате уменьшается сложность расчетов и обеспечивается универсальность решения.

Ключевые слова — кинематическое управление, обучение с подкреплением, глубокое обучение, робот-манипулятор, глубокая нейронная сеть, глубокий детерминированный градиент политики.

Для цитирования: Solovyeva E. B., Abdullah A. Controlling system based on neural networks with reinforcement learning for robotic manipulator. *Информационно-управляющие системы*, 2020, № 5, с. 24–32. doi:10.31799/1684-8853-2020-5-24-32

For citation: Solovyeva E. B., Abdullah A. Controlling system based on neural networks with reinforcement learning for robotic manipulator. *Informatsionno-upravlyaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 24–32. doi:10.31799/1684-8853-2020-5-24-32

Нейросетевое прогнозирование событий для роботов с непрерывным обучением

В. Ю. Осипов^а, доктор техн. наук, профессор, orcid.org/0000-0001-5905-4415, osipov_vasilyi@mail.ru

Д. И. Милосердов^а, аспирант, orcid.org/0000-0002-5312-5531

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

Введение: большие надежды на существенное расширение возможностей человека в различных сферах деятельности возлагают на создание и применение высокоинтеллектуальных роботов. Для достижения такого уровня интеллектуальности необходимо успешно решать задачи прогнозирования внешней среды и состояний самих роботов. В качестве многообещающих нейросетевых систем прогнозирования выступают решения на основе рекуррентных нейронных сетей с управляемыми элементами. **Цель:** поиск новых методов и целесообразных нейросетевых структур для прогнозирования событий. Разработка подходов к управлению ассоциативным вызовом информации из памяти нейронных сетей. **Методы:** компьютерное моделирование рекуррентных нейронных сетей с управляемыми элементами с различными структурами слоев. **Результаты:** разработан усовершенствованный метод нейросетевого прогнозирования событий с непрерывным обучением роботов. Метод позволяет прогнозировать события как на длинных, так и на коротких выборках временных рядов. Для повышения точности прогнозирования предложены новые правила управления ассоциативным вызовом информации из нейросетевой памяти. Разработана программная система, реализующая предлагаемый метод и допускающая эмуляцию нейронных сетей с различными структурами слоев. На примере прогнозирования городских транспортных потоков проанализированы возможности рекуррентных нейронных сетей с линейными и спиральными структурами слоев. Выигрыш предложенного метода в сравнении с интегрированной моделью авторегрессии – скользящего среднего – по показателю MAPE составил от 4,1 до 7,4 %. Среди исследованных нейросетевых структур наибольшую точность показали спиральные структуры, наименьшую – линейные. **Практическая значимость:** результаты исследования позволяют повысить точность прогнозирования событий для интеллектуальных роботов.

Ключевые слова – нейронная сеть, прогнозирование событий, непрерывное обучение, робот.

Для цитирования: Осипов В. Ю., Милосердов Д. И. Нейросетевое прогнозирование событий для роботов с непрерывным обучением. *Информационно-управляющие системы*, 2020, № 5, с. 33–42. doi:10.31799/1684-8853-2020-5-33-42

For citation: Osipov V. Yu., Miloserdov D. I. Neural network event forecasting for robots with continuous training. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 33–42 (In Russian). doi:10.31799/1684-8853-2020-5-33-42

Введение

Большие надежды на существенное повышение эффективности деятельности человека в различных сферах возлагаются на создание и применение высокоинтеллектуальных роботов. Для достижения необходимого уровня интеллектуальности роботов требуется успешно решать задачи прогнозирования их состояний и внешней среды. Специфика этих задач такова, что состояние роботов и внешней среды определяется большим количеством внутренних и внешних постоянно изменяющихся факторов. Перспективные роботы в общем случае должны функционировать в условиях с высокой степенью неопределенности событий [1–4].

Для эффективного прогнозирования среды и внутренних состояний роботов в этих условиях необходимо наличие соответствующих методов. Эти методы на основе обработки временных рядов событий, несущих информацию о наблюдаемых процессах, должны выдавать в систему управления роботом точные и своевременные прогнозы.

В настоящее время для прогнозирования временных рядов в интересах как роботов, так и

других систем используют различные методы и инструменты [1, 5–6]. Широко применяют линейные и нелинейные регрессионные, а также другие модели [5]. К числу перспективных решений относятся методы, основанные на использовании искусственных нейронных сетей (НС). Все многообразие нейросетевых архитектур можно разделить на НС прямого распространения, рекуррентные нейронные сети (РНС) и гибридные решения.

Нейронные сети прямого распространения [7–13] благодаря простоте реализации и обучения нашли широкое применение при прогнозировании. Так, для прогнозирования дорожного трафика в работе [7] использована нейронная сеть с двумя скрытыми слоями. В [8] применены автокодировщики, а в [9] использованы медианные нейронные сети. Похожие исследования затрагивают проблему прогнозирования экономических временных рядов [10–13]. Тем не менее возможности НС прямого распространения существенно ограничены по точности и горизонту прогноза. В этих сетях при прогнозировании не учитываются обратные результаты. Такие сети не способны

без переобучения адаптироваться к меняющимся внутренним и внешним факторам, влияющим на динамику анализируемых временных рядов.

Рекуррентные нейронные сети [14–20] обладают меньшими недостатками. Обзор архитектур РНС применительно к задаче прогнозирования временных рядов приведен в работе [14]. Распространено применение нейросетевых структур с долгой краткосрочной памятью [15–17] и с управляемыми рекуррентными нейронами [21]. Для прогнозирования применяются многослойная ограниченная машина Больцмана [18], сети Эльмана [19], ряд других архитектур [20]. Возможности РНС значительно выше, чем у НС прямого распространения. Однако системы прогнозирования на основе РНС во многом не проработаны. Для них характерны невысокая устойчивость, необходимость прерывания на переобучение для прогнозирования временных рядов с изменяющимися законами поведения, трудности при ассоциативном вызове ранее запомненной информации [14–21].

Появление гибридных нейросетевых решений вызвано желанием преодолеть ограничения отдельных архитектур [22–25]. В работе [22] предложен подход, основанный на комбинировании долгой краткосрочной памяти и сверточных нейронных сетей. В [23] используются глубокие сети доверия. Гибрид нейронных сетей состояний «эхо» и квантовых сетей предложен в [24]. В [25] рассмотрен подход, основанный на объединении НС прямого распространения и нечетких систем. Объединение нескольких типов НС в единую систему позволяет немного расширить возможности систем прогнозирования, но это не устраняет принципиальных недостатков, характерных НС прямого распространения и РНС. Кроме этого, усложняется общая архитектура.

В качестве многообещающих нейросетевых систем прогнозирования выступают решения на основе РНС с управляемыми элементами [26–32]. Полученные результаты применения этих систем в условиях динамичной обстановки и несовершенства выборки временных рядов свидетельствуют, что по точности и горизонту прогнозирования они превосходят известные подходы [32]. Используемые в этих системах прогнозирования РНС с управляемыми элементами [31, 32] обладают расширенными возможностями ассоциативного связывания и запоминания обрабатываемых сигналов, а также извлечения их из памяти. Их возможности во многом зависят от видов логических структур слоев РНС, реализуемых правил управления ассоциативной памятью, способов применения самих сетей. В настоящее время нет однозначного ответа на вопрос, какие структуры слоев РНС с управляемыми элементами предпочтительно использовать в интересах решения задач прогнозирования временных рядов.

Кроме этого, во многом не исследованы подходы к управлению ассоциативным вызовом информации из памяти этих сетей. Остаются открытыми вопросы поиска целесообразных методов применения этих РНС.

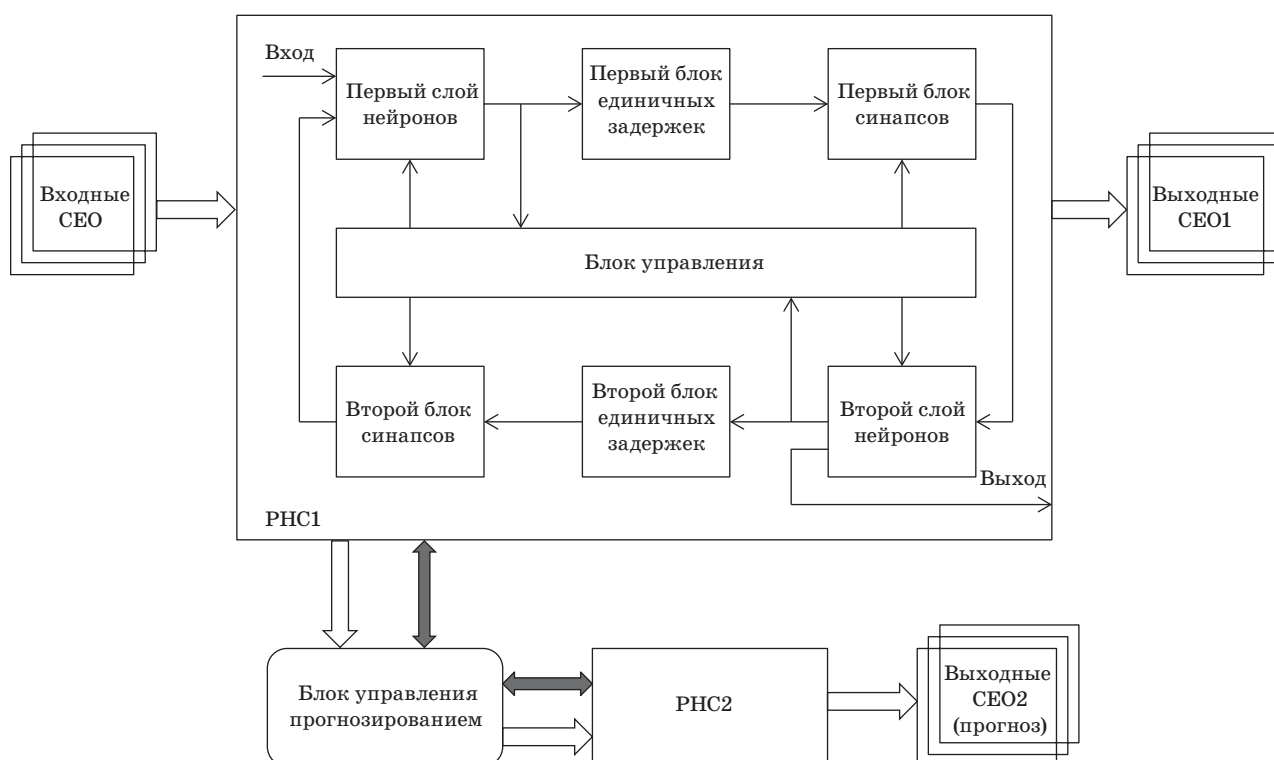
В настоящей статье уточняется предложенный в работе [32] метод прогнозирования временных рядов с использованием РНС с управляемыми элементами, который позволяет получать прогнозы с непрерывным обучением этих сетей. Раскрывается архитектура реализующей его программной системы. Оцениваются возможности прогнозирования временных рядов этим методом с применением РНС с различными структурами слоев. Даются рекомендации по применению предлагаемого метода в перспективных интеллектуальных системах.

Метод нейросетевого прогнозирования

Поясним усовершенствованный метод нейросетевого прогнозирования событий для роботов на примере реализующей его системы. В состав обобщенной блок-схемы этой системы (рис. 1) входят две идентичные двухслойные РНС с управляемыми элементами, а также блок управления прогнозированием. На вход РНС1 подаются сигналы, преобразованные в последовательности совокупностей единичных образов (СЕО). Поданные в РНС1 СЕО продвигаются вдоль слоев согласно заданной схеме [см. 28]. В качестве таких схем могут выступать линейные, спиральные, петлевые и др. Такое продвижение обеспечивается за счет пространственных сдвигов СЕО при передаче от одного слоя к другому [30]. При продвижении последовательностей СЕО в РНС1 они связываются. Результаты связывания запоминаются на элементах сети.

В процессе непрерывного обучения в РНС1 формируются постоянно обновляемые модели воспринимаемых сигналов. На правом выходе РНС1 можно получать результаты распознавания обработанных сетью последовательностей СЕО.

В интересах предсказания событий для роботов в системе на рис. 1 блоком управления прогнозированием считывается информация о состоянии элементов из РНС1 в РНС2. После надления РНС2 этой информацией запускается процесс обработки в ней сигналов и ускоренного вызова из ассоциативной памяти результатов прогноза в виде выходных СЕО2. Для повышения эффективности прогнозирования осуществляется усиление такого вызова в направлении входа РНС2 собственным блоком управления этой сети. Вызванные из ассоциативной памяти результаты прогнозирования следуют в РНС2 за обрабатываемыми СЕО. В случаях обработки



■ **Рис. 1.** Обобщенная схема системы, реализующей метод нейросетевого прогнозирования событий для роботов с непрерывным обучением

■ **Fig. 1.** A generalized scheme of a system that implements the method of neural network event prediction for robots with continuous training: SSP is a set of single pulses; RNN1, RNN2 are the first and the second identical recurrent neural networks

малых выборок в РНС2 предлагается сначала их удлинять за счет вызова из памяти предшествующих сигналов, а затем только осуществлять прогнозирование. Для этого предлагается сначала усиливать ассоциативный вызов сигналов из памяти РНС2 в направлении выхода, а затем в направлении входа. После того как результаты прогноза в виде последовательности будущих СЕО2 получены, может начинаться очередной цикл считывания с РНС1 информации о состоянии ее элементов в РНС2 и прогнозирование ею событий относительно очередного момента времени.

Пример логической схемы применяемой РНС со структурой слоев в виде сходящейся, а не постоянной по диаметру [29, 30] спирали, показан на рис. 2.

В рекуррентных нейронных сетях усиление ассоциативного вызова сигналов из памяти в требуемом направлении осуществляется за счет изменения параметров расходимости единичных образов соответствующих совокупностей при передаче от слоя к слою [26]. В соответствии с более ранними исследованиями [27] амплитуда единичного образа на выходе каждого синапса равна амплитуде входного единичного образа, умно-


женной на вес $w_{ij}(t)$ синапса. Веса $w_{ij}(t)$ синапсов определяются через произведение их весовых коэффициентов $k_{ij}(t)$ и функций ослабления $\beta(r_{ij}(t))$, $\eta(r_{ij}(t))$ расходящихся и сходящихся единичных образов [26, 27]:

$$w_{ij}(t) = k_{ij}(t) \cdot \beta(r_{ij}(t)) \cdot \eta(r_{ij}(t)).$$

Весовые коэффициенты $k_{ij}(t)$ изменяются в зависимости от воздействий на синапсы единичных образов и выступают в качестве элементов долговременной памяти сети. Единичные образы, проходя через синапсы, снимают с них информацию о предыдущих воздействиях и оставляют информацию о своем появлении через изменения весовых коэффициентов. Для каждого динамического синапса, связывающего i -й нейрон с j -м нейроном, весовой коэффициент $k_{ij}(t)$ на момент времени t поступления на синапс очередного единичного образа может определяться согласно правилам [27]

$$k_{ij}(t) = (1 - \exp(-\gamma g_{ij}(t))) / (1 + \exp(-\gamma g_{ij}(t))) = \text{th}(\gamma g_{ij}(t) / 2),$$

$$g_{ij}(t) = g_{ij}(t - \Delta t) + \Delta g_{ij}(t),$$



■ **Рис. 2.** Структура РНС в виде сходящейся спирали: 1, 3 — направления продвижения СЕО вдоль и между слоями РНС; 2 — линии разделения слоев на логические поля; 4 — нейроны первого и второго слоев

■ **Fig. 2.** The RNN structure in the form of a converging spiral: 1, 3 — direction of SSPs promotion along and between the layers of the RNN; 2 — the lines of splitting layers into logical fields due to spatial shifts of SSPs during transmission from one layer to another; 4 — neurons of the first and second layers

где $g_{ij}(t)$, $g_{ij}(t - \Delta t)$ — предыстория на моменты времени t и Δt соответственно; $g_{ij}(0) = 0$; γ — некоторый положительный коэффициент. Величина $\Delta g_{ij}(t)$ определяется в зависимости от состояний i -го и j -го нейронов. Если i -й нейрон сгенерировал сигнал и после этого возбудился j -й нейрон, то $\Delta g_{ij}(t)$ присваивается некоторая положительная величина. В случае, если возбуждение j -го нейрона произошло без участия i -го нейрона, то $\Delta g_{ij}(t)$ отрицательно. В остальных вариантах $\Delta g_{ij}(t) = 0$.

Функции $\beta(r_{ij}(t))$ ослабления единичных образов зависят от $r_{ij}(t)$ — условной удаленности связываемых через синапсы нейронов (условных расстояний между ними) на текущий момент времени. Для расчета $\beta(r_{ij}(t))$ и $r_{ij}(t)$ применимы формулы [26]

$$\beta(r_{ij}(t)) = 1/(1 + \alpha(r_{ij}(t))^{1/h}),$$

$$r_{ij}(t) = ((\Delta x_{ij}(t))^2 + \Delta y_{ij}(t)^2)^{1/2},$$

где α , h — положительные коэффициенты; $\Delta x_{ij}(t)$, $\Delta y_{ij}(t)$ — проекции связи i -го нейрона с j -м нейроном на оси X и Y без учета пространственных сдвигов. Полагается, что расстояние между слоями пренебрежимо мало.

Согласно этим формулам смещение СЕО вдоль слоев реализуемо за счет изменения $r_{ij}(t)$ путем задания значений $\Delta x_{ij}(t)$ и $\Delta y_{ij}(t)$. Расходимость

единичных образов в РНС управляется изменением коэффициентов α . Возможны и другие варианты такого управления [31].

Функции изменения параметров расходимости единичных образов в РНС возлагаются на блоки управления этих сетей. Однако команды на такие изменения предлагается подавать с блока управления прогнозированием в зависимости от условий заполнения РНС1 обрабатываемыми совокупностями единичных образов на момент считывания с нее информации. В случае заполнения РНС1 СЕО не меньше заданного значения обрабатываемая выборка временных рядов считается длинной, в противном случае — короткой. С учетом этого для РНС2 задается режим прогнозирования на длинных или коротких выборках.

В качестве результатов прогнозирования на выходе РНС2 выступают те СЕО, которые следуют за вызывающими их сигналами.

Алгоритм нейросетевого прогнозирования

Принимая во внимание вышесказанное, предлагаемый усовершенствованный метод можно представить в виде следующей последовательности шагов.

Шаг 1. Ввод в систему нейросетевого прогнозирования наблюдаемых сигналов.

Шаг 2. Преобразование этих сигналов в последовательность совокупностей единичных образов в базисе, согласованном с входом РНС1.

Шаг 3. Ассоциативная обработка в РНС1 преобразованных сигналов. Формирование и запоминание на элементах сети модели обрабатываемых сигналов с учетом накопленного опыта.

Шаг 4. Считывание информации о состоянии элементов из РНС1 в блок управления прогнозированием. Определение параметров загрузки РНС1 входными сигналами, длины выборки и положения выборки на слоях сети. Принятие решения о режиме прогнозирования. Перенос информации о состоянии элементов РНС1 в РНС2.

Шаг 5. Если загрузка РНС1 входными сигналами сосредоточена до середины ее слоев, а остальные части слоев свободны или слабо загружены, то осуществляется переход к шагу 7 прогнозирования с возможным удлинением коротких выборок.

Шаг 6. Запуск и реализация процесса обработки в РНС2 сигналов с ускоренным вызовом из ассоциативной памяти результатов прогноза в направлении входа этой сети в виде совокупностей единичных образов. Переход к шагу 9.

Шаг 7. Запуск и реализация процесса обработки в РНС2 сигналов с ускоренным вызовом информации из ассоциативной памяти в направлении выхода этой сети в течение времени, зависящего от длины обрабатываемой выборки и ее положения на слоях сети. Результат такой частичной обработки — удлинение справа обрабатываемых коротких выборок.

Шаг 8. Изменение направленности ассоциативного вызова информации из памяти РНС2 в сторону входа сети и продолжение реализации процесса обработки сигналов с формированием прогноза.

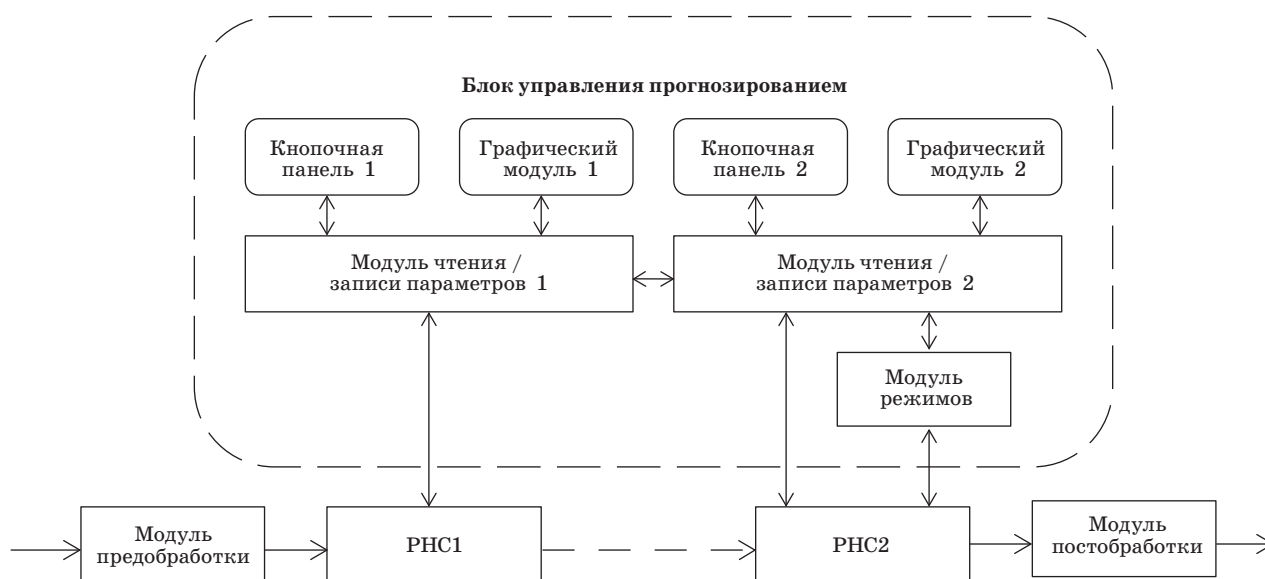
Шаг 9. Обратное преобразование результатов прогнозов в РНС2 в соответствующие им исходные сигналы.

Согласно этому алгоритму основное усовершенствование базового метода состоит в правилах ассоциативного вызова информации из памяти РНС2 для прогнозирования сигналов как на длинных, так и на коротких выборках. На удлинении коротких выборок может тратиться не менее ¼ времени, отводимого на всю обработку сигналов в РНС2. В случае обработки неоднородных входных выборок с пропусками сигналов и ложными выбросами возможно прогнозирование с усреднением многошаговых прогнозов, полученных относительно смещенных моментов времени.


За счет предлагаемого метода предоставляется возможность успешно прогнозировать различные события не только без прерывания обучения, но и на различных длинах выборок обрабатываемых временных рядов.

Программная реализация

Предложенный метод был реализован в программной системе прогнозирования на языке С++ с применением фреймворка Qt [29, 31]. Архитектура этой системы представлена на рис. 3. Программная система прогнозирования позво-



■ **Рис. 3.** Архитектура программной системы нейросетевого прогнозирования
 ■ **Fig. 3.** Architecture of software neural network forecasting system



■ **Рис. 4.** Логические структуры слоев РНС, реализованных в программной системе прогнозирования: *а, б, в* — линейная, петлевая и спиральная структуры; *г, д* — структуры в виде сходящейся и расходящейся спирали
 ■ **Fig. 4.** Logical structures of the RNN layers implemented in the forecasting software system: *a, б, в* — linear, loop and spiral structures; *г, д* — structures in the form of converging and diverging spiral

ляет конфигурировать любую логическую структуру применяемых РНС, выбирать количество и размер логических полей, настраивать другие параметры.

Для оценки возможностей предложенного метода формировались пять различных конфигураций РНС, входящих в систему прогнозирования. Конфигурации отличались только типами реализуемых логических структур РНС при 768 нейронах в каждом слое. За счет реализуемых пространственных сдвигов СЕО слои РНС разбивались на 24 поля по 32 нейрона. Направления продвижения СЕО вдоль слоев в таких конфигурациях показаны на рис. 4.

При прочих равных параметрах РНС оценивались возможности прогнозирования предложенным методом и реализующей его программной системой в этих пяти конфигурациях.

Исходные данные и результаты прогнозирования

Для прогнозирования был выбран эталонный набор данных Лаборатории исследования транспортных данных (TDRL) [33]. Этот набор содержит информацию о дорожной ситуации в городах-побратимах Миннесота и Ротчестер, полученную с микроволновых датчиков. Для проведения исследования были выбраны данные об объеме трафика (файлы *.v30) в период с 12 по 24 января 2018 года с детекторов № 51, 56, 61, 77, 80, 90, 453. Данные за 12–23 января 2018 года исполь-

зовались для обучения РНС, в то время как прогнозирование выполнялось на горизонт, равный одним суткам (24 января 2018 года). Интервал составлял 3 часа, а количество прогнозируемых значений равнялось восьми.

На этих исходных данных были получены результаты прогнозирования, которые сравнивались с реальными значениями объема трафика за 24 января 2018 года. Метрики, используемые при оценке точности, включали среднюю абсолютную процентную ошибку (MAPE), среднюю абсолютную ошибку (MAE) и среднеквадратическую ошибку (RMSE):

$$MAPE_k = \sum_{i=1}^N (|R_{ki} - F_{ki}| / R_{ki}) \cdot 100\% / N;$$

$$MAE_k = \sum_{i=1}^N (|R_{ki} - F_{ki}|) / N;$$

$$RMSE_k = (\sum_{i=1}^N ((R_{ki} - F_{ki})^2) / N)^{1/2},$$

где $k = 1..7$; $N = 8$; R_{ki} — реальные значения; F_{ki} — прогнозные значения.

Результаты оценивания точности прогнозирования по этим метрикам для рассмотренных пяти конфигураций программной системы представлены в таблице. В этой же таблице для сравнения приведены оценки, полученные на таких же исходных данных с помощью модели Бокса — Дженкинса (ARIMA — autoregressive integrated moving average).

Результаты показывают, что все пять конфигураций продемонстрировали достаточно высокую точность прогнозирования объема дорожного трафика. Она выше точности ARIMA.

- Результаты оценивания точности прогнозирования
- The results of the evaluation of prediction accuracy

Структура РНС	Показатель	Датчик							Среднее
		1	2	3	4	5	6	7	
Линейная	MAE	1,63	1,39	0,34	0,53	0,30	0,68	0,69	0,79
	MAPE	27,90	19,20	22,70	10,00	11,60	30,50	20,40	20,30
	RMSE	2,22	2,18	0,44	1,06	0,43	0,98	0,98	1,18
Спираль с постоянным диаметром	MAE	1,15	1,07	0,47	0,53	0,18	0,68	0,63	0,67
	MAPE	18,80	13,80	25,90	10,00	8,90	30,50	11,30	17,00
	RMSE	1,80	1,78	0,65	1,06	0,21	0,98	0,96	1,06
Петлевая	MAE	1,29	1,44	0,33	0,60	0,18	0,69	0,63	0,74
	MAPE	20,70	24,00	22,30	14,40	8,90	30,50	11,30	18,90
	RMSE	2,01	2,37	0,42	1,08	0,21	0,99	0,96	1,15
Спираль сходящаяся	MAE	1,29	1,27	0,33	0,59	0,18	0,65	0,63	0,71
	MAPE	21,10	16,60	22,30	10,80	8,90	28,50	11,30	17,10
	RMSE	1,87	2,04	0,42	1,09	0,21	0,97	0,96	1,08
Спираль расходящаяся	MAE	0,97	1,13	0,44	0,55	0,18	0,71	0,63	0,66
	MAPE	15,50	14,50	25,80	10,30	8,90	32,40	11,30	17,00
	RMSE	1,72	1,95	0,55	1,07	0,21	0,99	0,96	1,06
ARIMA	MAE	1,72	1,34	0,61	0,89	0,36	0,80	0,65	0,91
	MAPE	30,10	19,00	30,80	17,40	13,90	41,20	18,70	24,40
	RMSE	2,50	2,03	1,12	1,16	0,50	1,19	0,94	1,35

Наилучшие результаты характерны для спиральных структур, которые предпочтительнее линейных.

Наблюдаемый результат объясним преимуществом спиральных нейросетевых структур с точки зрения плотности ассоциативного связывания вызываемых сигналов с теми СЕО, которые уже находятся на слоях РНС. В то же время линейная структура может обеспечить относительно плотное связывание только ближайших СЕО, а влияние других единичных образов по мере удаления становится пренебрежимо малым.

Заключение

В результате данного исследования был разработан и проанализирован усовершенствованный метод нейросетевого прогнозирования событий с применением двух экземпляров потоковых РНС с управляемыми элементами. Согласно методу первый экземпляр постоянно находится в режиме обучения, благодаря чему на его синапсах выстраивается и постоянно обновляется пространственно-временная модель анализируемых событий. В интересах предсказания блок

управления прогнозированием считывает эту модель во второй экземпляр и запускает в нем процесс обработки информации, в результате чего из ассоциативной памяти вызываются результаты прогнозирования. Усовершенствованный метод предполагает прогнозирование не только с непрерывным обучением, но и на различных длинах выборки. Если выборка признается короткой, то при ее обработке вначале в целях получения предшествующих значений осуществляется усиление ассоциативного вызова сигналов в направлении выхода сети, и выполняется прогноз. Прогнозированием усиливает вызов сигналов в направлении входа сети, и выполняется прогноз. Наличие возможности управлять направленностью ассоциативного вызова сигналов позволяет уменьшить количество ошибок в виде пробелов в будущих событиях без искажения последовательности сигналов, которые их вызывают.

Для поиска целесообразной структуры слоев применяемой рекуррентной НС проведено исследование пяти вариантов (линейной, петлевой, спиральной структур, а также конфигураций в виде сходящейся и расходящейся спиралей). Для этого на языке программирования С++ разработана программная система прогнозирования, реали-

зующая предложенный метод. Исследование эффективности этих структур проводилось на примере прогнозирования городских транспортных потоков. В качестве исходных данных был выбран эталонный набор TDRL. Результаты сравнительной оценки эффективности предложенного метода с известной моделью ARIMA на одних и тех же исходных данных показали существенное преимущество предложенных решений. В частности, выигрыш по показателю MAPE составил

от 4,1 до 7,4 %. Ошибки по метрике RMSE ниже на значения от 0,17 до 0,29 и по MAE — от 0,12 до 0,2. Среди исследованных структур наибольшую точность показали спиральные структуры. Это объясняется более низкой плотностью ассоциативного связывания сигналов в линейной конфигурации. Разработанный метод рекомендуется для использования в современных робототехнических и других интеллектуальных системах для прогнозирования различных событий.

Литература

1. Brockwell P. J., Davis R. A. *Introduction to Time Series and Forecasting*. Springer, 2016. 425 p.
2. Nagy A. M., Simon V. Survey on traffic prediction in smart cities. *Pervasive and Mobile Computing*, 2018, vol. 50, pp. 148–163. doi:10.1016/j.pmcj.2018.07.004
3. Bok B., Caratelli D., Giannone D., Sbordone A. M., Tambalotti A. Macroeconomic nowcasting and forecasting with big data. *Annual Review of Economics*, 2018, vol. 10, pp. 615–643. doi:10.1146/annurev-economics-080217-053214
4. Timmermann A. Forecasting methods in finance. *Annual Review of Financial Economics*, 2018, vol. 10, pp. 449–479. doi:10.1146/annurev-financial-110217-022713
5. Welc J., Esquerdo P. J. R. *Applied Regression Analysis for Business*. Cham, Springer Nature Switzerland AG, 2018. 286 p. doi:10.1007/978-3-319-71156-0
6. Singh P. *Applications of Soft Computing in Time Series Forecasting*. Cham, Springer International Publishing Switzerland, 2016. doi:10.1007/978-3-319-26293-2
7. Скоробогатченко Д. А., Степанова П. Ю. Применение искусственных нейронных сетей при краткосрочном прогнозировании уровня загрузки городских автомобильных дорог. *Известия Волгоградского государственного технического университета*, 2017, № 14(209), с. 24–30.
8. Zhou T., Han G., Xu X., Lin Z., Han C., Huang Y., Qin J. δ -agree AdaBoost stacked autoencoder for short-term traffic flow forecasting. *Neurocomputing*, 2017, vol. 247, pp. 31–38. http://dx.doi.org/10.1016/j.neucom.2017.03.049
9. Egrioglu E., Yolcu U., Bas E., Dalar A. Z. Median-Pi artificial neural network for forecasting. *Neural Computing & Applications*, 2019, vol. 31, pp. 307–316. doi: 10.1007/s00521-017-3002-z
10. Herrera I., Chicaiza J., Herrera E., Lorente-Leyva L., Caraguay-Procet J., García-Santillán I., Peluffo D. Artificial neural networks for bottled water demand forecasting: A small business case study. *Advances in Computational Intelligence: Proceedings of 15th International Work-Conference on Artificial Neural Networks (IWANN 2019)*, Gran Canaria, Spain, June 12–14, 2019, Lecture Notes in Computer Science, 2019, vol. 11507. doi:10.1007/978-3-030-20518-8_31
11. Chawla A., Singh A., Lamba A., Gangwani N., Soni U. *Demand Forecasting Using Artificial Neural Networks — A Case Study of American Retail Corporation*. In: *Applications of Artificial Intelligence Techniques in Engineering. Series: Advances in Intelligent Systems and Computing*, 2019. Vol. 697. doi:10.1007/978-981-13-1822-1_8
12. Wu W., Wang X. The coal demand prediction based on the grey neural network model. *LISS 2014: Proceedings of 4th International Conference on Logistics, Informatics and Service Science*, Springer, Heidelberg, 2015, pp. 1337–1343. doi:10.1007/978-3-662-43871-8_194
13. Christopher J., Mou J., Yin D. Convolutional neural network deep-learning models for prediction of shared bicycle demand. *International Conference on Applications and Techniques in Cyber Security and Intelligence (ATCI 2018)*, 2019, vol. 842. doi:10.1007/978-3-319-98776-7_1
14. Bianchi F. M., Maiorino E., Kampffmeyer M. C., Rizzi A., Jenssen R. *Recurrent Neural Networks for Short-Term Load Forecasting*. Springer, 2017. 72 p. doi:10.1007/978-3-319-70338-1
15. Yang B., Sun S., Li J., Lin X., Tian Y. Traffic flow prediction using LSTM with feature enhancement. *Neurocomputing*, 2019, vol. 332, pp. 320–327. doi:10.1016/j.neucom.2018.12.016
16. Tian Y., Zhang K., Li J., Lin X., Yang B. LSTM-based traffic flow prediction with missing data. *Neurocomputing*, 2018, vol. 318, pp. 297–305. doi:10.1016/j.neucom.2018.08.067
17. Prokoptsev N. G., Alekseenko A. E., Kholodov Ya. A. Traffic flow speed prediction on transportation graph with convolutional neural networks. *Computer Research and Modeling*, 2018, vol. 10, no. 3, pp. 359–367. doi:10.20537/2076-7633-2018-10-3-359-367
18. Goudarzi S., Kama M. N., Anisi M. H., Soleymani S. A., Doctor F. Self-organizing traffic flow prediction with an optimized deep belief network for Internet of vehicles. *Sensors*, 2018, vol. 18, iss. 10, 3459. doi:10.3390/s18103459
19. Krichene E., Masmoudi Y., Alimi A. M., Abraham A., Chabchoub H. Forecasting using elman recurrent neural network. *ISDA 2016: Proceedings of Interna-*

- tional Conference on Intelligent Systems Design and Application*, Springer, 2017, vol. 557. doi:10.1007/978-3-319-53480-0_48
20. Schmidhuber J. Deep learning in neural networks: An overview. *Neural Networks*, 2015, vol. 61, pp. 85–117. doi:10.1016/j.neunet.2014.09.003
 21. Junyoung Chung, Caglar Gulcehre, Kyung Hyun Cho, Yoshua Bengio. Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv:1412.3555v1 [cs. NE] 11 Dec 2014. <https://arxiv.org/pdf/1412.3555.pdf> (дата обращения: 30 июня 2020).
 22. Shen Z., Zhang Y., Lu J., Xu J., Xiao G. A novel time series forecasting model with deep learning. *Neurocomputing*, 2019, vol. 396, pp. 302–313. doi:10.1016/j.neucom.2018.12.084
 23. Fan C., Ding C., Zheng J., Xiao L., Ai Z. Empirical mode decomposition based multi-objective deep belief network for short-term power load forecasting. *Neurocomputing*, 2020, vol. 388, pp. 110–123. doi:10.1016/j.neucom.2020.01.031
 24. Junxiu L., Tiening S., Yuling L., Su Y., Yi C., Jia Z. An echo state network architecture based on quantum logic gate and its optimization. *Neurocomputing*, 2020, vol. 371, pp. 100–107. doi:10.1016/j.neucom.2019.09.002
 25. Haitao L. Research on prediction of traffic flow based on dynamic fuzzy neural networks. *Neural Computing & Applications*, 2016, vol. 27, pp. 1969–1980. doi:10.1007/s00521-015-1991-z
 26. Осипов В. Ю. Ассоциативная интеллектуальная машина. *Информационные технологии и вычислительные системы*, 2010, № 2, с. 59–67.
 27. Пат. RU 2413304 С1. Способ и устройство интеллектуальной обработки информации в нейронной сети / В. Ю. Осипов, М. В. Осипова (РФ). № 2009141077.08; заявл. 02.11.2009; опубл. 27.02.2011; Бюл. 6.
 28. Осипов В. Ю. Нейросетевое прогнозирование событий для интеллектуальных роботов. *Мехатроника, Автоматизация, Управление*, 2015, № 12, с. 836–840.
 29. Осипов В. Ю. Рекуррентная нейронная сеть со спиральной структурой слоев. *Информационно-управляющие системы*, 2012, № 6, с. 28–32.
 30. Осипов В. Ю., Никифоров В. В. Возможности рекуррентных нейронных сетей с управляемыми элементами по восстановлению потоков кадров. *Информационно-управляющие системы*, 2019, № 5, с. 10–17. doi:10.31799/1684-8853-2019-5-10-17
 31. Osipov V., Osipova M. Space-time signal binding in recurrent neural networks with controlled elements. *Neurocomputing*, 2018, vol. 308, pp. 194–204. doi:10.1016/j.neucom.2018.05.009
 32. Osipov V., Nikiforov V., Zhukova N., Miloserdov D. Urban traffic flows forecasting by recurrent neural networks with spiral structures of layers. *Neural Computing and Applications*, 2020. doi:10.1007/s00521-020-04843-5
 33. <http://www.d.umn.edu/~tkwon/TMCdata/TMCarchive.html> (дата обращения: 17 декабря 2019).

UDC 004.4:004.8

doi:10.31799/1684-8853-2020-5-33-42

Neural network event forecasting for robots with continuous trainingV. Yu. Osipov^a, Dr. Sc., Tech., Professor, orcid.org/0000-0001-5905-4415, osipov_vasiliy@mail.ruD. I. Miloserdov^a, Post-Graduate Student, orcid.org/0000-0002-5312-5531^aSaint-Petersburg Institute for Informatics and Automation of the RAS, 39, 14 Line, V. O., 199178, Saint-Petersburg, Russian Federation

Introduction: High hopes for a significant expansion of human capabilities in various fields of activity are pinned on the creation and use of highly intelligent robots. To achieve this level of robot intelligence, it is necessary to successfully solve the problems of predicting the external environment and the state of the robots themselves. Solutions based on recurrent neural networks with controlled elements are promising neural network forecasting systems. **Purpose:** Search for appropriate neural network structures for predicting events. Development of approaches to controlling the associative call of information from a neural network memory. **Methods:** Computer simulation of recurrent neural networks with controlled elements and various structures of layers. **Results:** An improved method of neural network event forecasting with continuous robot training has been developed. This method allows you to predict events on either long or short samples of time series. In order to improve the forecasting accuracy, new rules have been proposed for controlling the associative call of information from the neural network memory. A software system has been developed which implements the proposed method and supports the emulation of neural networks with various layer structures. The possibilities of recurrent neural networks with linear or spiral layer structures are analyzed using the example of urban traffic flow forecasting. The gain of the proposed method in comparison with the ARIMA model for the MAPE indicator is from 4.1 to 7.4%. Among the studied neural network structures, the spiral structures have shown the highest accuracy, and linear structures have shown the lowest accuracy. **Practical relevance:** The results of the study can be used to improve the accuracy of event forecasting for intelligent robots.

Keywords — neural network, events forecasting, continuous training, robot.

For citation: Osipov V. Yu., Miloserdov D. I. Neural network event forecasting for robots with continuous training. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 33–42 (In Russian). doi:10.31799/1684-8853-2020-5-33-42

References

1. Brockwell P. J., Davis R. A. *Introduction to Time Series and Forecasting*. Springer, 2016. 425 p.
2. Nagy A. M., Simon V. Survey on traffic prediction in smart cities. *Pervasive and Mobile Computing*, 2018, vol. 50, pp. 148–163. doi:10.1016/j.pmcj.2018.07.004
3. Bok B., Caratelli D., Giannone D., Sbordon A. M., Tambalotti A. Macroeconomic nowcasting and forecasting with big data. *Annual Review of Economics*, 2018, vol. 10, pp. 615–643. doi:10.1146/annurev-economics-080217-053214
4. Timmermann A. Forecasting methods in finance. *Annual Review of Financial Economics*, 2018, vol. 10, pp. 449–479. doi:10.1146/annurev-financial-110217-022713
5. Welc J., Esquerdo P. J. R. *Applied Regression Analysis for Business*. Cham, Springer Nature Switzerland AG, 2018. 286 p. doi:10.1007/978-3-319-71156-0
6. Singh P. *Applications of Soft Computing in Time Series Forecasting*. Cham, Springer International Publishing Switzerland, 2016. doi:10.1007/978-3-319-26293-2
7. Skorobogatchenko D. A., Stepanova P. Yu. Application of artificial neural networks with short-term prediction of the level of loading of urban automobile roads. *Izvestia VSTU*, no. 14(209), pp. 24–30 (In Russian).
8. Zhou T., Han G., Xu X., Lin Z., Han C., Huang Y., Qin J. δ -agree AdaBoost stacked autoencoder for short-term traffic flow forecasting. *Neurocomputing*, 2017, vol. 247, pp. 31–38. <http://dx.doi.org/10.1016/j.neucom.2017.03.049>
9. Egrioglu E., Yolcu U., Bas E., Dalar A. Z. Median-Pi artificial neural network for forecasting. *Neural Computing & Applications*, 2019, vol. 31, pp. 307–316. doi: 10.1007/s00521-017-3002-z
10. Herrera I., Chicaiza J., Herrera E., Lorente-Leyva L., Caraguay-Procel J., Garcia-Santillán I., Peluffo D. Artificial neural networks for bottled water demand forecasting: A small business case study. *Proceedings of 15th International Work-Conference on Artificial Neural Networks (IWANN 2019) "Advances in Computational Intelligence"*, Gran Canaria, Spain, June 12–14, 2019, Lecture Notes in Computer Science, 2019, vol. 11507. doi:10.1007/978-3-030-20518-8_31
11. Chawla A., Singh A., Lamba A., Gangwani N., Soni U. *Demand Forecasting Using Artificial Neural Networks – A Case Study of American Retail Corporation*. In: *Applications of Artificial Intelligence Techniques in Engineering. Series: Advances in Intelligent Systems and Computing*, 2019. Vol. 697. doi:10.1007/978-981-13-1822-1_8
12. Wu W., Wang X. The coal demand prediction based on the grey neural network model. *Proceedings of 4th International Conference on Logistics, Informatics and Service Science (LISS 2014)*, Springer, Heidelberg, 2015, pp. 1337–1343. doi:10.1007/978-3-662-43871-8_194
13. Christopher J., Mou J., Yin D. Convolutional neural network deep-learning models for prediction of shared bicycle demand. *International Conference on Applications and Techniques in Cyber Security and Intelligence (ATCI 2018)*, 2019, vol. 842. doi:10.1007/978-3-319-98776-7_1
14. Bianchi F. M., Maiorino E., Kampffmeyer M. C., Rizzi A., Jenssen R. *Recurrent Neural Networks for Short-Term Load Forecasting*. Springer, 2017. 72 p. doi:10.1007/978-3-319-70338-1
15. Yang B., Sun S., Li J., Lin X., Tian Y. Traffic flow prediction using LSTM with feature enhancement. *Neurocomputing*, 2019, vol. 332, pp. 320–327. doi:10.1016/j.neucom.2018.12.016
16. Tian Y., Zhang K., Li J., Lin X., Yang B. LSTM-based traffic flow prediction with missing data. *Neurocomputing*, 2018, vol. 318, pp. 297–305. doi:10.1016/j.neucom.2018.08.067
17. Prokoptsev N. G., Alekseenko A. E., Kholodov Ya. A. Traffic flow speed prediction on transportation graph with convolutional neural networks. *Computer Research and Modeling*, 2018, vol. 10, no. 3, pp. 359–367. doi:10.20537/2076-7633-2018-10-3-359-367
18. Goudarzi S., Kama M. N., Anisi M. H., Soleymani S. A., Doctor F. Self-organizing traffic flow prediction with an optimized deep belief network for Internet of vehicles. *Sensors*, 2018, vol. 18, iss. 10, 3459. doi:10.3390/s18103459
19. Krichene E., Masmoudi Y., Alimi A. M., Abraham A., Chabchoub H. Forecasting using elman recurrent neural network. *Proceedings of International Conference on Intelligent Systems Design and Application (ISDA 2016)*, Springer, 2017, vol. 557. doi:10.1007/978-3-319-53480-0_48
20. Schmidhuber J. Deep learning in neural networks: An overview. *Neural Networks*, 2015, vol. 61, pp. 85–117. doi:10.1016/j.neunet.2014.09.003
21. Junyoung Chung, Caglar Gulcehre, Kyung Hyun Cho, Yoshua Bengio. Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv:1412.3555v1 [cs.NE] 11 Dec 2014. Available at: <https://arxiv.org/pdf/1412.3555.pdf> (accessed 30 June 2020).
22. Shen Z., Zhang Y., Lu J., Xu J., Xiao G. A novel time series forecasting model with deep learning. *Neurocomputing*, 2019, vol. 396, pp. 302–313. doi:10.1016/j.neucom.2018.12.084
23. Fan C., Ding C., Zheng J., Xiao L., Ai Z. Empirical mode decomposition based multi-objective deep belief network for short-term power load forecasting. *Neurocomputing*, 2020, vol. 388, pp. 110–123. doi:10.1016/j.neucom.2020.01.031
24. Junxiu L., Tiening S., Yuling L., Su Y., Yi C., Jia Z. An echo state network architecture based on quantum logic gate and its optimization. *Neurocomputing*, 2020, vol. 371, pp. 100–107. doi:10.1016/j.neucom.2019.09.002
25. Haitao L. Research on prediction of traffic flow based on dynamic fuzzy neural networks. *Neural Computing & Applications*, 2016, vol. 27, pp. 1969–1980. doi:10.1007/s00521-015-1991-z
26. Osipov V. Y. The associative intelligent machine. *Journal of Information Technologies and Computing Systems*, 2010, no. 2, pp. 59–67 (In Russian).
27. Osipov V. Yu., Osipova M. V. *Sposob i ustroystvo intellektualnoy obrabotki informatsii v neyronnykh seti* [Method and device of intellectual processing of information in neural network]. Patent RU 2413304 C1, 2011.
28. Osipov V. Yu. Neural network prediction of event for intelligent robots. *Mechatronics, Automation, Control*, 2015, no. 12, pp. 836–840 (In Russian).
29. Osipov V. Yu. Recurrent neural network with a spiral structure of layers. *Informatsionno-upravliayushchie sistemy* [Information and Control Systems], 2012, no. 6, pp. 2–32 (In Russian).
30. Osipov V. Y., Nikiforov V. V. Recurrent neural networks with controlled elements in restoring frame flows. *Informatsionno-upravliayushchie sistemy* [Information and Control Systems], 2019, no. 5, pp. 10–17 (In Russian). doi:10.31799/1684-8853-2019-5-10-17
31. Osipov V., Osipova M. Space-time signal binding in recurrent neural networks with controlled elements. *Neurocomputing*, 2018, vol. 308, pp. 194–204. doi:10.1016/j.neucom.2018.05.009
32. Osipov V., Nikiforov V., Zhukova N., Miloserdov D. Urban traffic flows forecasting by recurrent neural networks with spiral structures of layers. *Neural Computing and Applications*, 2020. doi:10.1007/s00521-020-04843-5
33. Available at: <http://www.d.umn.edu/~tkwon/TMCdata/TMCarchive.html> (accessed 17 December 2019).

Storage scaling management model

Sovetov B. Ya.^a, Dr. Sc., Tech., Professor, orcid.org/0000-0003-3116-8810,

Tatarnikova T. M.^b, Dr. Sc., Tech., Associate Professor, orcid.org/0000-0002-6419-0072, tm-tatarn@yandex.ru

Poymanova E. D.^b, Senior Lecturer, orcid.org/0000-0002-7903-2480,

^aSaint-Petersburg Electrotechnical University «LETI», 5, Prof. Popov St., 197376, Saint-Petersburg, Russian Federation

^bSaint-Petersburg State University of Aerospace Instrumentation, 67, B. Morskaia St., 190000, Saint-Petersburg, Russian Federation

Introduction: The implementation of data storage process requires timely scaling of the infrastructure to accommodate the data received for storage. Given the rapid accumulation of data, new models of storage capacity management are needed, which should take into account the hierarchical structure of the data storage, various requirements for file storage and restrictions on the storage media size. **Purpose:** To propose a model for timely scaling of the storage infrastructure based on predictive estimates of the moment when the data storage media is fully filled. **Results:** A model of storage capacity management is presented, based on the analysis of storage system state patterns. A pattern is a matrix each cell of which reflects the filling state of the storage medium at an appropriate level in the hierarchical structure of the storage system. A matrix cell is characterized by the real, limit, and maximum values of its carrier capacity. To solve the scaling problem for a data storage system means to predict the moments when the limit capacity and maximum capacity of the data carrier are reached. The difference between the predictive estimates is the time which the administrator has to connect extra media. It is proposed to calculate the values of the predictive estimates programmatically, using machine learning methods. It is shown that when making a short-term prediction, machine learning methods have lower accuracy than ARIMA, an integrated model of autoregression and moving average. However, when making a long-term forecast, machine learning methods provide results commensurate with those from ARIMA. **Practical relevance:** The proposed model is necessary for timely allocation of storage capacity for incoming data. The implementation of this model at the storage input allows you to automate the process of connecting media, which helps prevent the loss of data entering the system.

Keywords – data storage system, storage media, multi-level data storage, databank, databank scaling, databank control, required storage capacity forecast.

For citation: Sovetov B. Ya., Tatarnikova T. M., Poymanova E. D. Storage scaling management model. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 43–49. doi:10.31799/1684-8853-2020-5-43-49

Introduction

Data storage is a service needed by companies, governmental structures or individuals. Banks and insurance companies are active users of this service, as they keep all the primary documentation in scanned format. National security structures also have a high demand in data storage [1]. Urban infrastructure projects such as “Smart yard”, “Safe city”, etc. assume real-time data storage with subsequent archiving. The storage of unstructured medical data is often regulated by law. Individual users also contribute to the rapid growth of the data amount, creating private “clouds” in order to store their personal content.

The tendency of rapid data accumulation is referred to as “big data”. It is often characterized by its “three Vs”:

Volume, i. e. physical amount of data;

Velocity, i. e. speed of the data growth;

Variety, i. e. the capability to process different data types in the same time.

Big data is a trend in the modern stage of our transition to a digital society. To organize data storage, you need special infrastructure [2]. It can

be provided by a data storage system (DSS) which is a software/hardware solution for recording the data to be stored, secure storage of this data, and reading it by user’s demand [3]. The total capacity of a DSS, without going into details about the software/hardware solution, is also called data storage [4, 5].

A data storage is a complex control object which must deal with two types of load: data coming in real time, and data whose secure storage requires timely procedures of archiving, backuping, etc. [6–8]. Thus, the problem of big data is not the lack of the storage space but the lack of adequate models for controlling this space, in particular, its timely extension [9, 10]. Currently, the solution for this problem is not automated, being a part of the DSS operator’s duties. Implementing such a model at the input of a storage would allow us to automate the process of linking up the storage media, making sure the input data is not lost [11].

The results presented in this article are a continuation of the work [12]. The model proposed in [12] allows you to make short-range forecasts about events that require your DSS to be scaled. However, data storage systems need mid- and long-range

forecasts, as the implementation of scaling takes time, including the time for purchasing, installing and setting the equipment.

Description of the research object and statement of the problem

A data storage system follows the principle of hierarchical storage. Nowadays, at least three levels are specified in the DSS architecture [13–15]:

- RAID (Redundant Array of Independent Disks);
- automated libraries;
- long-term storage media.

Increasing the number of the levels is the problem of vertical scaling. Let us denote the number of levels in a DSS as m .

Increasing the number of the volumes/carriers at the i^{th} level of a DSS is the problem of timely horizontal scaling. Let us denote the number of volumes/carriers in a DSS as n [16].


The state of a DSS can be formalized as a matrix \mathbf{B} of size $m \times n$ [17], whose elements are sets of files with assigned parameters $F = \{t, f, \lambda\}$, where t is the time of guaranteed storage determined from the file extension **.type*; f is the file size; λ is the frequency of requests for the file. Parameters t and f are metadata analyzed at the DSS input. Parameter λ is dynamic; it determines the migration of files over the DSS levels.

Each cell of the matrix \mathbf{B} , in its turn, can be represented by its own characteristics (Fig. 1).

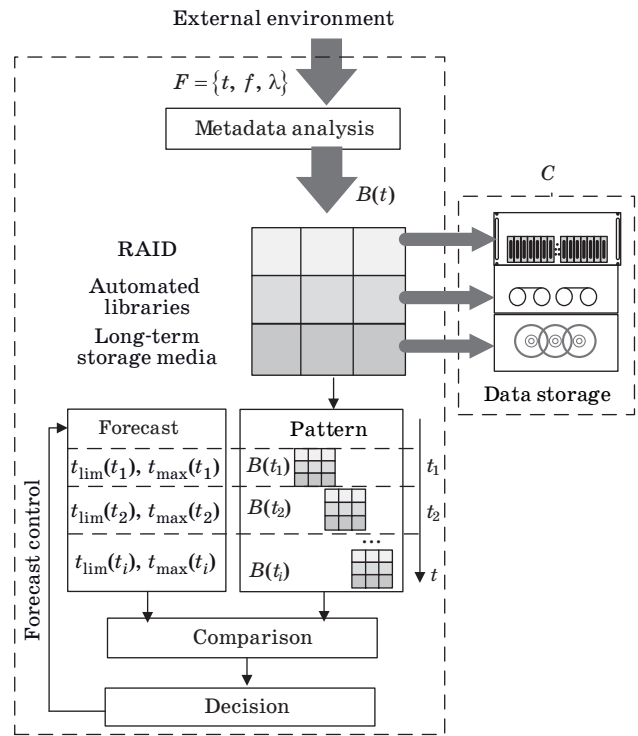
Thus, the problem of DSS scaling formulated in [12] as a forecast problem (estimating the moment t_{lim} of an event at which V_{cur} tends to V_{lim} and estimating the moment t_{max} of an event at which V_{cur} tends to V_{max}) is still the same. But our goal is getting mid- and long-range forecasts.

Let us call the DSS state specified by the matrix \mathbf{B} at the time moment t a behavior pattern $B(t)$ [18, 19].

Periodic analysis of $B(t)$ patterns allows you to adjust the forecast estimations t_{lim} and t_{max} . The structure of the data storage scaling management model is given in Fig. 2.



■ Fig. 1. Characteristics of a cell of the matrix \mathbf{B}



■ Fig. 2. Data storage scaling management model

The forecast model is adjusted automatically if the deviation of the pattern parameters from the forecast estimations becomes significant.

Proposed solution

In order to estimate the values of t_{lim} and t_{max} , let us use the following machine learning methods:

- Decision trees;
- Random forest;
- Feedforward neural network;
- Support vector machines.

Decision trees are the most popular method of numerical forecasting in the case when the forecast variable values are continuous. The method is popular due to the tree structure, in which the decision-making sequence is reduced to a number of vertex transitions, which subsequently makes model very comprehensible. The major shortcoming of the method is that it often requires retraining, which can lead to branchy trees and/or high class bias.

Formally, a decision tree is a graph $G = (V, E)$, where V is a finite non-empty set of vertexes, i. e. tree leaves; E is a finite non-empty set of vertex pairs, i. e. tree branches. The branches contain various conditions, and the leaves contain their values. The main parameter of the method is the tree depth, i. e. the distance from the root to the most remote leaves. The model of a decision tree is built

following two algorithms: induction and pruning. Induction specifies the borders of a hierarchical solution, based on the feature space x . Pruning removes less informative structures from the tree, preventing retraining. The conditions for splitting tree vertices are formed with a feature chosen by a greedy algorithm in order to reduce the cost function. In numerical prediction, this function is mean squared error (MSE):

$$MSE = \sum_{i=1}^N (V_i - \hat{V}_i)^2, \quad (1)$$

where V_i is real data in the i^{th} point; \hat{V}_i is a predicted value in the i^{th} point; N is the sample size.

The decision tree G breaks all the feature space into a certain number of non-overlapping subsets $\{E_1, \dots, E_M\}$, and in each subset E_j produces a prediction \hat{V}_j

$$G(V, E) = \sum_{j=1}^M \hat{V}_j [E_j \in E]. \quad (2)$$

In the prediction problem to be solved, the tree vertices are traffic amounts, and the branches are the moments of time when the incoming traffic amount is fixed.

Random forest is an ensemble of trees in which each tree has its weight when obtaining the final prediction estimation. The randomness is introduced into the ensemble of trees at the induction stage. The most common way of building an ensemble of trees is called *bagging* (abbreviated *bootstrap aggregation*). It is based on artificial creation of several samples $V = \{V_1, V_2, \dots, V_C\}$ from the training set, uniformly and with replacement. On each sample, a decision tree $G_i, i = \overline{1, C}$ is built. Bagging is normally used in order to avoid retraining, i. e. saving the training dataset indiscriminately. The algorithm is characterized by two main parameters: number of the trees and their depth.

In addition to bagging, you can randomly select a subset of features in each vertex in order to make the trees more independent. The final prediction is chosen by averaging:

$$G(V, E) = \frac{1}{C} \sum_{i=1}^C G_i. \quad (3)$$

Using *neural networks* for time series prediction is based on the assumption that a regression problem can be replaced by a recognition problem. As a matter of fact, a neural network cannot predict. It can only recognize, in the current parameters of a time series, a familiar situation, reproducing a reaction to it as precisely as possible. Thus, the statement of a prediction problem as applied to a neural network can be formulated as follows: to find the

best approximation to a function defined by a finite set of a training sample.

In time series prediction, a multilayer perceptron, i. e. a feedforward neural network can be useful, as a feedback network uses short-term memory.

The inputs of a multilayer perceptron are fed with parameters reflecting the function of the data stream $\phi(t)$ to the DSS, and the outputs are the predicted values of t_{lim} and t_{max} . This method was dubbed “sliding windows”, as its implementation requires two windows: the input window corresponds to the values of the input layer of the neural network; the output window corresponds to the expected values of its output layer. In the course of a prediction, both these windows move along the function $\phi(t)$ with a step which corresponds to the time series interval. Like in all regression problems solved by neural networks, supervised training method is used.


Support vector machines solve the prediction problem through classification, taking the initial data vector to an n -dimensional space and searching for $(n - 1)$ dimensional hyperplane with a maximum Euclidean distance between the borders of areas separating one class from another. The initial data vector is a time series describing the amount of traffic coming to the storage to be stored. In fact, support vector machines solve an optimization problem where the target function is maximizing the Euclidean distance between the decision planes or minimizing the average value of the MSE classifier. During the training, “volume-time” classes of the function $\phi(t)$ are determined; and during the prediction, the classes are revealed to which the future values of $\phi(t)$ can be assigned, and the values $t_{\text{lim}}(t)$ and $t_{\text{max}}(t)$ are calculated.

Linear optimization assumes that a system of equations is written as a scalar product; non-linear optimization assumes that it is written as a non-linear kernel function. In this work, Gaussian radial basis function is chosen.


Discussion of the results

To estimate the accuracy of a short-term prediction, we used LTE traffic data for 6 days (August 20–25, 2018) provided by MTS mobile operator in Saint-Petersburg, Russia (Fig. 3). The time series consists of 144 observations averaged by 1440 values of the service amount V .

Since most machine learning methods are sensitive to scaling, the data should be pre-processed, using the procedures of data normalization if the nominal features can be put into the range from 0 to 1, or standardization if each feature has a mean value equal to 0 and dispersion equal to 1. In Fig. 4, you can see standardized LTE traffic from Fig. 3.



■ Fig. 3. Incoming stream of LTE traffic data by MTS [12]



■ Fig. 4. Standardized LTE traffic by MTS

The short-term prediction was built for August 25, 2018. Fig. 5, *a-d* contains graphs demonstrating the difference between the real traffic and the predicted one, obtained through machine learning. Table 1 contains the values of MSE from which you can judge the prediction error, along with the key parameters selected during the training.

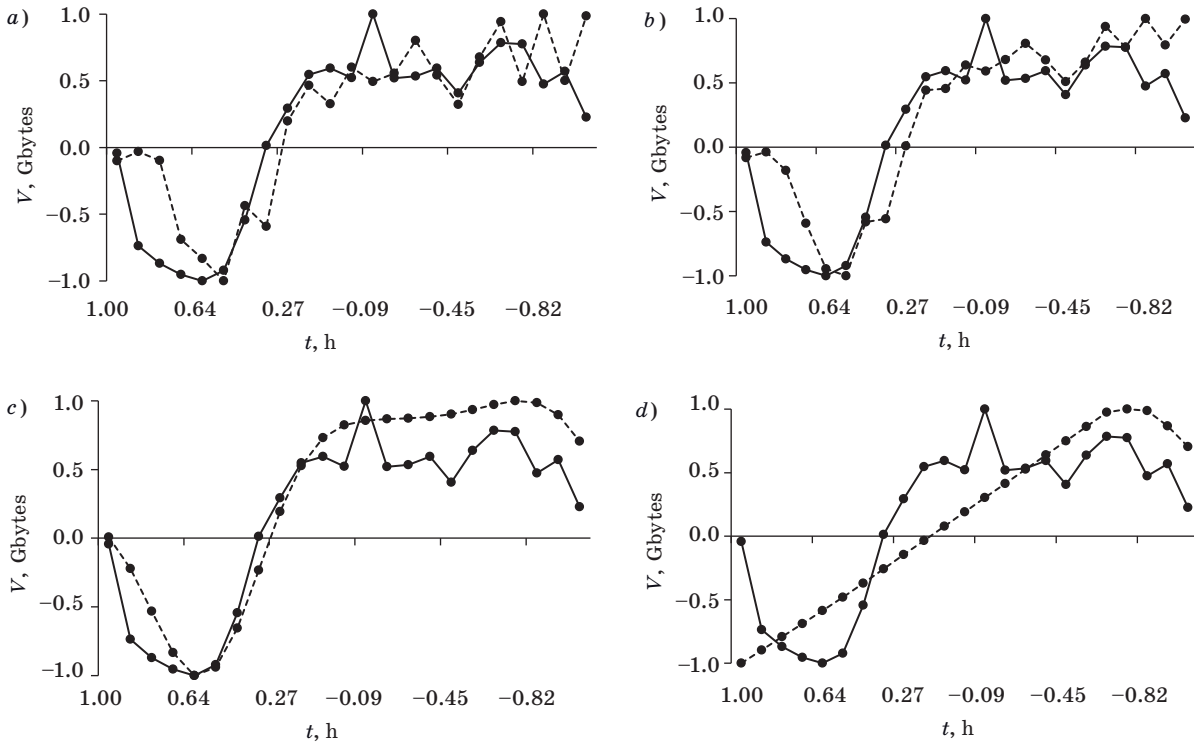
In [12] it was shown to be possible to obtain MSE = 0.04 by using ARIMA, an integrated model

of autoregression and moving average. Fig. 6 shows graphs demonstrating the difference between the real traffic and predicted one obtained through ARIMA. The results do not contradict the statements that autoregression models are currently the best tool for time series prediction.


For obtaining medium- and long-term predictions, we need long records of traffic traces [20]. This

■ Table 1. MSE values and key parameters of machine learning

Machine learning method	MSE	Key parameters
Decision tree	0.54	Depth of the tree is 15
Random forest	0.525	Bagging, and randomly generated subsets from the training set with repetitions
Support vector machines	0.41	Gaussian kernel with radial basis function
Neural network	0.62	Architecture (A) is a multilayer perceptron with 3 hidden layers. The number of the hidden layers h is chosen experimentally: $\lim_{0 < h \leq 9} A(h) \rightarrow \min(MSE)$



■ Fig. 5. Real traffic (—) and traffic short-term prediction (---) through machine learning: *a* — decision tree; *b* — random forest; *c* — support vector machines; *d* — neural network



■ Fig. 6. Real traffic (—) and traffic prediction (---) through ARIMA model

seemingly unsatisfiable demand was satisfied due to the open publication of internet traffic data by a Japanese MAWI research group, WIDE project. The training set has 24-hour traces for September 05, 2018 and September 04, 2019, 48-hour traces for September 01, 2007–November 01, 2007, 72-hour routes for March 18–20, 2008, and 96-hour traces for March 30, 2009 and February 01–04, 2009.

Figure 7, *a–d* contains graphs demonstrating the difference between the real traffic and predicted one obtained through machine learning.

The values of MSE in ARIMA model, as applied to long records of traffic traces with medium- and long-term predictions do not significantly change, being equal to 0.035.

Table 2 shows the predicted values of t_{lim} , t_{max} for the storage at RAID0, RAID3 and RAID5 levels with the following parameters: capacity of one 2.5" SSD is 3840 Gbytes; number of the discs is 50; total capacity is 192 Tbytes; time of switching between the discs at RAID3 level is 1 minute for taking into account the difference in performance between RAID3 and RAID5; time given by the administrator for scaling is 9 hours.





After applying different machine learning methods to the analysis and prediction of filling up the storage, we can make the following conclusions:

1. In spite of the fact that ARIMA model shows good results when its parameters are properly set up, it should be noted that the parameters are chosen through auto-correlation analysis which can take an order of magnitude more time as compared to machine learning.

2. There is no commonly accepted model for the prediction of filling up a data-storage system in or-

■ Table 2. Predicted values of the onset of time of the maximum and real storage capacity

RAID level	Capacity, Tbytes	Efficient capacity, Tbytes	t_{lim} , days	t_{max} , days
RAID0	192	192	14.27	14.57
RAID3	192	188.16	14.06	14.36
RAID5	192	188.16	13.98	14.28



■ Fig. 7. Real traffic (—) and traffic long-term prediction (---) through machine learning: *a* — decision tree, MSE = 0.047; *b* — random forest, MSE = 0.047; *c* — support vector machines, MSE = 0.013; *d* — neural network, MSE = 0.056

der to make a decision about timely scaling of the system. However, based on the obtained results, we can recommend the following:

- ARIMA model for short-term predictions;
- machine learning models for long-term predictions.

3. Although any prediction is an extrapolation of data, machine learning methods actually solve an interpolation problem. This allows us to restore the amounts of data written in the storage which are not fixed in time.

Conclusion

The article discusses the importance of timely scaling of a data storage system. A model of hori-

zontal scaling is proposed which presumes that the number of volumes/carriers at any hierarchical storage level is differentially increased.

Planning the scaling of storage capacity is based on predicting the amount of the incoming data traffic and the moment when the limit or maximum capacity of the storage medium is reached.

We have discussed various methods of machine learning applied to the analysis and long-term prediction of filling up a data storage system. The method of support vector machines provided predictive estimates three times higher by MSE value than those obtained through ARIMA which is currently considered the best model for time series prediction.

The prediction of storage capacity scaling is necessary for timely allotment of memory resources and reduction of the incoming traffic loss.

References

1. **Yakhina I.** Warehouses for big data. *Otkrytye sistemy* [Open systems], 2012, no. 7. Available at: <https://www.osp.ru/os/2012/07/13017639> (accessed 31 August 2020).
2. **Proskuryakov N. E., Anufrieva A. Yu.** Analysis and prospects of modern digital data storage systems. *Proc. of the TSU*, 2013, no. 3, pp. 368–377 (In Russian).
3. **Vogel A., Griebler D., Maron C., Schepke C, Fernandes L.** Private IaaS clouds: a comparative analysis of OpenNebula, CloudStack and OpenStack. *2016 24th Euromicro International Conference on Parallel, Distributed, and Network-Based Processing (PDP)*, IEEE 2016, pp. 672–679.
4. **Gangadharan G. R.** Open source solutions for cloud computing. *Computer*, 2017, no. 1, pp. 66–70.
5. *Information Storage and Management*. 2nd Edition. New Jersey, John Wiley & Sons, 2016. 544 p.
6. **Song Z., Zhang X., Eriksson C.** Data center energy and cost saving evaluation. *Energy Procedia*, 2015, vol. 75, pp. 1255–1260.
7. **Farley M.** *Building Storage Networks*. Osborne, McGrawHall, 2001. 576 p.
8. Recommendation Y.3510: Cloud computing infrastructure requirements. Geneva, ITU-T, 2013. Available at: <https://www.itu.int/rec/T-REC-Y.3510-201305-S> (accessed 29 January 2019).
9. **Leonov V.** *Google Docs, Windows Live i drugie oblachnye tekhnologii* [Google Docs, Windows Live and other cloud technologies]. Eksmo Publ., 2012. 304 p. (In Russian).
10. **Carr N.** *The Big Switch — our New Digital Destiny*. WW Norton & Company, 2008. 278 p.
11. **Burmistrov V. D., Zakovryashin E. M.** Creating a data warehouse for a distributed system. *Young Scientist*, 2016, no. 12, pp. 143–147 (In Russian).
12. **Poymanova E. D.** *Model' upravleniya resursami sistem khraneniya dannykh*. Dis. kand. tehn. nauk [Storage management system resource management model. PhD tech. sci. diss.]. Saint-Petersburg, SPbGETU “LETI” Publ., 2020. 17 p. (In Russian).
13. **Buyya R., Broberg J., Goscinski A.** *Cloud Computing. Principles and Paradigms*. New Jersey, John Wiley & Sons, 2011. 637 p.
14. Recommendation Y.3501: Cloud computing framework and high-level requirements. Geneva, ITU-T, 2013. Available at: <https://www.itu.int/ITU-T/recommendations/rec.aspx?rec=11917> (accessed 29 January 2019).
15. **Zhmylev S. A., Martynchuk I. G.** Mathematical modeling in cloud systescaling. *IEEE Xplore Digital Library*, 2019, pp. 1–9. doi:10.1109 / WECONF.2019. 8840614
16. **Lorido-Botran Tania, Miguel-Alonso Jose, Lozano Jose A.** A review of auto-scaling techniques for elastic applications in cloud environments. *Journal of Grid Computing*, 2014, vol. 12, no. 4, pp. 559–592.
17. **Sovetov B. Ya., Tatarnikova T. M., Poymanova E. D.** Organization of multi-level data storage. *Informatcionno-upravliaiushchie sistemy* [Information and Control Systems], 2019, no. 2, pp. 68–75 (In Russian). doi:10.31799/1684-8853-2019-2-68-75
18. **Morville P., Callender J.** *Search Patterns: Design for Discovery*. O'Reilly, 2010. 192 p.
19. **Stacey M., Salvatore J., Jorgensen A.** *Visual Intelligence: Microsoft Tools and Techniques for Visualizing Data*. New Jersey, John Wiley & Sons, 2013. 432 p.
20. **Shahzad A., Lee Y. S., Lee M., Kim Y-G., Xiong N.** Real-time cloud-based health tracking and monitoring system in designed boundary for cardiology patients. *Journal of Sensors*, 2018, vol. 2018, 15 p. doi:10.1155/2018/3202787

УДК 004.7

doi:10.31799/1684-8853-2020-5-43-49

Модель управления масштабированием системы хранения данныхБ. Я. Советов^а, доктор техн. наук, профессор, orcid.org/0000-0003-3116-8810Т. М. Татарникова^б, доктор техн. наук, доцент, orcid.org/0000-0002-6419-0072, tm-tatarn@yandex.ruЕ. Д. Пойманова^б, старший преподаватель, orcid.org/0000-0002-7903-2480^аСанкт-Петербургский государственный электротехнический университет «ЛЭТИ», Профессора Попова ул., 5, Санкт-Петербург, 197376, РФ^бСанкт-Петербургский государственный университет аэрокосмического приборостроения, Б. Морская ул., 67, Санкт-Петербург, 190000, РФ

Постановка проблемы: хранение данных требует своевременного масштабирования инфраструктуры для размещения данных, поступающих на хранение. С учетом стремительного накопления данных необходимы новые модели управления емкостью хранилища, которые должны учитывать иерархическую структуру хранилища данных, разные требования к хранению файлов и ограничения на объем носителей. **Цель исследования:** предложить модель своевременного масштабирования инфраструктуры хранения данных, основанную на прогнозных оценках наступления того момента, когда заполнится емкость носителей данных. **Результаты:** разработана и приведена модель управления емкостью системы хранения данных, основанная на анализе паттернов состояния системы хранения. Паттерн представляет собой матрицу, каждая ячейка которой отражает состояние заполнения носителя системы хранения данных на соответствующем уровне иерархической структуры системы хранения. Ячейка матрицы характеризуется реальным, предельным и максимальным значениями емкости носителя. Задача масштабирования системы хранения данных заключается в прогнозной оценке наступления событий достижения предельной емкости и максимальной емкости носителя данных. Разница между прогнозными оценками есть время, которое выделено администратору для подключения дополнительных носителей. Предложено вычислять значения прогнозных оценок времени программным способом, применяя методы машинного обучения. Показано, что при построении краткосрочного прогноза методы машинного обучения проигрывают в точности ARIMA — интегрированной модели авторегрессии и скользящего среднего. Однако при построении долгосрочного прогноза методы машинного обучения дали результаты, соизмеримые с теми, что обеспечивает ARIMA. **Практическая значимость:** предложенная модель управления масштабированием системы хранения данных необходима для своевременного выделения емкости для поступающих на хранение данных. Реализация этой модели на входе хранилища позволяет автоматизировать процесс подключения носителей, что предотвращает потерю входящих в систему данных.

Ключевые слова — система хранения данных, носители, многоуровневое хранение данных, хранилище данных, масштабирование хранилища, управление хранилищем, прогнозирование требуемой емкости хранения.

Для цитирования: Sovetov B. Ya., Tatarnikova T. M., Poymanova E. D. Storage scaling management model. *Информационно-управляющие системы*, 2020, № 5, с. 43–49. doi:10.31799/1684-8853-2020-5-43-49

For citation: Sovetov B. Ya., Tatarnikova T. M., Poymanova E. D. Storage scaling management model. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 43–49. doi:10.31799/1684-8853-2020-5-43-49

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, что снижает 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 сверху справа на стартовой странице): <https://orcid.org>

UDC 004.032.2

doi:10.31799/1684-8853-2020-5-50-61

System for monitoring and adjusting the learning process of primary schoolchildren based on the EEG data analysis

S. A. Kurkin^a, Dr. Sc., Phys.-Math., Professor, orcid.org/0000-0002-3438-5717, kurkinsa@gmail.com

V. V. Grubov^a, PhD, Phys.-Math., Senior Researcher, orcid.org/0000-0003-2491-2592

V. A. Maksimenko^a, PhD, Phys.-Math., Senior Researcher, orcid.org/0000-0002-4632-6896

E. N. Pitsik^a, Junior Researcher, orcid.org/0000-0003-1850-2394

M. V. Khramova^b, PhD, Ped., Associate Professor, orcid.org/0000-0002-6392-4580

A. 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: Monitoring the learning process usually involves an analysis of the higher mental functions of the student: imagination, memory, thinking, attention, etc. Currently, there are wide opportunities for objective monitoring and evaluation of these characteristics based on the achievements of modern neuroscience. Analysis of the personal characteristics of the student allows to perform personalization of educational process. In this context, the approaches based on the electroencephalography analysis are particularly promising. Currently, one of the main barriers to the widespread introduction of EEG based systems in the school educational process is the lack of ready-made solutions to such systems for use in the learning process of schoolchildren, as well as scenarios for their application. **Purpose:** Development and initial testing of the system for monitoring and adjusting the learning process, as well as strategies for its use for primary school students. **Methods:** EEG analysis, wavelet analysis of recorded multichannel EEG data, analysis of changes in the energies of the main rhythms of the neural activity of the brain, the feedback provided by the system. **Results:** The concept and diagram of the developed system for monitoring and adjusting the learning process and the strategy for its use for elementary school students are described in detail. An increase in the efficiency of learning process with developed system was demonstrated as a consequence of feedback based on the assessment of changes in the energies of the characteristic rhythms of the student's brain activity. **Practical relevance:** The use of EEG systems for an objective analysis of the personal characteristics of students and the personalization of the learning process through the implementation of feedback based on the data obtained will increase the quality of the educational process and the efficiency of learning new material.

Keywords – personalized learning, EEG, elementary school students, brain-computer interface, learning process control, electroencephalography, EEG signal analysis, brain activity, neural activity.

For citation: Kurkin S. A., Grubov V. V., Maksimenko V. A., Pitsik E. N., Khramova M. V., Hramov A. E. System for monitoring and adjusting the learning process of primary schoolchildren based on the EEG data analysis. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 50–61. doi:10.31799/1684-8853-2020-5-50-61

Introduction

The control of the learning process on the all levels of education has always been an demanded topic. The control has been considered in the context of the evaluation the learning process efficiency by teacher as well as by the students. The pedagogical control implies correction of the learning process based on the analysis of the data obtained by the teacher. The procedure of adjustment itself can be carried out at each step of the learning process, but it has the most important value at the completion of the learning new material. Thus, the pedagogical control is a certain way to assess information about the quality of the learning process and the readiness of the student.

Traditionally, the Russian and foreign pedagogy of XX century was focused on the quality of the learning, skills and attitudes. Various forms and methods of control were able to not only to verify

learning, skills and attitudes, but also change the system of teaching in the process of learning, which allows to individualize and differentialize it [1–5].

Introduction of competency approach in the school education highlighted certain dissatisfaction with the traditional methods of learning process control. The search for the new methods and techniques was initiated for verifying not only traditional learning, skills and attitudes, but also personal and mental features of the student.

Since the works of L. S. Vygotskiy, the educational psychology implied the analysis of the development of the higher mental functions, such as imagination, memory, thinking, attention, etc. [2, 6] Russian and foreign teachers and psychologists tried to consider corresponding neuropsychological knowledge in the process of the learning and control [5, 7]. Recently, the great opportunities for objective control and evaluation of such features were discovered based on the achievements of modern

neuroscience. In [8, 9] the relationships between academic progress, cognitive abilities and features were studied. The modern techniques of neuroimaging (EEG, MEG, fNIRS, fMRI) have broad potential to consider the development of memory and attention of preschoolers [10], as well as to visualize the cognitive processes while solving the spatial reasoning mathematical tasks [11], arithmetic tasks [12], or the tasks that require auditory processing during reading and spelling [13].

Introduction of the digital learning devices and remote educational technologies, as well as transition of the learning in the digital environment, highlighted the issue of relevance of the learning process quality control. On the one hand, the analytics of a large amount of data obtained in the process of mass training and, on its basis, the personalization of the learning process has become in demand [14]. On the other hand, personalization became possible based on the analysis of the cognitive characteristics of the students [15]. EEG based research on the analysis of brain activity seems to be especially promising. First of all, this is due to the fact that EEG, being a relatively inexpensive, affordable, easy-to-use and safe technology, allows obtaining objective information about the brain's work with good time resolution [16]. Moreover, when using EEG, preliminary analysis and optimization usually allows to significantly reduce the number of electrodes, as well as the duration of recordings of EEG signals when solving a specific problem [17]. For example, in [18], it was shown that the state of the subject upon perception of an ambiguous visual stimulus can be identified with high accuracy using signals recorded with only two EEG channels.

Electroencephalogram studies have shown [19] that children with lower math skills need more careful monitoring and processing of resources. In [20], it was revealed how the type and complexity of the task affect the information processing mechanism and how the approaches to solving linguistic and visual-spatial tasks differ in individuals of different intelligence levels. However, such works are rather in the nature of scientific research and are not intended for the direct introduction of EEG into the learning process. The 2018 survey mentions only 22 examples of publications on this topic [16].

At the same time, it became clear that the use of EEG for an objective analysis of the cognitive characteristics of students and personalization of the learning process through the implementation of feedback based on the data obtained will significantly improve the quality of the educational process and the efficiency of learning new material [16]. It is expected that the proposed approach will give the best results when used on primary schoolchildren. This is due to the higher lability of children and the presence of simpler scenarios for using such a sys-

tem on the relatively simple and easily systematized educational material of primary school.

Currently, there are two main barriers that prevent the widespread introduction of EEG systems into the school educational process. Firstly, the technical difficulties of using EEG, which include the relatively long process of mounting electrodes on the head and the need to use special gel and paste. Secondly, the lack of ready-made solutions for systems based on EEG to use in the learning process of schoolchildren, as well as scenarios for their use. However, the development of compact and relatively inexpensive electroencephalographs and "dry" electrodes already makes it possible to overcome the first barrier [16].

In present paper, we took a step towards overcoming the second barrier by describing the concept and scheme of the developed system for monitoring and adjusting the learning process and the strategy of its use for primary schoolchildren. The results of the first tests of the implemented system are also given.

General description of the system for monitoring and adjusting the learning process

Functional diagram and main blocks

A diagram of the proposed prototype (briefly — a learning control system, LCS) is shown in Fig. 1. It includes three main blocks.

1. Electroencephalograph for recording the electrical activity of the student's brain in the process of solving cognitive tasks.

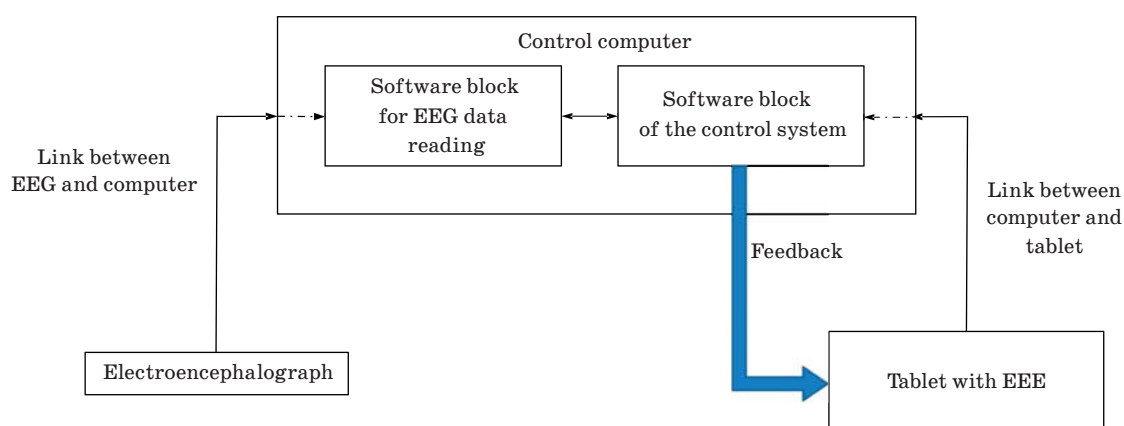
2. A tablet with a developed electronic educational environment (EEE). EEE provides an interface for the student to interact with the LCS using a tablet, solving the proposed tasks, studying the proposed educational material, or perceiving other accompanying information.

3. Control computer (personal computer or laptop) with a software module for reading and primary processing of data coming from the electroencephalograph and a software module of the control system that processes all incoming information, controls the effectiveness of the learning process and develops a strategy for its correction.


There are three main streams of information organized in LCS.

1. The EEG data are transmitted to the control computer (to the software module for reading EEG data and then to the software module of the control system) via wireless communication channel (for example, Bluetooth).

2. The results of the students' testing are transmitted from the tablet with EEE to the control computer (to the software module of the control sys-



■ Fig. 1. Functional diagram of the proposed system



■ Fig. 2. Qualitative illustration of the developed learning control system

tem). The results can be both the correctness and speed of the solution, as well as the reaction time, the number of errors and any other behavioral specifications; a wireless communication channel is used for data transmission.

3. Feedback in the form of control commands transmitted via wireless channel from the software module of the control system to the tablet with EEE. Feedback is necessary to adjust the tasks and educational material (their level of difficulty, type, rest time and other parameters) offered to the student through the EEE. The control system determines the direction of changing the task parameters based on the analysis of incoming information (see items 1 and 2) using original algorithms. Moreover, control or adjustment can be carried out by an operator (teacher, psychologist) in manual

mode based on information displayed in real time on the monitor of the control computer.

Figure 2 shows an illustration of the developed system for monitoring and adjusting the learning process of primary schoolchildren based on the analysis of EEG data, which schematically demonstrates the variant of its use.

The principle of functioning of the developed system

Let's consider the principle of operation of the proposed LCS system on a simple example of its use during one student control session. In this case, the student is invited to pass a set (battery) of tests in the EEE on a tablet, consisting of mandatory and variable parts. The obligatory part includes tests for assessing the student's cognitive resource, in

particular, Schulte tables, memory test, proofreading test, etc. These tests allow assessing the student's current cognitive resource, as well as his psycho-emotional and psychophysiological state and the level of cognitive fatigue. The variable part of the tests includes subject-oriented test assignments in the frames of the taught discipline. Tests can be both input and intermediate, or final verification tests for the chosen topic.

A fundamental feature of the developed system is the feedback (see Figs. 1 and 2), based on continuous monitoring and analysis of the student's brain activity and adjusting the complexity of test tasks based on the aggregate information about the correctness of tasks and the characteristics of brain activity. The latter allows to objectively and continuously assess such components of the cognitive resource as the level of attention, cognitive fatigue, and working memory. Thus, the following main scenarios of feedback have been implemented:

— The student successfully copes with the current test task (the success criterion is set by the teacher) — the feedback commands EEE to increase the complexity of the task. For example, the student copes well with the implementation of the Schulte table consisting of 25 digits, then the feedback will lead a Schulte table of 36 digits, on the next step of testing.

— The student does not cope with the current test task, the analysis of EEG data shows a high level of cognitive fatigue — the student is given the rest necessary to reduce cognitive fatigue, for example, an educational game or cartoon is offered. The test then continues.

— The student does not cope with the current test task, the analysis of EEG data shows a low level of attention, while cognitive fatigue is at a normal level — the student is given comments that motivate him to perform the test more attentively.

— The student does not cope with the current test task, while the analysis of the EEG data shows that cognitive fatigue and the degree of attention are at normal levels. This means that the student is trying to solve the task proposed to him, effectively using his cognitive resource. However, the complexity of the task is too high for him. As a result, the feedback gives the EEE command to reduce the level of task complexity.

The described adaptive adjustment of the complexity of the test tasks based on the analysis of the student's EEG data, allows to determine the maximum task complexity for each student, which is determined by his cognitive resource and abilities. This adjustment is carried out both for mandatory and optional tests. In the first case, feedback allows to assess the most correct and objective state of the cognitive resource of the student, as well as his psychoemotional and psychophysiological state.

In the second case, it is possible to determine the current level of the student on the topics covered by the tests.

Relationships between EEG and cognitive resources


As mentioned in the previous subsection, the feedback in LCS based on a continuous assessment of the components of a student's cognitive resource, which are attention level, cognitive fatigue, working memory load, using recorded EEG in the process of passing test tasks. It is well known that M/EEG signals reflect the activity of the brain in different frequency ranges [17, 21, 22], mainly δ -rhythm (1–4 Hz), θ -rhythm (4–8 Hz), α -rhythm (8–12 Hz), β -rhythm (13–30 Hz) and γ -rhythm (> 30 Hz). The ratio of given frequency ranges reflects various cognitive processes in the human brain [23–26]. To assess the cognitive resource (in particular, indicators of attention and cognitive fatigue), the most important is the ratio of the energies of the α - and β -rhythms [27–32]. For example, an increase in the level of attention and concentration on solving a problem in most cases is accompanied by a significant decrease in the energy of the α -rhythm with a simultaneous increase in activity in the β -range [29, 31, 33]. Note that it is not the absolute values of the energies of different rhythms that matter, but how they change relatively to a certain basic level (for example, the corresponding energies at rest), or their dynamics in the process of solving problems. Thus, when using EEG signals to assess the cognitive characteristics of a student, a necessary step is to calibrate the system for a particular student, which is carried out during resting state [34]. Further, the system monitors changes in various rhythms of brain activity in the process of performing test tasks by students, as well as during rest between tasks. To assess the energies of various rhythms in EEG signals, wavelet analysis is used [35].

The methodological basis of the algorithms that establish the relationship between the levels of the main components of the student's cognitive resource and changes in rhythm energies in EEG signals is described in more detail in [31, 36, 37] and presented in registered computer programs [38, 39].

The strategy of using the developed system to control and adjust the learning process

The developed system in the educational process monitors and adjusts the learning process at certain points in time.

Suppose that some educational course consists of N topics (Fig. 3), and the level of complexity of the taught material within each of the topics may vary. For simplicity, let's assume that there are only



■ **Fig. 3.** A qualitative illustration of the principle of application of the developed system for monitoring and adjusting the learning process: T_i symbols and circles indicate reference points in time at which testing is performed using the learning control system, while white circles correspond to entrance tests, and gray circles correspond to intermediate ones; a thick line with arrows shows the “educational path” in terms of changes in the complexity of the taught material over time, while the arrows indicate the direction of the change in complexity at reference points in time

three difficulty levels (the dashed horizontal line in Fig. 3 corresponds to the average level), and each topic is two weeks long. Then, a possible effective scenario for using LCS would be testing each student using this system twice during one topic: conducting an entrance test before the beginning of a new topic (white circles in Fig. 3) and an intermediate test in the middle (in this case, a week after the start topics; gray circles in Fig. 3).

As mentioned, entrance testing with the help of LCS allows to objectively determine the current level of a student according to the topics covered by the tests, which makes it possible to choose the most suitable level of complexity of the material planned for teaching. During intermediate testing (in this case, after a week), the difficulty level is adjusted based on the test results. Thus, an “educational trajectory” personalized for a particular student is built in the chosen discipline (see the thick line with arrows in Fig. 3). The described adaptive adjustment of the complexity of the material taught to the student in accordance with its current level is aimed at increasing the efficiency of the educational process and the success of mastering the necessary material.

Let’s take a closer look at the structure of EEE tests. The variable part of the tests should consist of several blocks (usually from three to five), which allows to change the difficulty level from block to block in accordance with the feedback commands and, thus, to implement adaptive adjustment. A set of related tasks can act as a block. Also, the block structure turns out to be convenient for the mandatory part of the test. In this case, for example, one Schulte table or a proof test can act as a block. Moreover, the cognitive characteristics of the student, as well as the success of his solution of tasks, is assessed throughout the block, and not when solving individual tasks. Such averaged characteristics

are more objective and less susceptible to random fluctuations.

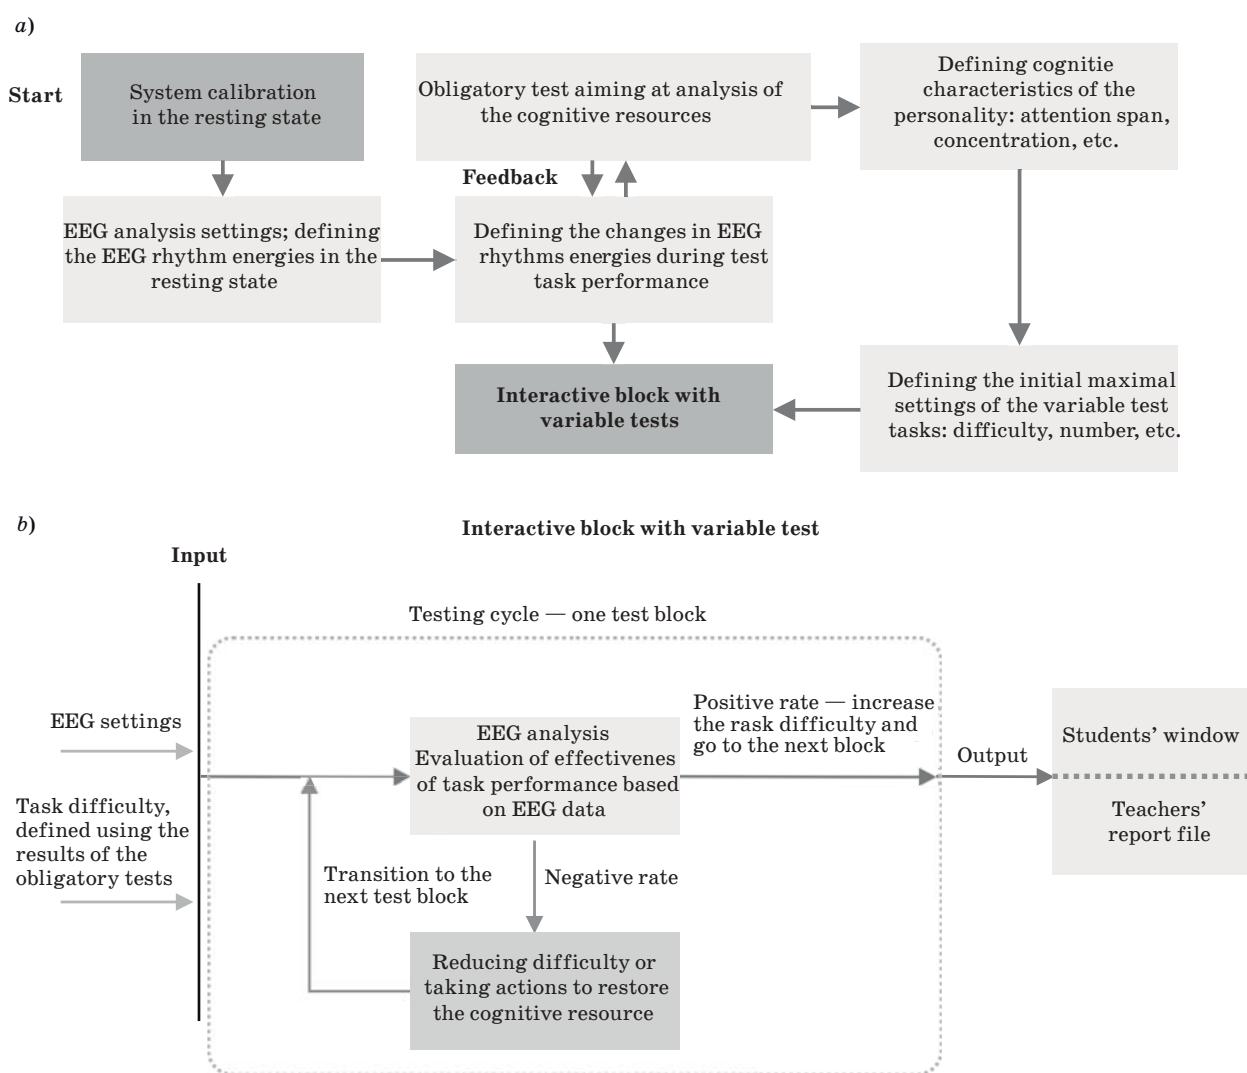
Note that when completing tasks from the first block of the variable part, the difficulty level is selected based on the assessment of the components of the cognitive resource based on the test results for the mandatory part and the difficulty level determined in the previous testing session, if the current test is intermediate. The result of testing for the variable part is an assessment of the level of complexity of the material that will be most appropriate for a given student at a given period of time, taking into account his current training and abilities. Thus, the level of complexity of the taught material is set in accordance with the test results in the period from the next lesson to the next reevaluation, adjusting the level of complexity using the LCS.

For the system to work successfully, it is necessary to foresee in advance the possibility of changing the level of complexity of the taught material for different students, for example, by combining students into different subgroups according to the level of difficulty. Also, blocks of tasks of various difficulty levels must be included in the base of LCS tests.

Note that the number of difficulty levels can be more than three. Also, instead of difficulty, another scale can act, for example, the type of material taught, the strategy of material presentation, etc. Moreover, the scale can consist of several parameters, i. e. be multidimensional.

Algorithm of functioning of the developed system for monitoring and adjusting the learning process

Let us consider in more detail the algorithm underlying the functioning of the developed system for monitoring and adjusting the learning process of a primary school student. Algorithm consists of



■ **Fig. 4.** The algorithm for the functioning of the learning control system: *a* — the preparatory part related to the calibration of the system and passing the required tests; *b* — the main part associated with the passage of tasks from the variable tests

two main parts, preparatory and main, shown in Fig. 4, *a* and *b*, respectively. The first step is to calibrate the system, which consists in assessing the base levels of the basic rhythms of neural activity using EEG data under rest condition. This calibration must be done for every new user; then the calibration information is saved in users' profile. To improve the accuracy of the system, it is necessary to periodically recalibrate it (for example, once in a month) for already registered users. Based on the calibration information, the parameters of the time-frequency analysis of EEG signals are also adjusted.

The next step starts the obligatory part of the test, which is implemented using feedback based on the analysis of changes in the energies of the rhythms of neural activity according to the recorded EEG data. As a result of the test,

the levels of the components of the student's cognitive resource are determined, and on the basis of these data, the initial level of difficulty and other settings of the tasks of the variable part of the test. Then control is transferred to the block with the variable part of the test (see Fig. 4, *b*). Here, the student is asked to solve a number of test tasks, grouped into separate blocks, while the complexity of the tasks varies from block to block in accordance with the principle of feedback implementation (for more details, see subsection "The principle of functioning of the developed system"). As a result, the system generates a summary of the test results, the level of the components of the student's cognitive resource and recommendations on the optimal parameters (for example, the level of difficulty) of the material planned for teaching on the test topic.

Description and testing of the implemented system to control and adjust the learning process

System was implemented with electroencephalograph “ActiCHamp” (Brain Products, Germany), a tablet with a stylus and a laptop as a control computer. EEG signals were recorded from 31 channels using active electrodes “ActiCap” (Brain Products) based on high-quality Ag/AgCl-sensors, while the electrodes were placed using a special cap in accordance with the “10-10” scheme with a ground electrode on the position “Fpz” and one reference electrode in the area of the right mastoid. An abrasive “NuPrep” gel was used to increase the conductivity of the scalp, and the “SuperVisc” conductive gel was applied to the EEG electrodes.

Electroencephalogram recordings were sampled at 250 Hz and filtered with a bandpass filter from 0.016 to 70 Hz and a notch filter at 50 Hz. An illustration of the learning process using developed LCS is shown on Fig. 5.

To interact with the student in the process of passing the tests, an EEE was developed in an interactive form familiar to the child, in which a special fictional character conducts communication with the child (Fig. 6). The type and character of this character were developed in cooperation with psychologists in terms of the best communication with a primary school child.

Working process with EEE consists of three stages:

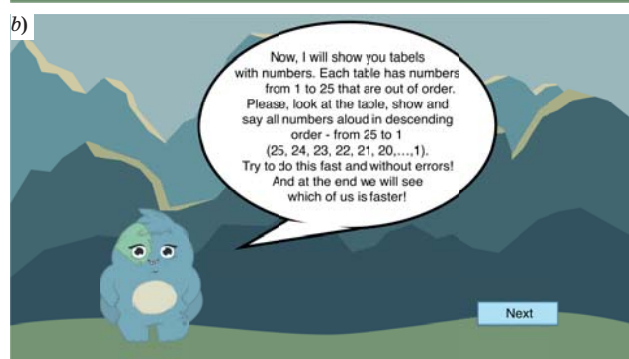


■ Fig. 5. The learning process with the developed system

1) the procedure for calibrating and configuring the system (Fig. 6, a);

2) the obligatory part of the test (in Fig. 6, b and c, the task with the Schulte table is shown as an example);

3) the variable part of the test. In the developed EEE it consists of logic tasks (an example is shown in Fig. 6, d).



c)

1	7	25	11	16
21	23	9	22	4
12	15	3	10	14
5	24	19	20	6
13	17	8	18	2

d) Cheburashka went to school. The teacher put him at the second desk, if you count from the front, and the fourth, if you count from the back. How many desks are there in a row?

5

6

■ Fig. 6. Screenshots of the developed e-learning environment: a — the stage of calibration and tuning of the system; b and c — an example task with a Schulte table from the mandatory part of the test; d — an example of a logical problem from the variable part of the test

The system gives out test results, an assessment of the cognitive resource and individual recommendations for teaching material for the student who passed the tests.

We now consider its functioning when a student completes an assignment with a Schulte table, which is a simplified version of the Zahlen-Verbindungs-Test [40]. The completion of this task allows to determine the effectiveness of the student's work and his ability to work, as well as resistance to external distractions. By default, the Schulte table is a 5×5 matrix with randomly located numbers from 1 to 25. However, its size can be increased or decreased by the system as the student passes the test. By default, the student should select numbers from 25 to 1 in the table in descending order by clicking on them on the tablet. The system registers time intervals Δt_m between two consecutive clicks on adjacent numbers. For example, Δt_1 is the time interval between the moment the task starts and the moment you press the digit "25", Δt_2 is between pressing the non-digit "25" and "24", etc.

The participants in the experiment were 10 schoolchildren aged 7 to 10 years (grades 1–3 of the school). Each student completed $N = 5$ Schulte tables, the execution of 1 table took from 50 to 90 s, we denote the execution time as $t_1, t_2, \dots, \Delta t_N$. Between the tables there was a short break of 10–20 s. As a result, the following individual cognitive characteristics of schoolchildren can be determined:


1. Efficiency of work, which is the arithmetic mean of the execution times of all tables: $W_E = (t_1 + t_2 + \dots + t_N) / N$. It characterizes consistency of attention and productivity.

2. The indicator of working capacity, which is the ratio of the time of execution of the first table to the efficiency of work: $W_U = t_1 / W_E$. $W_U < 1$ indicates good working capacity, otherwise, it indicates that the student needs a longer preparation for the main job.

3. Psychological stability (a person's ability to maintain work activity for a long time) $PS = t_N - 1 / W_E$. If $PS < 1$, then this indicates good psychological stability.

Let's consider the main steps that the developed LCS takes, and the results and conclusions obtained in the process of executing the Schulte table. First, the system analyzes the dependence of the time required for a student to search for each subsequent number on its number: $\Delta t_m(m)$. An example of such a dependence is shown in Fig. 7. Its analysis allows to draw conclusions about the efficiency and speed of execution of a given table.

Second, according to EEG data, the dependencies of the energy values of α - and β -rhythms on the number m , averaged over the corresponding intervals Δt_m : $E_{\alpha, \beta}(m)$, are estimated for each of the 31 channels. Analysis of these dependencies allows




■ Fig. 7. The time Δt_m required for the student to search for each subsequent number on his number m

you to determine the level of concentration on solving the problem when choosing each of the numbers. Thus, an increase in the β -rhythm with a simultaneous decrease in the α -rhythm relative to the activity of the brain in a calm state, recorded during the calibration process, indicates an increase in the level of attention and concentration on solving the problem [41].

However, more objective assessments are given by the values of the energies of the corresponding rhythms averaged over one table (in the general case, one test block). Fig. 8 shows the values of the efficiency of each of the five Schulte tables, which is the inverse to the time spent on its execution ($eff_n = 1/t_n$), and the corresponding ratios of the β - and α -rhythm energies (E_β/E_α) in the temporal brain area, averaged over period of execution of each of the tables. The task consisted of five 5×5 Schulte tables in total. Fig. 8, *a* corresponds to the typical case when LCS is used in the process of completing a task. One can see that for the second table, the effectiveness of solving the assigned task decreases (solid line). This is accompanied by a decrease in the β - and the α -rhythm energies ratio (dashed line), which indicates a decrease in the level of attention and concentration. LCS reveals this feature and, in accordance with the described above algorithm, gives the student a feedback, motivating him to perform the task more attentively. This leads to an increase in the efficiency of the task, starting from the fourth Schulte table. As a result, the efficiency of the last table exceeds the efficiency of the first one.

On the contrary, Fig. 8, *b* corresponds to a situation when LCS is not used in the process of a schoolchild's fulfillment of an assignment. In this case, starting from the fourth table, the efficiency of task performance is significantly reduced, and for the last table it becomes much lower than for the



■ Fig. 8. Efficiency of each of the five Schulte tables (solid line) and the corresponding values E_{β}/E_{α} in the temporal region, averaged over the period of execution of each of the tables (dashed line): a — the characteristic case when the student uses the learning control system; b — the case without the use of the learning control system (for another subject)

first one. This is due to a decrease in the level of attention and concentration of the student on solving the task (see the dependence E_{β}/E_{α} in Fig. 8, b).

Comparing the Fig. 8, a and b, we demonstrate that in case with Schulte tables the LCS increased the efficiency and the stability of the results of the student's performance due to the presence of feedback.

Additionally, the analysis demonstrated that the tendency towards a high β/α -rhythms ratio is most pronounced in the occipital and temporal areas of the brain. Excitation of high-frequency β -activity and a decrease in the α -rhythm in the occipital region indicates an increased load on the visual cortex, while a similar trend in the temporal cortex indicates the activity of the brain associated with learning and processing new information [42, 43].

In conclusion, note that in order to reliably confirm the effectiveness of the proposed system and demonstrate the statistical significance of the differences obtained, it is necessary to conduct its versatile testing on a group of schoolchildren, including various types of tasks and scenarios. The results of such testing will be presented in our subsequent works.

Conclusion

We described in detail the concept and scheme of the developed system for monitoring and adjusting the learning process, as well as the strategy its' application for primary schoolchildren. The functional diagram and the main blocks of the system, the principle and algorithms of its functioning are described. The relationship of the characteristics of EEG signals with the components of the cognitive resource and the implementation of this concept in the LCS system are discussed. The strategy of using the developed system for monitoring and

adjusting the learning process in the educational process is described. A description of a specific implemented system along with an electronic educational environment is given. The results of the first tests of the implemented system are presented when schoolchildren perform a simple task consisting of N Schulte tables. The results of comparing the effectiveness of solving the proposed tasks with and without active LCS system demonstrated using a specific example of the increase in the efficiency of a schoolchild's work when using LCS system. This is a consequence of the influence of feedback and personalization of the testing process, based on the assessment of changes in the energies of the characteristic rhythms of the student's brain activity.

Financial support

This work was supported by the RFBR (grant No. 19-29-14101). Work on the development of algorithms for time-frequency analysis was supported by the grant of the President of the Russian Federation (MD-1921.2020.9).

Reference

1. Basham J. D., Hall T. E., Carter Jr. R. A., Stahl W. M. An operationalized understanding of personalized learning. *Journal of Special Education Technology*, 2016, vol. 31, no. 3, pp. 126–136. doi: 10.1177/0162643416660835
2. Bernacki M. L., Walkington C. The role of situational interest in personalized learning. *Journal of Educational Psychology*, 2018, vol. 110, no. 6, pp. 864. doi:10.1037/edu0000250
3. Kovaleva T. M. New didactic resources for modern school. *Science and school*, 2015, no. 1, pp. 88–94.

4. Pardo A., et al. OnTask: Delivering data-informed, personalized learning support actions. *Journal of Learning Analytics*, 2018, vol. 5, no. 3, pp. 235–249. doi: 10.18608/jla.2018.53.15.
5. Bulger M. Personalized learning: The conversations we're not having. *Data and Society*, 2016, vol. 22, no. 1, pp. 1–29.
6. Vygotsky L. S. *Myshlenie i rech'* [Thinking and Speech]. Moscow, Labirint Publ., 1999. 352 p. (In Russian).
7. Stepanov V. G. *Nejropedagogika. Mozg i effektivnoe razvitie detej i vzroslyh: vozrast, obuchenie, tvorchestvo, proforientaciya* [Neuropedagogy. The brain and the effective development of children and adults: age, education, creativity, career guidance]. Moscow, Akademicheskij proekt Publ., 2020. 345 p. (In Russian).
8. Demetriou A., Kazi S., Spanoudis G., Makris N. Predicting school performance from cognitive ability, self-representation, and personality from primary school to senior high school. *Intelligence*, 2019, vol. 76, September–October, 101381. doi:10.1016/J.Intell.2019.101381
9. Demetriou A., Makris N., Taxmatzidis D., Kazi S., Spanoudis G. Decomposing the influence of mental processes on academic performance. *Intelligence*, 2019, vol. 77, November–December, 101404. doi:10.1016/j.intell.2019.101404
10. Anjolie Diaz, Tashauna L. Blankenship, Martha Ann Bell. Episodic memory in middle childhood: Age, brain electrical activity, and self-reported attention. *Cognitive Development*, 2018, vol. 47, July–September, pp. 63–70. doi:10.1016/j.cogdev.2018.03.003
11. Murat Perit Çakır, Hasan Ayaz, Meltem İzzetoğlu, Patricia A. Shewokis, Kurtuluş İzzetoğlu, Banu Onaral. Bridging brain and educational sciences: An optical brain imaging study of visuospatial reasoning. *Procedia — Social and Behavioral Sciences*, 2011, vol. 29, pp. 300–309. doi:org/10.1016/j.sbspro.2011.11.243
12. Anna A. Matejko, Daniel Ansari. The neural association between arithmetic and basic numerical processing depends on arithmetic problem size and not chronological age. *Developmental Cognitive Neuroscience*, 2019, vol. 37, June, 100653. doi:10.1016/j.dcn.2019.100653
13. Debskaa A., Chyla K., Dzięgiela G., Kacprzakab A., Luniewskaa M., Plewkoa J., Marchewkaa A., Grabowskad A., Jednoroga K. Reading and spelling skills are differentially related to phonological processing: Behavioral and fMRI study. *Developmental Cognitive Neuroscience*, 2019, vol. 39, October, 100683. doi:10.1016/j.dcn.2019.100683
14. Mamedova G. A., Zeynalova L. A., Melikova R. T. Big data technologies in e-learning. *Open Education*, 2017, no. 6, pp. 41–48 (In Russian). doi:10.21686/1818-4243-2017-6-41-48
15. Yawei Cheng, Chen Yi Chen, Jean Decety. An EEG/ERP investigation of the development of empathy in early and middle childhood. *Developmental Cognitive Neuroscience*, 2014, vol. 10, October, pp. 160–169. doi:10.1016/j.dcn.2014.08.012
16. Jiahui Xu, Baichang Zhong. Review on portable EEG technology in educational research. *Computers in Human Behavior*, 2018, vol. 81, April, pp. 340–349. doi:10.1016/j.chb.2017.12.037
17. Maksimenko V. A., Kurkin S. A., Pitsik E. N., Musatov V. Y., Runnova A. E., Efremova T. Y., Hramov A. E., Pisarchik A. N. Artificial neural network classification of motor-related EEG: An increase in classification accuracy by reducing signal complexity. *Complexity*, 2018, vol. 2018, 9385947. doi:10.1155/2018/9385947
18. Hramov A. E., Maksimenko V. A., Koronovskii A., Runnova A. E., Zhuravlev M., Pisarchik A. N., Kurths J. Percept-related EEG classification using machine learning approach and features of functional brain connectivity. *Chaos*, 2019, vol. 29, 093110. doi:10.1063/1.5113844
19. Gonzalez-Garrido A., Gomez-Velazquez F. R., Salido-Ruiz R. A., Espinoza-Valdez A., Velez-Perez H., Romo-Vazquez R., Gallardo-Moreno G. B., Ruiz-Stovel V. D., Martínez-Ramos A., Berumen G. The analysis of EEG coherence reflects middle childhood differences in mathematical achievement. *Brain and Cognition*, 2018, vol. 124, July, pp. 57–63. doi:10.1016/j.bandc.2018.04.006
20. Jun-Su Kang, Amitash Ojha, Giyoung Lee, Minho Lee. Difference in brain activation patterns of individuals with high and low intelligence in linguistic and visuo-spatial tasks: An EEG study. *Intelligence*, 2017, vol. 61, March–April, pp. 47–55. doi:10.1016/j.intell.2017.01.002
21. Fries P. Rhythms for cognition: communication through coherence. *Neuron*, 2015, vol. 88, no. 1, pp. 220–235. doi:10.1016/j.neuron.2015.09.034
22. Chholak P., Niso G., Maksimenko V. A., Kurkin S. A., Frolov N. S., Pitsik E. N., Hramov E. A., Pisarchik A. N. Visual and kinesthetic modes affect motor imagery classification in untrained subjects. *Scientific Reports* 9, 2019, 9838. doi:10.1038/s41598-019-46310-9
23. Marrufo V., Vaquero E., Cardoso M. J., Gómez C. M. Temporal evolution of α and β bands during visual spatial attention. *Cognitive Brain Research*, 2001, vol. 12, no. 2, pp. 315–320. doi:10.1016/s0926-6410(01)00025-8
24. Clayton M. S., Yeung N., Kadosh R. C. The roles of cortical oscillations in sustained attention. *Trends in Cognitive Sciences*, 2015, vol. 19, no. 4, pp. 188–195. doi:10.1016/j.tics.2015.02.004
25. Khorev V. S., Maksimenko V. A., Pitsik 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

26. Kurkin S. A., Pitsik E. N., Hramov A. E. Classifying electrical activity of the brain during imaginary movements of untrained subjects using artificial neural networks. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2019, no. 6, pp. 77–84 (In Russian). doi:10.31799/1684-8853-2019-6-77-84
27. Carp J., Compton R. J. Alpha power is influenced by performance errors. *Psychophysiology*, 2009, vol. 46, no. 2, pp. 336–343. doi:10.1111/j.1469-986.2008.00773.x
28. Mazaheri A., Nieuwenhuis I. L., van Dijk H., Jensen O. Prestimulus alpha and mu activity predicts failure to inhibit motor responses. *Human Brain Mapping*, 2009, vol. 30, no. 6, pp. 1791–1800. doi:10.1002/hbm.20763
29. Klimesch W. Alpha-band oscillations, attention, and controlled access to stored information. *Trends in Cognitive Sciences*, 2012, vol. 16, no. 12, pp. 606–617. <https://doi.org/10.1016/j.tics.2012.10.007>
30. Novikov N. A., Bryzgalov D. V., Chernyshev B. V. Theta and alpha band modulations reflect error-related adjustments in the auditory condensation task. *Frontiers in Human Neuroscience*, 2015, vol. 9, p. 673. doi:10.3389/fnhum.2015.00673
31. Maksimenko V. A., Runnova A. E., Zhuravlev M. O., Makarov V. V., Nedayvozov V., Grubov V. V., Pchelintceva 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, no. 12. <https://doi.org/10.1371/journal.pone.0188700>
32. Stam C. J. Brain dynamics in theta and alpha frequency bands and working memory performance in humans. *Neuroscience Letters*, 2000, vol. 286, no. 2, pp. 115–118. doi:10.1016/S0304-3940(00)01109-5
33. Sacchet M. D., LaPlante R. A., Wan Q., Pritchett D. L., Lee A. K., Hämäläinen M., Moore C. I., Kerr C. E., Jones S. R. Attention drives synchronization of alpha and beta rhythms between right inferior frontal and primary sensory neocortex. *Journal of Neuroscience*, 2015, vol. 35, no. 5, pp. 2074–2082. doi:10.1523/JNEUROSCI.1292-14.2015
34. Roslan N. S., et al. Review of EEG and ERP studies of extraversion personality for baseline and cognitive tasks. *Personality and Individual Differences*, 2017, vol. 119, pp. 323–332. doi:10.1371/journal.pone.0219839
35. Hramov A. E., Koronovskii A. A., Makarov V. A., Pavlov A. N., Sitnikova E. *Wavelets in Neuroscience*. Springer Berlin Heidelberg, 2015. 318 p. <https://doi.org/10.1007/978-3-662-43850-3>
36. Maksimenko V. A., Runnova A. E., Kulanin R. A., Protasov P. A., Zhuravlev M. O., Chholak P., Pisarchik A. N., Hramov A. E. Algorithm for automatic estimation of human brain activity features during mental task evaluation. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2018, no. 5, pp. 104–111. doi:10.31799/1684-8853-2018-5-104-111
37. Maksimenko V. A., Runnova A. E., Zhuravlev M. O., Protasov P., Kulanin R., Khramova M. V., Pisarchik A. N., Hramov A. E. Human personality reflects spatio-temporal and time-frequency EEG structure. *PloS One*, 2018, vol. 13, no. 9. <https://doi.org/10.1371/journal.pone.0197642>
38. Badarin A. A., Runnova A. E., Karavaev A. S., Zhuravlev M. P., Astahov S. V., Hramov A. E. *Ustrojstvo dlya opredeleniya v rezhime real'nogo vremeni stepeni koncentracii vnimaniya operatora pri vospriyatii i obrabotke informacii*. [The device for real-time detection of operators' concentration level during the perception and processing of information]. Patent for invention № 2704562, 2019.
39. Maksimenko V. A., Nedaivozov V. O., Hramov A. E. *Ocenka koncentracii vnimaniya cheloveka po dannym EEG-izmerenij*. [Evaluation of human attention using EEG]. Certification of official registration of computer program № 2019661003, 2019.
40. Vernon P. A. Der Zahlen-Verbindungs-Test and other trail-making correlates of general intelligence. *Personality and Individual Differences*, 1993, vol. 14, no. 1, pp. 35–40.
41. Grubov V. V., Maksimenko V. A., Kurkin S. A., Khramova M. V., Hramov A. E. Maintaining attention state of children during cognitive load. *Proc. SPIE 11459, Saratov Fall Meeting 2019: Computations and Data Analysis: from Nanoscale Tools to Brain Functions*, 114590A. doi:10.1117/12.2564349.
42. Papanicolaou A. C., Loring D. W., Deutsch G., Eisenberg H. M. Task-related EEG asymmetries: a comparison of alpha blocking and beta enhancement. *International Journal of Neuroscience*, 1986, vol. 30, no. 1-2, pp. 81–85. doi:10.3109/00207458608985658
43. Morozova L. V., Zvyagina N. V., Terebova N. N. Characteristics of visual perception in seven-year-old children differing in functional maturity of brain structures. *Human Physiology*, 2008, vol. 34, no. 1, pp. 14–21. doi:10.1134/S0362119708010027

УДК 004.032.2

doi:10.31799/1684-8853-2020-5-50-61

Система для контроля и корректировки процесса обучения младших школьников на базе анализа данных ЭЭГС. А. Куркин^а, доктор физ.-мат. наук, профессор, orcid.org/0000-0002-3438-5717, kurkinsa@gmail.comВ. В. Грубов^а, канд. физ.-мат. наук, старший научный сотрудник, orcid.org/0000-0003-2491-2592В. А. Максименко^а, канд. физ.-мат. наук, старший научный сотрудник, orcid.org/0000-0002-4632-6896Е. Н. Пидик^а, младший научный сотрудник, orcid.org/0000-0003-1850-2394М. В. Храмова^б, канд. пед. наук, доцент, orcid.org/0000-0002-6392-4580А. Е. Храмов^а, доктор физ.-мат. наук, профессор, orcid.org/0000-0003-2787-2530^аУниверситет Иннополис, Университетская ул., 1, Иннополис, 420500, РФ^бСаратовский национальный исследовательский государственный университет им. Н. Г. Чернышевского, Астраханская ул., 83, Саратов, 410012, РФ

Введение: контроль процесса обучения обычно подразумевает анализ развития высших психических функций обучающегося: воображения, памяти, мышления, внимания и др. В настоящее время открываются широкие возможности объективного контроля и оценки данных характеристик благодаря достижениям современной нейронауки. Персонализация становится возможной на основе анализа личностных характеристик обучаемых. Особенно перспективными представляются подходы с использованием электроэнцефалографии. Одним из главных барьеров, препятствующих широкому внедрению ЭЭГ-систем в школьный образовательный процесс, является отсутствие готовых решений таких систем для применения в ходе обучения школьников, а также сценариев их приложения. **Цель:** разработка и тестирование системы для контроля и корректировки процесса обучения, а также стратегии ее использования для школьников младших классов. **Методы:** ЭЭГ-анализ, вейвлет-анализ регистрируемых многоканальных ЭЭГ-данных, анализ изменений энергий характерных ритмов нейронной активности головного мозга, а также реализуемая системой обратная связь. **Результаты:** детально описана концепция и схема разработанной системы для контроля и корректировки процесса обучения, стратегия ее использования для школьников младших классов. Продемонстрировано существенное повышение эффективности работы школьников при применении разработанной системы, что является следствием влияния обратной связи и персонализации процесса тестирования и обучения, базирующихся на оценке изменения энергий характерных ритмов мозговой активности школьника. **Практическая значимость:** использование ЭЭГ-систем для объективного анализа личностных характеристик обучаемых и персонализации процесса обучения путем реализации обратной связи на основании получаемых данных существенно повысит в перспективе качество образовательного процесса и эффективность усвоения нового материала.

Ключевые слова — персонализированное обучение, ЭЭГ, младшие школьники, интерфейс мозг-компьютер, контроль процесса обучения, электроэнцефалография, анализ сигналов ЭЭГ, мозговая активность, нейронная активность.

Для цитирования: Kurkin S. A., Grubov V. V., Maksimenko V. A., Pitsik E. N., Khramova M. V., Hramov A. E. System for monitoring and adjusting the learning process of primary schoolchildren based on the EEG data analysis. *Информационно-управляющие системы*, 2020, № 5, с. 50–61. doi:10.31799/1684-8853-2020-5-50-61

For citation: Kurkin S. A., Grubov V. V., Maksimenko V. A., Pitsik E. N., Khramova M. V., Hramov A. E. System for monitoring and adjusting the learning process of primary schoolchildren based on the EEG data analysis. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 50–61. doi:10.31799/1684-8853-2020-5-50-61

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.

UDC 681.3:612.8

doi:10.31799/1684-8853-2020-5-62-69

Method of automatic search for odor-induced patterns in bioelectric activity of a rat olfactory bulb

I. V. Shcherban^a, Dr. Sc., Tech., Professor, orcid.org/0000-0002-3997-9151, shcheri@mail.ru

P. O. Kosenko^a, PhD, Biol., orcid.org/0000-0002-4333-5332

O. G. Shcherban^a, PhD, Tech., Associate Professor, orcid.org/0000-0001-5139-8520

P. V. Lobzenko^b, PhD, Tech., Associate Professor, orcid.org/0000-0002-5293-0109

^aSouthern Federal University, 105/42, B. Sadovaya St., 344006, Rostov-on-Don, Russian Federation

^bMoscow Technical University of Communications and Informatics, 32, Narodnogo Opolcheniya St., 123423, Moscow, Russian Federation

Introduction: The olfactory system in chronic animal experiments is studied according to the records of bioelectric activity recorded with microelectrode arrays located on the dorsal surface of the olfactory bulb. It is believed that the response of the olfactory bulb bioelectric activity to the odorant presentation is associated with fluctuations synchronized by respiration and belonging to the range of so-called gamma rhythms. **Purpose:** To develop a method of automatic search for time boundaries of odor-induced gamma rhythm patterns in the bioelectric activity of an olfactory bulb. **Results:** The complexity of automatic search for odor-induced patterns are due to masking them by spontaneous oscillations of gamma rhythms unrelated to the olfactory system activity. Besides, the modal frequency of the patterns is a priori unknown and changes dynamically during an experiment on an anesthetized animal. The Hausdorff distance is used as a cost function of the search. In order to increase its sensitivity, an adaptive band-pass filter was synthesized based on a multichannel singular spectrum analysis. Its passband in the analyzed time sample corresponds best to the spectrum of the required patterns. The results of experiments on rats are presented. The use of band-pass filters based on the Fourier transform with parameters unchanged during the experiment due to the non-stationary nature of the frequency characteristics of the desired patterns does not ensure their effective search. In particular, when using the Butterworth band-pass filter in the search algorithm, significant errors were observed in determining the time boundaries of the epochs of patterns, and omissions of patterns. But the use of a synthesized adaptive band-pass filter provided reliable automatic search for patterns and determination of their time boundaries with a high accuracy. Algorithm failures in this case were observed only in rat motion artifacts. **Practical relevance:** The developed method extends the existing tools used to study the olfactory system of a living organism.

Keywords – olfactory bulb, bioelectric activity, odor-induced patterns, Hausdorff distance, multichannel singular spectrum analysis.

For citation: Shcherban I. V., Kosenko P. O., Shcherban O. G., Lobzenko P. V. Method of automatic search for odor-induced patterns in bioelectric activity of a rat olfactory bulb. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 62–69. doi:10.31799/1684-8853-2020-5-62-69

Introduction

Experimental studies of the olfactory system in chronic animal experiments presume the analysis of multidimensional time records of bioelectric activity (BEA) of the olfactory bulb (OB), recorded with microelectrode arrays. The observed BEA reflects the averaged aggregates of synaptic, neuronal, and axonal activities of neuron groups which represent the functioning of the neural network in the volume of tissue [1, 2]. The difficulties of the research in this case are mainly due to the fact that the applicability of the event-related potentials (ERPs), a well-proven method in studying other sensory systems, is fundamentally limited here. Classically, the ERPs method is based on a dogma that there is a certain synchronizing factor, a stimulus label. In experimental studies of the somatosensory, visual or auditory system of a living organism, the time moments of their external influences are known quite accurately. This allows us to reasonably summarize a large number of EEG fragments which

immediately follow the presentation of a stimulus, reflecting a weak BEA response from the organism. Thus, averaging the selected epochs by their implementations makes it possible to pick out ERPs components in the EEG against the background of other oscillations unrelated to the BEA response of the sensory system under study.

In the olfactory system, the main synchronizing factor is the moment of inhalation. Normally, respiration is characterized by variability in frequency and depth of inhaling [3]. Respiratory activity patterns affect the temporal structure of the sensory input and subsequent processing in the brain [4], amplifying the modulation of the incoming sensory signals [5]. Such variability, especially taking into account the weak reaction of the olfactory system to a low concentration of odorants makes it impossible to accurately determine the initial moment of the organism's reaction and, thus, to perform multiple summation of the response ERPs. Besides, the latency (duration) of a reaction to the presentation of odorants in the BEA structures of an OB is still unclear; this reaction is

determined both by changes in the air concentration of the odorant and by the adaptation of the olfactory system to the presented odorant at different levels of its organization, or by other reasons.

The activation mechanisms and information coding principles used in the olfactory system are not fully understood yet, unlike the other sensory systems. At present, it is generally accepted that an OB, when an odorant is presented, produces a BEA response associated with fast gamma oscillations synchronized with the respiration and related to the frequency range 30–150 Hz [1, 2, 6]. The difficulties in the automatic search for epochs containing such odor-induced gamma rhythm patterns are caused by the following reasons. The activity pattern has a narrow-band spectrum within 30–150 Hz, and at certain moments of observation the spectrum width can be only 20–35 Hz. Moreover, its modal frequency is not only a priori unknown; it is also not constant, dynamically changing during the experiment, in particular, on an anesthetized animal. The pattern duration is 20–25% of the respiration period, falling on the final phase of the inhalation, and the amplitude is only 10–30% of the recorded BEA record amplitude. Thus, odor-induced patterns are masked by other rhythms of a close frequency range which have a significantly higher amplitude, and by spontaneous gamma oscillations of a strong intensity with close frequency spectra.

The existing approaches to solve similar problems of search and time-axis localization of a priori undefined structures of unknown frequency oscillators are well developed. For example, there is a widely used technique which, through windowed Fourier transform, or through discrete or continuous wavelet transforms, turns a temporal representation into a time-frequency one, and runs a search based on various entropy criterion functions. Such methods were used in the problems of identifying the effects of alcohol on EEG [7], assessing cardiac rhythm irregularities by ECG [8], diagnosing epilepsy [9], and others.

However, it is the temporal non-stationarity in the frequency characteristics of gamma rhythm patterns that makes it impossible to use many of the existing approaches for their search. For example, the authors of [10, 11] discuss methods which allow you to detect low-intensity gamma oscillations in EEG when their frequency spectra are also unknown and close to the characteristics of the noise components. But the additional criterion functions introduced here in order to select the frequency range most suitable to the spectrum of the sought patterns can be used only if the frequency characteristics of the patterns are stationary over the observation interval.

Therefore, in order to expand the available tools for studying the olfactory system by a recorded

BEA, we need a method of automatic search for the time boundaries of odor-induced gamma rhythm patterns.

Formalization of the problem

Using the microelectrode array on the dorsal surface of an OB, at time moments $t \in [t_0; T]$ we record a multidimensional time series of BEA $\mathbf{S}(t) = (S_1(t), S_2(t), \dots, S_J(t))^T$, where t_0 is the initial moment equal to zero by default; T is the current sampling interval; J is the number of electrodes in array; and T is a transpose operator. Thus, for a sampling interval T at each j^{th} ($j = \overline{1, J}$) channel of array, the observed BEA can be presented as a one-dimensional time series $S_j(T) = \{s_{j,k}\}_{k=1}^K$ as large as $K = T/\Delta t$ numbers, where Δt is the discretization interval. At short time intervals significantly smaller than the sampling interval T , the presence of periodic odor-induced BEA is assumed, manifested in the form of low-amplitude patterns. The frequency spectrum of the narrow-band patterns is unknown beforehand; it refers to the range of 30–150 Hz, changing dynamically during the experiment. The problem is to find temporal epochs in the recorded signal which would contain such patterns.

Synthesis of an adaptive narrow-band band-pass filter

To solve the problem, it is reasonable to use the traditional approach when the search is performed within a certain sliding time window, much smaller than the sampling interval T . The criterion function for that should reflect the presence or absence of the desired gamma rhythm patterns in the current window. Apparently, ensuring a sufficient sensitivity of such a function when searching for low-amplitude patterns is possible on the basis of preliminary filtering of multidimensional BEA records in order to select the frequency range of interest. Experimental studies have shown that due to the presence of noise in the BEA records with frequency spectra close to the spectra of the sought patterns, the use of band-pass filters (BPF) with a priori specified parameters does not ensure that the criteria search functions are sensitive enough. In the multidimensional signal $\mathbf{S}(t)$, we need to pick out a narrow frequency range which would most closely match the spectrum of the sought patterns. Besides, it should be taken into account that the synthesized BPF must be adaptable to temporary fluctuations in the frequency characteristics of the sought patterns.

In order to synthesize a BPF that meets the formulated requirements, it is a good idea to apply

the technique of Singular Spectrum Analysis of time series (SSA), also called “Caterpillar” in its Russian version [12–14] or, in the multidimensional case, MSSA (Multichannel SSA). It allows you to synthesize a set of one low-frequency filter (LFF) and $(M - 1)$ linear BPFs. After applying the MSSA technique at a sampling interval T (see Appendix), we can use a set of M filters to split a multidimensional record $\mathbf{S}(T)$ into M time series, so-called reconstructed components (RCs), of the same dimension $J \times N_k$ as the original record \mathbf{S} has:

$$\begin{aligned}\tilde{\mathbf{S}}_1(T) &= (\tilde{S}_{1,1} \quad \tilde{S}_{2,1} \quad \dots \quad \tilde{S}_{J,1})^T, \dots, \\ \tilde{\mathbf{S}}_M(T) &= (\tilde{S}_{1,M} \quad \tilde{S}_{2,M} \quad \dots \quad \tilde{S}_{J,M})^T.\end{aligned}\quad (1)$$

The frequency spectra $\Delta F_1, \dots, \Delta F_M$ of the RCs (1) are sorted in ascending order, and the upper boundaries of the spectra satisfy the inequality $f_1^B \leq f_2^B \leq \dots \leq f_M^B$, where $f_M^B = 0,5f_s$; $f_s = 1/\Delta t$ is the sampling frequency. The sum of the narrow-band RCs is the initial multidimensional time series

$$\tilde{\mathbf{S}}_1(T) + \tilde{\mathbf{S}}_2(T) + \dots + \tilde{\mathbf{S}}_M(T) = \mathbf{S}(T).\quad (2)$$

Varying the number of filters M leads to changes in their passbands. The frequency spectra $\Delta F_1, \dots, \Delta F_M$ of the RCs change in a similar way (1). Therefore, when varying M based on the features of the signal under study and selecting the required RCs (1), we can separate the harmonic components, even those which intersect in the time-frequency space [15–18].

In order to simplify the synthesis of the required BPF, let us restore the narrow-band signal by just one multidimensional reconstructed component $\tilde{\mathbf{S}}_m(T)$ ($m = \overline{1, M}$) from (1). In [12, 17, 18] it is shown that the number M can be constrained by an upper limit $M_{\max} \leq 0,5N_k$. Since it is known that the largest possible width of the sought patterns cannot exceed 35 Hz, we also can find a lower limit M_{\min} . The following reasoning will help us reach our goal.

It is known that MJ counts of the eigenvector V_m of the averaged sample correlation matrix \mathbf{C} (A.2) formed from the trajectory matrix $\mathbf{X}(T)$ (A.1) for $\mathbf{S}(T)$ are MJ counts of the impulse response function h_m of the non-recursive m^{th} ($m = \overline{1, M}$) filter [13]. The frequency response H_m is a Fourier transform of the impulse response function $H_m(e^{j2\pi f'}) = \sum_{n=0}^{MJ-1} h_{m,n} e^{-j2\pi f'n}$, where $f' \in [0; 0,5]$ is a reduced frequency, and the frequency response of this m^{th} filter is a function of the number of filters M used in the MSSA:

$$A_m = \left| H_m(e^{j2\pi f'}) \right| = A_m(f', M).\quad (3)$$

Since for a given M the width of the effective passband $\Delta F_m(M) = f_m^u - f_m^l$ is the same for all the BPFs [12–14], where f_m^u and f_m^l are the upper and lower cut-off frequencies of the frequency response (3), the value of M_{\min} can be found from the condition

$$M_{\min} = \arg \max_M \{ \Delta F_m(M) \leq 35 \}.$$

With the reduced frequency step $f' = 1/f_s$ chosen in (3), we can calculate the values of the frequency response $A_m(f, M)$ in the actual frequency range $f \in [0; 0,5f_s]$ with 1 Hz resolution. Thus, when M is selected in the range $M_{\min} \leq M \leq M_{\max}$, the effective passband width of each BPF will approximately correspond to the a priori known width of the gamma activity pattern spectrum.

Due to the fact that the components $S_1(T), \dots, S_J(T)$ of a multidimensional BEA $\mathbf{S}(T)$ measured on a living organism on J channels in array at the same time moments are produced by the same physiological process, it would be permissible to average the corresponding counts of the power spectrum (PS) for the channels in the frequency range of interest:

$$\mathbf{P}(f) = \frac{1}{J} \sum_{j=1}^J P_j(f); \quad f \in [30; 150] \text{ Hz},\quad (4)$$

where $P_j(f)$ are PS values of a one-dimensional signal $\{s_{j,k}\}_{k=1}^K$ for each count of frequency f . It should be noted that averaging over J channels of the similar on time k^{th} counts of the components $\{s_{j,k}\}_{k=1}^K$ with the subsequent calculation of the PS function is incorrect since, as we know, some of the J one-dimensional time series of the BEA can be recorded inverted.

Frequency responses of the BPF (3) have a Gaussian shape [13]. Apparently, for an adaptive BPF, the frequency f_m^{\max} corresponding to the maximum of its frequency response A_m^{\max} at every moment of the observation should be close to the current modal frequency $f_\gamma^{\max} = \arg \max_f \{ \mathbf{P}(f); 30 \leq f \leq 150 \}$

of the sought gamma activity pattern. Hence, the characteristics of the required m^{th} BPF should be such that the averaged PS function

$$\tilde{\mathbf{P}}_m(f) = \frac{1}{J} \sum_{j=1}^J \tilde{P}_{m,j}(f)\quad (5)$$

of the RC $\tilde{\mathbf{S}}_m(T)$ comes nearest to the PS function $\mathbf{P}(f)$ (4), where $f \in [30; 150]$ Hz.

Based on the presented reasoning, we can make a final conclusion that if the optimal values of M_{opt} and m_{opt} should be chosen from the condition

$$\min_{M_{\min} \leq M \leq M_{\max}} \left\{ \sum_{30 \leq f \leq 150} [\mathbf{P}(f) - \tilde{\mathbf{P}}_m(f, M)]^2 \right\};$$

$$f_m^{\max} \rightarrow f_\gamma^{\max}, \quad (6)$$

then the spectrum of the BPF output signal $\tilde{\mathbf{S}}_m(T)$ most closely matches the spectrum of the sought gamma activity patterns.

Criterion function and algorithm of search for gamma activity epochs

Within the reconstructed narrow-band component $\tilde{\mathbf{S}}_m(T)$, the search for epochs with gamma activity patterns can be based on the comparison of two adjacent non-overlapping time samples N and $N + 1$ (where $N = 1, 2, \dots, K/n$ is the sample number), equal in volume and each containing $n \ll K$ similar on time counts $\left\{ (\tilde{s}_m)_{j,k} \right\}_{k=(N-1) \times n}^{N \times n}$ and $\left\{ (\tilde{s}_m)_{j,k} \right\}_{k=N \times n}^{(N+1) \times n}$ from each j^{th} channel. If a pattern is present in any of these samples, this fact should be reflected by a corresponding criterion function. Thus, with the resolution of n counts, you can determine the time boundaries of a pattern beginning or end. The choice of a criterion function is determined by the choice of a metric. For example, Hausdorff distance (HD) d_H [19–21] is used quite efficiently for the purposes of this kind. We will use this metric here.

The algorithm for search and time-axis localization of epochs containing low-amplitude narrow-band BEA patterns will finally be as follows.

1. On the sampling interval T with a sampling frequency f_s on J channel in array, we observe BEA

$$\mathbf{S}(T) = \left(\left\{ s_{1,k} \right\}_{k=1}^K \quad \left\{ s_{2,k} \right\}_{k=1}^K \quad \dots \quad \left\{ s_{J,k} \right\}_{k=1}^K \right)^T, \text{ which}$$

is a multivariate time series of the dimension $J \times K$. The interval T is chosen to satisfy the hypothesis that the frequency characteristics of the sought patterns are stationary. Then we calculate the current modal frequency $f_\gamma^{\max}(T)$ of the gamma activity pattern.

2. With MSSA technique and a solution of the optimization problem (6), from the original record we extract a narrow-band signal $\tilde{\mathbf{S}}_m(T)$ of the same dimension $J \times K$ counts, whose spectrum most closely matches the spectrum of the sought patterns.

3. The multidimensional series $\tilde{\mathbf{S}}_m(T)$ is divided into K/n non-overlapping time samples of the same dimensions $J \times n$, and for all the adjacent time samples the Hausdorff distance d_H is calculated. The size $n \ll K$ of the sliding time window is chosen so that the a priori known duration of the gamma ac-

tivity pattern is guaranteed to exceed the value of $n\Delta t$. Then, if any of the adjacent samples contains an initial or final pattern border, the criterion function d_H will have a local maximum.

4. Next, the subsequent K measurements of the BEA $\mathbf{S}(T)$ are accumulated on the same interval T , and the algorithm is repeated.

Experiments on rats

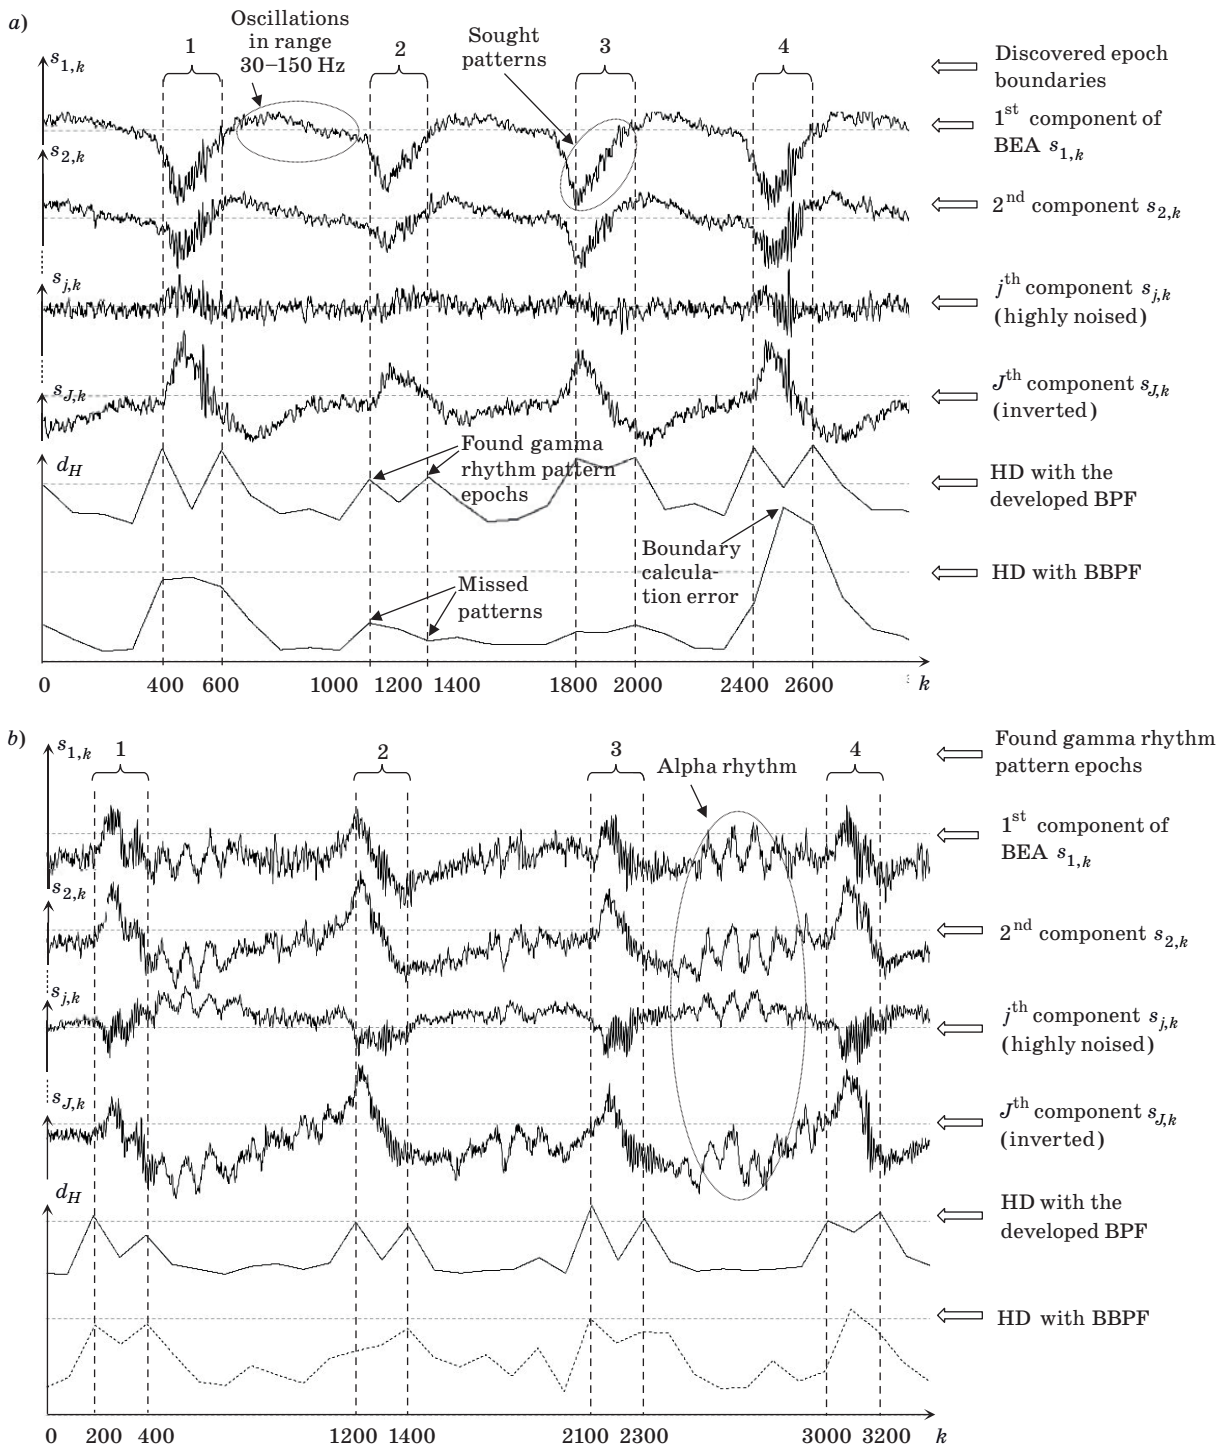
The experiments are carried out on sexually mature adult rats about 10 months old and 300–400 g of weight, under xylazine-zoletil anesthesia at the rate of 0.6 and 30 mg/kg respectively. 10–14 days before the experiment, in the course of a surgical operation, $J = 16$ microelectrodes are implanted into their olfactory analyzer structures. The microelectrodes are made of glass-insulated tungsten alloy with a tip diameter of about 5 μm and resistance 0.5 M Ω . The BEA is recorded with respect to two reference electrodes which are microscrews in the skull bones. The microelectrode matrix is fixed with six 0.7 mm bolts screwed into the skull bones.

The experiments are started after a complete postoperative rehabilitation of the animal. Under anesthesia, it is placed in a shielding chamber eliminating background electromagnetic interference. The BEA is recorded by a 32-channel MAP (Multichannel Acquisition Processor) from *Plexon Inc.* with a recording frequency of 10 KHz. After that, the records are decimated by a factor of 10 to the sampling frequency $f_s = 1$ KHz. The duration of the experiment is about 2 hours, during which the 16-channel BEA is continuously recorded. Olfactory stimuli are given by spraying various odorants at the animal's nose. After the experiments are completed, the animal is carried back to the vivarium for recovery.

Two time samples of BEA were obtained during the same experiment but at its different stages and their fragments for some of the $J = 16$ channels are shown in Fig. 1, *a* and *b*. Each time sample contains 4 patterns associated with the activity of the olfactory system structures. The graphs of d_H search functions calculated using the developed BPF or using the Butterworth BPF (BBPF) for the both time samples of BEA are shown at the same figures. The interval for analysis and the sliding time window size are chosen equal to $T = 6$ s, $n = 100$ ms.

Results and conclusions

Figure 1 shows that the sought patterns are masked by spontaneous oscillations of the gamma rhythm range and by high-amplitude alpha and beta rhythms similar in their frequency spectra and



■ **Fig. 1.** Two time samples (a) and (b) of the bioelectric activity of an olfactory bulb and Hausdorff distances using BPF and BBPF calculated for the both samples

unrelated to the olfactory system activity. These facts, as well as the inversion of the multichannel BEA signal in some channels, explain the low sensitivity of the search function.

The research has confirmed that the use of band-pass filters with parameters unchanged during the experiment does not provide an effective search,

because the frequency characteristics of the sought patterns are non-stationary in time. For example, in Fig. 1 (the graphs "HD with BBPF") you can see that when the BBPF is used in the search algorithm, there are gaps in patterns, and errors in determining the epoch boundaries. BBPF parameters (its order and cut-off frequencies) were chosen in the

beginning of the experiment. The “best on average” BBPF in the experiment under discussion, using which the time boundaries of the gamma rhythm patterns were found with the least number of errors, had an order 6 with cut-off frequencies 50 and 120 Hz.

For the two samples of the original BEA shown in Fig. 1, *a* and *b* we calculated PS function $P(f)$. In Fig. 2, *a* the solid line shows the graph of PS function calculated for the time sample of the BEA from Fig. 1, *a* and in Fig. 2, *b* the solid line shows the graph of the same PS function calculated for the time sample of the BEA from Fig. 1, *b*. The graphs show the PS components caused by the above-mentioned spontaneous gamma rhythms which are not associated with the olfactory system activity. It can also be seen how much, during the same experiment, the modal frequencies $f_{\gamma}^{\max}(T)$ of odor-induced patterns differ, equal to 106 and 83 Hz respectively for the considered time samples.

On the other hand, the use of a developed adaptive BPF provides a reliable automatic search for odor-induced patterns (see, for example, the graphs “HD with the developed BPF” in Fig. 1). The time boundaries of the gamma rhythm epochs are determined with an accuracy not worse than $0.5n\Delta t$. Algorithm failures in the experiments are observed only in cases of motor artifacts, which significantly distort the BEA records and are usually excluded from the analysis.

The obtained effect can be explained by the fact that a developed BPF provides filtering of $S(T)$ so that the output signal $\tilde{S}_m(T)$ has a spectrum on the analyzed time sample which most closely matches the current spectrum of the sought patterns. In Fig. 2, *a* the dotted line shows the graphs of PS function $\tilde{P}_m(f)$ calculated for the BEA from Fig. 1, *a* and in Fig. 2, *b* the dotted line shows the graphs of the same function calculated for the BEA from Fig. 1, *b*. You can see that the developed BPF adjusts itself to the current spectrum of odor-induced patterns and excludes the signal components unre-

lated to the olfactory system activity. Due to this, the search function has the required sensitivity.

A final conclusion can be drawn that the developed method provides a reliable real-time automatic search for the time boundaries of odor-induced patterns in a recorded BEA of an OB. The method can be used in the studies of information coding in an animal’s olfactory system.

Appendix. MSSA algorithm

1. By a measured multidimensional time series $\mathbf{S} = \left(\{s_{1,k}\}_{k=1}^{N_k} \quad \{s_{2,k}\}_{k=1}^{N_k} \quad \dots \quad \{s_{J,k}\}_{k=1}^{N_k} \right)^T$ of the dimension $\dim(\mathbf{S}) = J \times N_k$, you build a block trajectory matrix

$$\mathbf{X} = (\mathbf{X}_1 \mid \mathbf{X}_2 \mid \dots \mid \mathbf{X}_j \mid \dots \mid \mathbf{X}_J), \quad (\text{A.1})$$

where

$$\mathbf{X}_j = \begin{pmatrix} s_{j,1} & s_{j,2} & \dots & s_{j,k} & \dots & s_{j,K} \\ s_{j,2} & s_{j,3} & \dots & s_{j,k+1} & \dots & s_{j,K+1} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ s_{j,M} & s_{j,M+1} & \dots & s_{j,M+k} & \dots & s_{j,N_k} \end{pmatrix}$$

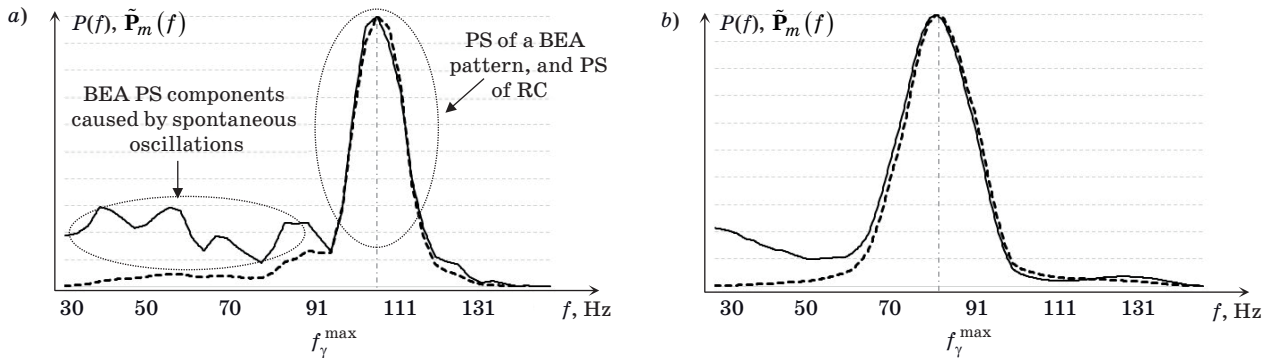
is a Hankel matrix of the dimension $\dim(\mathbf{X}_j) = M \times K$, built for each j^{th} component separately; M is the caterpillar length (embedding dimension); $K = N_k - M + 1$.

2. You calculate the restored matrix

$$\tilde{\mathbf{X}}(T) = \sum_{m=1}^M \tilde{\mathbf{X}}_m(T), \quad (\text{A.2})$$

where

$$\begin{aligned} \tilde{\mathbf{X}}_1 &= (\tilde{X}_{1,1} \mid \tilde{X}_{1,2} \mid \dots \mid \tilde{X}_{1,J}), \\ \tilde{\mathbf{X}}_2 &= (\tilde{X}_{2,1} \mid \tilde{X}_{2,2} \mid \dots \mid \tilde{X}_{2,J}), \dots, \\ \tilde{\mathbf{X}}_M &= (\tilde{X}_{M,1} \mid \tilde{X}_{M,2} \mid \dots \mid \tilde{X}_{M,J}) \end{aligned}$$



■ Fig. 2. Functions $P(f)$ (solid lines) and $\tilde{P}_m(f)$ (dashed lines) both calculated for the bioelectric activity shown in Fig. 1, *a* (a) and for the bioelectric activity shown in Fig. 1, *b* (b)

are block Hankel matrices generated by the corresponding eigenvectors V_m of an averaged sample correlation matrix $C = 1/K(\mathbf{X}\mathbf{X}^T)$; $\mathbf{V} = (V_1 \dots V_m \dots V_{MJ})$ is an orthogonal matrix of eigenvectors V_m ($\dim(V_m) = (MJ) \times 1$) of the matrix C , built as a result of ordering the eigenvectors V_m in descending order of their eigenvalues $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{MJ} \geq 0$; $C = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^T$ is a singular value decomposition of the matrix C ; $\mathbf{\Lambda} = \text{diag}(\lambda_1 \lambda_2 \dots \lambda_{MJ})$ is a diagonal matrix of eigenvalues. The blocks $X_{m,j}$ of the restored matrices from (A.2) are calculated as follows:

$$\tilde{X}_{1,1}(T) = \begin{pmatrix} v_{1,1} \\ v_{2,1} \\ \vdots \\ v_{M,1} \end{pmatrix} \begin{pmatrix} p_{1,1} \\ p_{2,1} \\ \vdots \\ p_{K,1} \end{pmatrix}^T ; \dots ;$$

$$\tilde{X}_{1,J}(T) = \begin{pmatrix} v_{MJ-M+1,MJ-M+1} \\ v_{MJ-M+2,MJ-M+1} \\ \vdots \\ v_{MJ,MJ-M+1} \end{pmatrix} \begin{pmatrix} p_{1,MJ-M+1} \\ p_{2,MJ-M+1} \\ \vdots \\ p_{K,MJ-M+1} \end{pmatrix}^T ;$$

$$\dots ; \tilde{X}_{M,J}(T) = \begin{pmatrix} v_{MJ-M+1,MJ} \\ v_{MJ-M+2,MJ} \\ \vdots \\ v_{MJ,MJ} \end{pmatrix} \begin{pmatrix} p_{1,MJ} \\ p_{2,MJ} \\ \vdots \\ p_{K,MJ} \end{pmatrix}^T ,$$

where $p_{1,1}, p_{2,1}, \dots, p_{k,MJ}$ are elements of a non-centered principal components matrix.

3. The application of antidiagonal averaging procedures to each of the matrices $\tilde{X}_1, \dots, \tilde{X}_M$ (A.2) allows you to form M multidimensional narrow-band RCs $\tilde{S}_1(T), \dots, \tilde{S}_M(T)$ (1).

References

- Zhuang L., Zhang B., Qin Z., Wang P. Nasal respiration is necessary for the generation of γ oscillation in the olfactory bulb. *Neuroscience*, 2019, no. 398, pp. 218–230. <https://doi.org/10.1016/j.neuroscience.2018.12.011>
- Guo T., Zhuang L., Qin Z., Zhang B., Hu N., Wang P. Multi-odor discrimination by a novel bio-hybrid sensing preserving rat's intact smell perception in vivo. *Sensors and Actuators B*, 2016, no. 225, pp. 34–41. <https://doi.org/10.1016/j.snb.2015.11.010>
- Kepecs A., Uchida N., Mainen ZF. Rapid and precise control of sniffing during olfactory discrimination in rats. *Journal of Neurophysiology*, 2007, no. 98, pp. 205–213. doi:10.1152/jn.00071.2007
- Carey R. M., Wachowiak M. Effect of sniffing on the temporal structure of mitral/tufted cell output from the olfactory bulb. *Journal of Neuroscience*, 2011, no. 31, pp. 10615–10626. doi:10.1523/JNEUROSCI.1805-11.2011
- Esclassan F., Courtiol E., Thevenet M., Garcia S., Buonviso N., Litaudon P. Faster, deeper, better: the impact of sniffing modulation on bulbar olfactory processing. *PLoS ONE*, 2012, no. 7, e40927. doi:10.1371/journal.pone.0040927
- Kay L. M. Olfactory system oscillations across phyla. *Current Opinion in Neurobiology*, 2015, no. 31, pp. 141–147. <https://doi.org/10.1016/j.conb.2014.10.004>
- Sriraam N., Padma Shri T. K. Detection of alcoholic impact on visual event related potentials using beta band spectral entropy, repeated measures ANOVA and k-NN classifier. *2016 International Conference on Circuits, Controls, Communications and Computing (IAC)*, Bangalore, India, 4–6 Oct. 2016. doi:10.1109/CIMCA.2016.8053284
- Ostanin S. A., Filatova E. V. A Virtual Instrument for Spectral Entropy Estimation of Heart Rate. *Izvestiya Altajskogo gosudarstvennogo universiteta*, 2016, no. 1. pp. 45–51 (In Russian). doi:10.14258/izvasu(2016)1-07
- Raghu S., Sriraam N., Kumar G. P., Hegde A. S. A novel approach for real-time recognition of epileptic seizures using minimum variance modified fuzzy entropy. *IEEE Transactions on Biomedical Engineering*, 2018, no. 65(11), pp. 2612–2621. doi:10.1109/TBME.2018.2810942
- Shcherban I. V., Kirilenko N. E., Shcherban O. G. Effective cost functions for spectrum entropy to search for high-frequency event-related patterns in electrograms with noise. *Informatsionno-upravliaiushchie sistemy [Information and Control Systems]*, 2018, no. 2, pp. 8–17 (In Russian). doi:10.15217/issn1684-8853.2018.2.8
- Shcherban I. V., Kirilenko N. E., Krasnikov S. O. A search method for unknown high-frequency oscillators in noisy signals based on the continuous wavelet transform. *Automation and Remote Control*, 2019, no. 80, pp. 1279–1287. <https://doi.org/10.1134/S0005117919070051>
- Rodrigues P. C., Mahmoudvand R. A robust approach to singular spectrum analysis. *Quality and Reliability Engineering*, 2018, no. 34(5549). doi:10.1002/qre.2337
- Danilov D. L., Zhiglyavskij A. A. *Glavnye komponenty vremennyh ryadov: metod "Gusenica"* [Principal components of time series structure: SSA]. Saint-Petersburg, Presskom Publ., 1997. 308 p. (In Russian).
- Mahmoudvand R., Rodrigues P. C., Yarmohammadi M. Forecasting daily exchange rates: A comparison between SSA and MSSA. *REVSTAT – Statistical Journal*, 2019, no. 17(4), pp. 599–616.
- Hu H., Guo S., Liu R., Wang P. An adaptive singular spectrum analysis method for extracting brain rhythms of electroencephalography. *PeerJ*, 2017, no. 6, e3474. doi:10.7717/peerj.3474

16. Zabalza J., Ren J., Wang Z., Marshall S., Wang J. Singular spectrum analysis for effective feature extraction in hyperspectral imaging. *IEEE Geoscience and Remote Sensing Letters*, 2014, no. 11, pp. 1886–1890. doi:10.1109/LGRS.2014.2312754
17. Maddirala A. K., Shaik R. A. Motion artifact removal from single channel electroencephalogram signals using singular spectrum analysis. *Biomedical Signal Processing and Control*, 2016, no. 30, pp. 79–85. doi:10.1016/j.bspc.2016.06.017
18. Maddirala A. K., Shaik R. A. Removal of EOG artifacts from single channel EEG signals using combined singular spectrum analysis and adaptive noise canceler. *IEEE Sensors Journal*, 2016, no. 16, pp. 8279–8287. doi:10.1109/JSEN.2016.2560219
19. Vizilter Yu. V., Zheltov S. Yu. Similarity measures and comparison metrics for image shapes. *Journal of Computer and Systems Sciences International*, 2014, vol. 53, no. 4, pp. 542–555. doi:10.1134/S1064230714040169
20. Mikhaylov I. A. Image recognition using a radial neighborhood method. *Computer Optics*, 2010, vol. 34, no. 3, pp. 399–407.
21. Taha A., Hanbury A. An efficient algorithm for calculating the exact Hausdorff distance. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, vol. 37, no. 11, pp. 2153–2163.

УДК 681.3:612.8

doi:10.31799/1684-8853-2020-5-62-69

Метод автоматического поиска одорологических вызванных паттернов в биоэлектрической активности обонятельной луковицы крысы

И. В. Щербань^а, доктор техн. наук, профессор, orcid.org/0000-0002-3997-9151, shcheri@mail.ru

П. О. Косенко^а, канд. биол. наук, orcid.org/0000-0002-4333-5332

О. Г. Щербань^а, канд. техн. наук, доцент, orcid.org/0000-0001-5139-8520

П. В. Лобзенко^б, канд. техн. наук, доцент, orcid.org/0000-0002-5293-0109

^аЮжный федеральный университет, Б. Садовая ул., 105/42, Ростов-на-Дону, 344006, РФ

^бМосковский технический университет связи и информатики, Народного Ополчения ул., 32, Москва, 123423, РФ

Введение: изучение обонятельной системы в хронических экспериментах на животных проводится по записям биоэлектрической активности, регистрируемой с использованием микроэлектродных матриц, расположенных на дорзальной поверхности обонятельной луковицы. Считается, что ответная на предъявление одоранта биоэлектрическая активность обонятельной луковицы связана с колебаниями, синхронизированными дыханием и относящимися к диапазону так называемых гамма-ритмов. **Цель:** разработать метод автоматического поиска временных границ подобных одорологически вызванных паттернов гамма-ритмов в биоэлектрической активности обонятельной луковицы. **Результаты:** сложности автоматического поиска одорологически вызванных паттернов обусловлены маскированием их спонтанными осцилляциями гамма-ритмов, не связанными с деятельностью обонятельной системы. Кроме того, модальная частота паттернов априорно неизвестна и динамически изменяется в ходе эксперимента, в частности, на наркотизированном животном. В качестве критериальной функции поиска использована метрика Хаусдорфа. В целях увеличения ее чувствительности на основе аппарата многомерного сингулярного спектрального анализа синтезирован адаптивный полосовой фильтр, полоса пропускания которого на анализируемой временной выборке максимально соответствует спектру искомым паттернов. Представлены результаты экспериментов на крысах. Применение полосовых фильтров на основе преобразования Фурье с неизменяемыми в ходе эксперимента параметрами в силу нестационарности во времени частотных характеристик искомым паттернов не обеспечивает эффективного их поиска. Так, при использовании в алгоритме поиска полосового фильтра Баттерворта наблюдались значительные ошибки в определении границ временных эпох паттернов, пропуски паттернов. Использование же синтезированного адаптивного полосового фильтра обеспечило надежный автоматический поиск паттернов и определение их временных границ с высокой точностью. Сбой алгоритма в этом случае наблюдались лишь при двигательных артефактах крыс. **Практическая значимость:** разработанный метод расширяет существующий инструментарий, применяемый для изучения обонятельной системы живого организма.

Ключевые слова – обонятельная луковица, биоэлектрическая активность, одорологически вызванные паттерны, метрика Хаусдорфа, многомерный сингулярный спектральный анализ.

Для цитирования: Shcherban I. V., Kosenko P. O., Shcherban O. G., Lobzenko P. V. Method of automatic search for odor-induced patterns in bioelectric activity of a rat olfactory bulb. *Информационно-управляющие системы*, 2020, № 5, с. 62–69. doi:10.31799/1684-8853-2020-5-62-69

For citation: Shcherban I. V., Kosenko P. O., Shcherban O. G., Lobzenko P. V. Method of automatic search for odor-induced patterns in bioelectric activity of a rat olfactory bulb. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 62–69. doi:10.31799/1684-8853-2020-5-62-69

Comparative assessment of text-image fusion models for medical diagnostics

A. A. Lobantsev^a, Programmer Engineer, orcid.org/0000-0002-8314-5103

N. F. Gusarova^a, PhD, Tech., Associate Professor, orcid.org/0000-0002-1361-6037, natfed@list.ru

A. S. Vatian^a, PhD, Tech., Associate Professor, orcid.org/0000-0002-5483-716X

A. A. Kapitonov^b, Post-Graduate Student, orcid.org/0000-0003-1378-1910

A. A. Shalyto^a, Dr. Sc., Tech., Professor, orcid.org/0000-0002-2723-2077

^aITMO University, 49, Kronverksky Pr., 197101, Saint-Petersburg, Russian Federation

^bBelarus State Medical University, 83, Dzerzhinski Ave., 220116, Minsk, Republic of Belarus

Introduction: Information overload and complexity are characteristic of decision-making in medicine. In these conditions information fusion techniques are effective. For the diagnosis and treatment of pneumonia using x-ray images and accompanying free-text radiologists reports, it is promising to use text-image fusion. **Purpose:** Development of a method for fusing text with an image in the treatment and diagnosis of pneumonia using neural networks. **Methods:** We used MIMIC-CXR dataset, the SE-ResNeXt101-32x4d for images feature extracting and the Bio-ClinicalBERT model followed by ContextLSTM layer for text feature extracting. We compared five architectures in the conducted experiment: image classifier, report classifier and three scenarios of the fusion, namely late fusion, middle fusion and early fusion. **Results:** We got an absolute excess of metrics (ROC AUC = 0.9933, PR AUC = 0.9907) when using an early fusion classifier (ROC AUC = 0.9921, PR AUC = 0.9889) even over the idealized case of text classifier (that is, without taking into account possible errors of the radiologist). The network training time ranged from 20 minutes for late fusion to 9 hours and 45 minutes for early fusion. Based on Class Activation Map technique we graphically showed that the image feature extractor in the fused classification scenario still learns discriminative regions for pneumonia classification problem. **Discussion:** Fusing text and images increases the likelihood of correct image classification compared to only image classification. The proposed combined image-report classifier trained with the early-fusion method gives better performance than individual classifiers in the pneumonia classification problem. However, it is worth considering that better results cost the training time and required computation resources. Report-based training is much faster in training and less demanding for computation capacity.

Keywords – text-image fusion, medical diagnostics, late fusion, early fusion, middle fusion, x-ray image.

For citation: Lobantsev A. A., Gusarova N. F., Vatian A. S., Kapitonov A. A., Shalyto A. A. Comparative assessment of text-image fusion models for medical diagnostics. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 70–79. doi:10.31799/1684-8853-2020-5-70-79

Introduction

The richer the information flow is, the more potential opportunities it provides for the organization of effective control, but at the same time, the more difficult it is for the decision-maker to review it and bring it together into a single whole. Therefore, in conditions of information overload and complexity, information fusion techniques are increasingly used. At the substantive level, information fusion can be described as combining complementary information from different sources concerning the same object or scene to obtain complex information representation providing more effective control. In the literature, fused sources are often in different modalities, and the process itself is called multimodal fusion.

A number of definitions of information fusion are presented in the literature [1–6], emphasizing various aspects of this process. In the context of this article, it is vital to highlight the following aspects:

— information fusion aims to maximize the decision maker's or expert systems performance;

— sources of information for information fusion can be not only physical sensors but also social media and human intelligence reports (expert knowledge);

— information fusion is a hierarchical process and can occur at multiple abstraction levels (measurements, features, decisions).

Multimodal fusion is widely used in various practical tasks, such as web-search [7], image segmentation [8–10], image and video classification [11, 12], emotion recognition [13, 14], analysis of social media content [15], audio-visual speech enhancement [16], etc. With the development of high-tech diagnostic tools, multimodal fusion is becoming increasingly prominent in medicine. Here, such areas are actively developing as predicting the patient's health based on genomic, transcriptomic, and lifestyle information of one [17] as well as predicting the development of certain diseases [18, 19]. For instance, multimodal fusion in neuroimaging is actively developing these days [20–24]. It combines data from multiple imaging modalities, like positron emission tomography, computed tomography, and magnetic resonance imaging, to overcome the limitations of individual

modalities. In this case, an artificially combined image of the zone of interest in the brain is constructed as subject to further visualizing. In the clinical process, the attending physician acts as an analyst and interpreter of those images.

It is vitally important to make the right decision as fast as it is possible, but this is implementable only if there are adequate diagnostic tools. As we are trying to solve the classification of pneumonia presence problem we have to build on the diagnostic tools used in these cases. Chest x-ray (CXR) is mandatory for lung diseases, so it is hard to overemphasize its importance. Developing multimodal fusion-based technologies may improve such concerns of the CXR as the time gap from getting the image to taking the clinical decision and accuracy of the image interpretation. Both these possible improvements should be based on the experience of interpreting CXR's gained by professional radiologists because they are carriers of context and highly specialized knowledge.

Here it is impossible to diminish the significance of the interpretations performed by radiologists. They are carriers of context and highly specialized knowledge that the attending physician does not have. Their interpretation is presented in the form of a textual report. However, like any human opinion, these reports are subjective and error-prone [25, 26].

On the other hand, today, a large and growing role in interpreting medical images is assigned to machine learning-based tools. The results of their work can be, for instance, segmented images with highlighted malignant zones or other areas of interest, the manifestation of the alleged diagnosis, etc. However, the use of machine learning in medicine encounters well-known problems, including the small volumes of available datasets, which do not allow to form a full-fledged context for learning, and the uninterpretable conclusions (the so-called black-box problem). Hence, medical image processing results with machine learning-based tools cannot be regarded as objective and error-free.

In this regard, for the diagnosis and treatment of pneumonia presence, it is promising to use text-image fusion in order to provide the attending physician with information for making a decision in the most reliable, visible and at the same time interpretable (not "black-box") form. The article discusses the emerging challenges, and also proposes an approach to their solution based on the specific problem, namely the classification of pneumonia presence using x-ray images and accompanying free-text radiologists reports.

Background and related works

The analysis of reviews [6, 17, 20, 21, 27, 28] devoted to the problem of multimodal fusion allows us

to highlight the main aspects that determine specific technological solutions for the fusion of images and texts in medicine:

- features the fusion is based on;
- IT architecture;
- and fusion level.

With regard to images, [21] divides features the fusion is based on into three groups: based on spatial domain, based on transform domain, based on deep learning. Features of the first group are the result of spatial (per-pixel) image segmentation, which can be performed according to various rules. For example, in [29, 30], the characteristics of intensity, hue and saturation are used for this. The selected features can be semantically labelled using anatomical brain atlases [31], special visual indexes [31] or ontologies [32]. The ontology describes the medical terms via a controlled vocabulary, where the conceptualizations of the domain knowledge are constructed as an OWL (Ontology Web Language) model.

Features of the second group are the result of transforming the source image to spatial-frequency domain which gives subband images with different scales and directions [33–35]. For example, in [35], sparse representation algorithm is used for merging low frequency subbands.

Features of the third group are formed directly by the neural network during the learning. As we approach the network's output layers, they reflect the image's structure with an increasing degree of generality, thereby constituting its multi-level abstract representation [36]. Nevertheless, as a rule, they stay semantically uninterpretable up to the last (decision) network level [7].

As for the text, the components of the text itself (words, terms, phrases, etc.) [37] or embeddings which transfer text information into a dense representation of the semantic space [38, 39] can be used as features. However, the texts of medical reports demonstrate the high syntactic and terminological complexity and the ambiguity in word usage. As shown in [40], embeddings perform significantly better in natural language processing tasks for such texts.

As the analysis of literature sources shows and as confirmed by the practice of radiologists [41], it is challenging to establish a formal correspondence between any fragments of medical images and fragments of medical reports describing them without involving semantic interpretation in both domains. Attempts to use external structures for this (such as visual indexes [31] or ontologies [32]) lead to significant losses in context, which in many cases decreases the benefits of multimodal fusion. Therefore, in recent publications, approaches related to the use of features that preserve contextual domain dependencies dominate [18, 19, 21–23], and

the deep learning methods are used as a technological base.

In tasks of semantic processing of medical texts, contextual word embeddings, primarily BERT [38], consisting of multiple layers of transformers which use self-attention mechanism, show the best results [40, 42, 43]. For example, for fusing text and speech in depression detection [19] features were extracted by BERT-CNN and VGG-16 CNN in combination with Gated Convolutional Neural Network (GCNN) followed by a LSTM layer. Additionally, [42] shows that BERT performs better than traditional word embedding methods in feature extraction tasks, and the BERT pre-trained on the clinical texts shows itself better than pre-trained on the general domain texts.

Thus, as the analysis shows, today, the CNN + BERT bundle is a popular architecture for joint processing of information from semantically loaded images and texts, a typical medicine case. However, the question of the fusion level remains open.

In a semantic sense, the information fusion can be performed at various levels of abstraction: measurements, features, decisions [1]. In [44], these levels correspond to various technological (architectural) solutions: recognition-based (also known as early fusion), decision-based (also known as late fusion), and hybrid multi-level.

In [45], feature map (DenseNet) and embeddings (BERT) are fused in an intermediate level using cross attention mechanism and afterward are supplied to fully connected layers. [12] compares the effectiveness of three fusion options: early fusion and late fusion combine information on the first convolutional layer and the first fully connected layer respectively, and slow fusion is a balanced mix between the two approaches such that higher layers get access to progressively more global information in both dimensions. The third option revealed some advantages and a strong dependence of efficiency on the context (the content of the dataset). In [46] and [8], the identical structures of late fusion with different weighting options are implemented, with opposite efficiency estimates obtained.

The work [9] explores several options for merging information of different modalities to highlight objects in an industrial landscape, including late sum fusion, late max fusion, late convolution fusion, and early fusion. Early fusion showed the best results; simultaneously, it was revealed that performance is highly problem dependent. Similar results were obtained in [10].

Authors of the work [23] implement a hybrid multi-level fusion based on a particle swarm search method to obtain optimal results. In [47], the authors propose a specialized module for intermediate fusion. The module operates between CNN streams and recalibrates channel-wise features in each mo-

ality. This module is generic and, in principle, suitable for any task, but, as the authors themselves note, the optimal locations and number of modules are different for each application.

Late fusion is rather popular in different applications [7, 18, 19, 37]. However, as noted in [47], this can be mainly due to resource reasons: the network for each unimodal stream can be designed and pre-trained independently for each modality. At the same time, late fusion can give rise to losing cross-modality information [27]. On the other hand, as the literature review reveals, the implementation of early and, even more so, multi-level fusion is a complex technological task and highly dependent on the subject area.

In conclusion of the review, it should be said that there are few works devoted directly to the fusion of texts and images for the diagnostics of particular diseases [18, 48] — this emphasizes the urgency of the problem.

Considering that the formation and training of deep learning models that implement multimodal merging for medical applications is a complex and resource-intensive process, the authors set themselves the task of experimentally assessing the effect of the fusion level on the effectiveness of the classification of pneumonia presence using x-ray images and accompanying free-text radiologists reports.

Method and materials

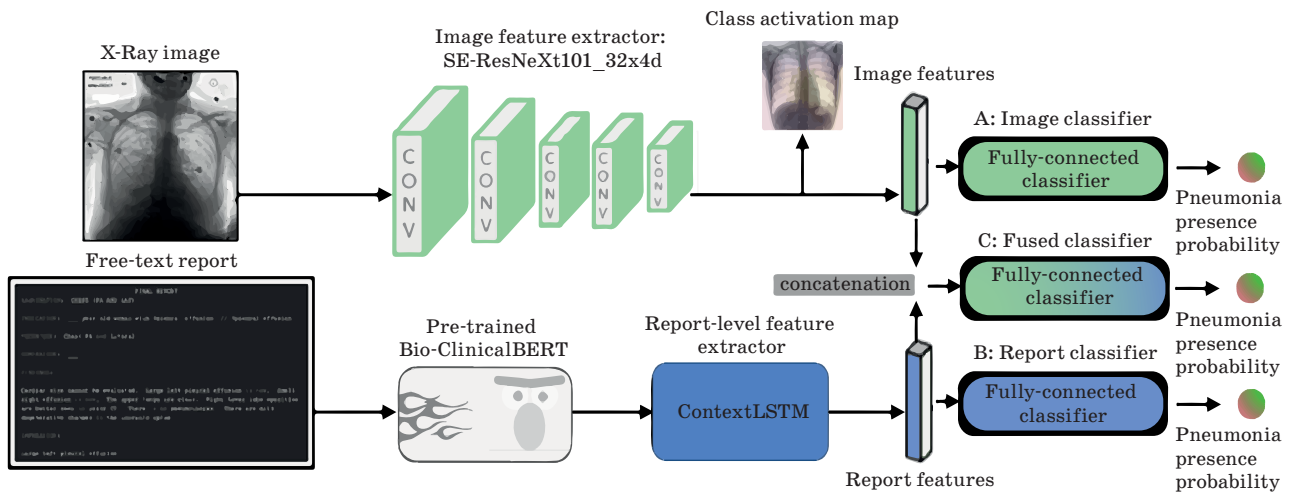
Datasets and data preprocessing

We used MIMIC-CXR [49–51] — the extensive publicly available chest radiographs dataset with free-text radiology reports. The dataset contains more than 300,000 images from over 60,000 patients. Labels were made with CheXpert labeler [50]. We used p10 and p11 data split folders.

We have performed the data preprocessing as follows. For images, pixel values were normalized to the range [0.0, 1.0]. Then, according to the DICOM field “Photometric Interpretation (0028, 0004)” images pixel values were inverted such that air in the image appears white (highest pixel value), while the patient’s body appears black (lower pixel value). Then, the scikit-image library [52] was used to histogram equalization of the image to enhance contrast. Histogram equalization involves shifting pixel values towards 0.0 or 1.0 such that all pixel values have approximately equal frequency. All images were resized to 224 × 224 px size. For reports, we excluded all the text punctuation, and then used tokenizer from the pretrained BERT model (see next section).

Models and training procedure

We consider the model’s architecture as a combination of feature extractors for image and text da-



■ Fig. 1. Training pipeline of the network

ta, and the fusion network appended to combine the extracted features. Training pipeline describing our training approach is shown in Fig. 1.

For images feature extracting we used the SE-ResNeXt101-32x4d [53] which is the ResNeXt101-32x4d model with added Squeeze-and-Excitation [54] module. In order to get word embeddings to feed the report feature extractor we used the pre-trained Bio-ClinicalBERT Model [55]. The Bio-ClinicalBERT model was trained on all notes from the MIMIC III database containing electronic health records from ICU patients at the Beth Israel Hospital in Boston [51].

The report feature extractor prepares report-level embeddings, which we train with the network we called the ContextLSTM layer. The ContextLSTM includes two-layer stacked LSTM network, and one fully connected layer. As input, ContextLSTM takes the sequence of word embeddings from the report. Then, each embedding vector from the sequence is stacked (concatenated) with the next N neighbours in the sequence, forming the context vectors for each entry of the sequence. We used context size $N = 2$.

We compare five architectures in the reported experiment.

Image classifier. To classify pneumonia using only x-ray images, on top of the image feature extractor, we placed a fully connected classification layer followed by the softmax activation.

Report classifier. To classify pneumonia using only reports, on top of the report feature extractor, we placed a fully connected classification layer prepended by the ReLU activation and followed by the softmax activation.

Fused classifier. As a fusion model we used the model consisting of the both feature extractors, followed by the single fully-connected classification layer. We consider three scenarios of the fusion:

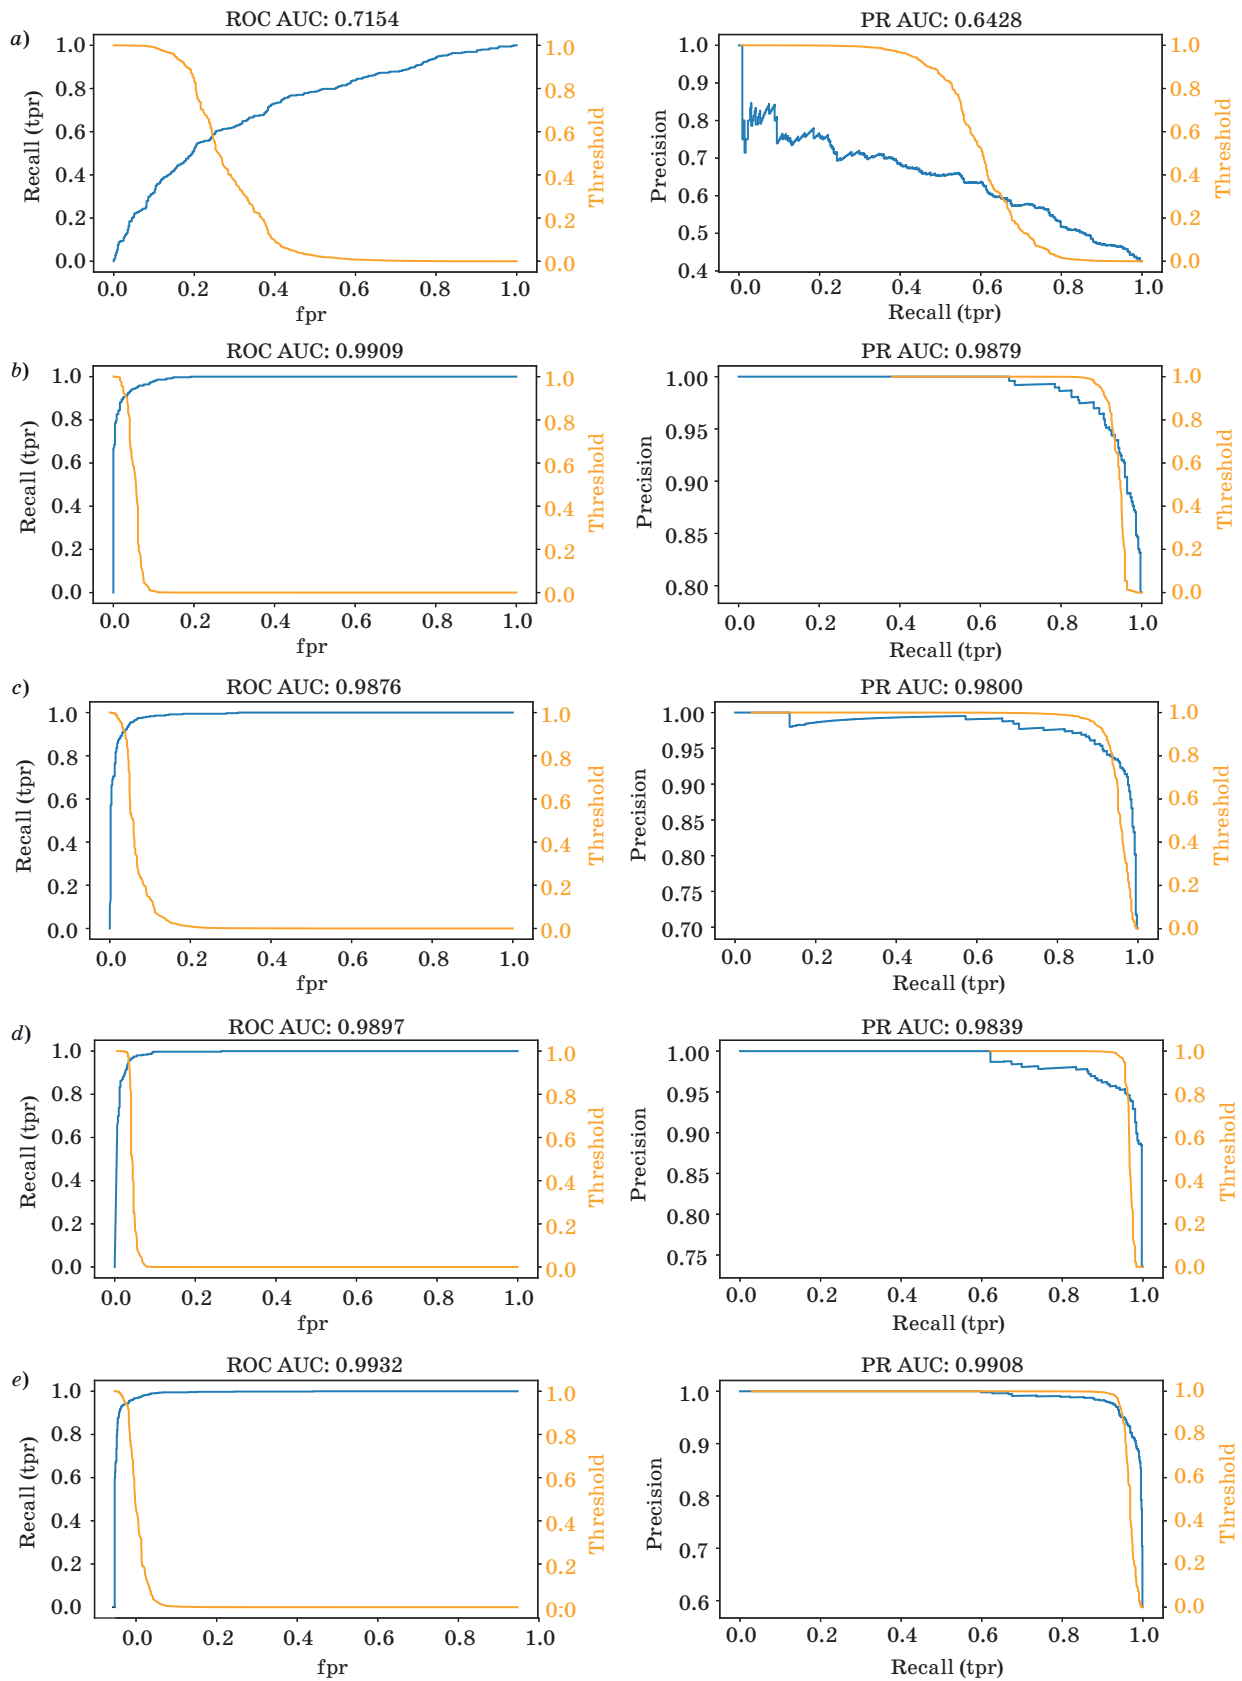
Late Fusion: fully-connected classifier is training on top of completely frozen pre-trained image and report feature extractors.

Middle Fusion: fully-connected classifier is training on top of the pre-trained image and text feature extractors with unfrozen last block of the SE-ResNeXt101-32x4d image feature extractor and the entire unfrozen ContextLSTM report feature extractor.

Early Fusion: the entire network is trained (except the BERT word embedding extractor) including SE-ResNeXt101-32x4d feature extractor, ContextLSTM report feature extractor, and the last fully-connected classification layer.

To compare the model quality we use the metrics: accuracy, model sensitivity and model specificity (at 0.5 probability threshold), area under ROC curve, area under precision-recall curve. Of these, the ROC AUC and PR AUC metrics — integral metrics for all possible decision thresholds — are key to conclusions. Metrics accuracy, specificity and sensitivity, typical for the medical literature, are auxiliary in this case. They are indicated at a typical threshold value of 0.5; the task of selecting the optimal threshold value was not posed here.

Training procedure we used looks as follows. First, we pre-trained each feature extractor as a separate classifier with the same task of classifying the presence of pneumonia. Then we trained late- and middle-fusion scenarios on the top of the pre-trained feature extractors. Finally, we trained the early fusion scenario network. All experiments were conducted with Adam optimizer (betas = 0.9, 0.999), learning rate was optimized with the Cosine Annealing scheduler [56] with the following hyperparameters of the scheduler: base_LR = $1e-8$, $T_0 = 50$, $T_{mult} = 2$, $\eta_{max} = 1e-4$, $\text{GAMMA} = 0.1$. We used batch size = 16, image



■ Fig. 2. Curves ROC (left) and PR (right) for: a — model of the image classifier; b — report classifier models; c — report classifier models for the Late-fusion classifier; d — Middle-fusion classifier; e — Early-fusion classifier

size = (224, 224). During training, images were augmented with random flips, shifts, scales, rotations, and small elastic transforms. NVIDIA RTX 2080Ti was used for training.

Results and discussion

We present the obtained metrics values for all types of classifiers in the Table, using the following abbreviations: ROC AUC — area under the ROC curve, PR AUC — area under precision-recall curve. These curves for each type of classifier is illustrated by Fig. 2, *a–e*. The last column in the Table shows training time comparison.

Figure 3 shows examples of Class Activation Maps [57] for results of image classifier and image feature extractor in early-fusion model indicating the most distinctive areas used by each classifier to determine the category to which the image belongs: 0 — no pneumonia, 1 — pneumonia. Areas with higher activation values have more impact on the

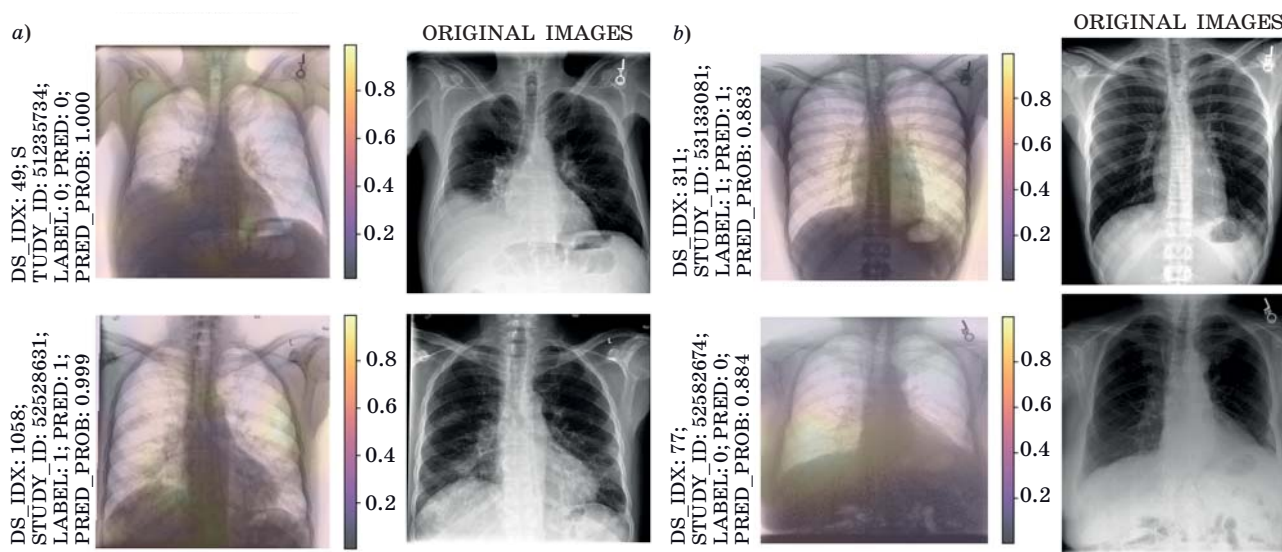
network decision. Color graduations correspond to the level of activation of the image features on the last convolution layers. Lighter areas are more critical for the network to gain the decision than the darker ones. Here we can see that the image feature extractor in the fused classification scenario still learns discriminative regions for pneumonia classification problem.

Analysis of the results obtained allows us to draw the following statements.

Though the values of all metrics for the image classifier (see Table) are relatively poor compared to the report classifier, they entirely correspond to the current world level [58–60]. Note that during training the report classifier, only obviously correct text reports were used; in reality, it is necessary to consider the human factor associated with errors and fatigue of radiologists, which reduces the received metrics. Under these conditions, fusing text and images increases the likelihood of correct image classification. Besides, Table shows that we got an absolute excess of metrics when using an early fu-

■ Metrics values for different classifiers

Classifier type	Accuracy	Sensitivity	Specificity	ROC AUC	PR AUC	Training time
Image classifier	0.6823	0.5718	0.7637	0.7195	0.6438	6 h 14 min
Report classifier	0.9590	0.9696	0.9511	0.9921	0.9889	20 min
Late-fusion classifier	0.9484	0.9558	0.9430	0.9876	0.9800	15 min
Middle-fusion classifier	0.9613	0.9669	0.9572	0.9897	0.9838	29 min
Early-fusion classifier	0.9579	0.9684	0.9504	0.9933	0.9907	9 h 45 min



■ Fig. 3. Class Activation Map for different classifiers: *a* — early fusion classifier; *b* — image classifier

sion classifier even over the idealized case of text classifier.

Comparing Figures 3, *a* and *b* shows that in the case of the image classifier, the network learns only from those areas of the image that are directly affected by pneumonia. Simultaneously, in the case of the fusion classifier, the network takes into account not only these areas but also the surrounding context, which is more consistent with the approach of a radiologist to the medical images classification. Besides, as shown in Table, the report classifier learns much faster than all other classifiers. However, Fig. 3, *b* indicates that introducing a text classifier into the fusion pipeline does not lead to training only on the textual data, i.e., image feature extractor in the fused network model still learns correct semantic image areas for classification.

Comparing the results of the Table for three types of fusion shows an exchange ratio between the classification and training efficiency metrics: the higher the desired classification efficiency metrics, the more computing resources are required to train the network. This circumstance must be taken into account when choosing the proposed models in a real clinical process.

References

1. Dimou I., Zervakis M., Lowe D., and Tsiknakis M. *Computational Methods and Tools for Decision Support in Biomedicine: An Overview of Algorithmic Challenges*. In: *Handbook of Research on Advanced Techniques in Diagnostic Imaging and Biomedical Applications*. T. P. Exarchos, A. Papadopoulos and D. I. Fotiadis (eds.). 2009. Pp. 1–17.
2. Yu-Jin Zhang. *Image Fusion Techniques with Multiple-Sensors*. In: *Encyclopedia of Information Science and Technology*. Third Ed. 2015. Pp. 5926–5936.
3. Solaiman B., Bosse E. *Possibility Theory for the Design of Information Fusion Systems*. Series: Information Fusion and Data Science. 2019. 278 p.
4. Rogova G. L. *Information Quality in Fusion-Driven Human-Machine Environments*. In: *Information Quality in Information Fusion and Decision Making*. Series: Information Fusion and Data Science. E. Bosse, G. L. Rogova (eds.). 2019. Pp. 3–29.
5. Calderero F., Marqués F. *Image Analysis and Understanding Based on Information Theoretical Region Merging Approaches for Segmentation and Cooperative Fusion*. In: *Handbook of Research on Computational Intelligence for Engineering, Science, and Business*. S. Bhattacharyya, and P. Dutta (eds.). 2013. Pp. 75–121.
6. Meng T., Jing X., Yan Z., Pedrycz W. A survey on machine learning for data fusion. *Information Fusion*, May 2020, vol. 57, pp. 115–129.
7. Wang D., Mao K., Ng G.-W. Convolutional neural networks and multimodal fusion for text aided image classification. *20th International Conference on Information Fusion*, 2017, July 10–13, 2017, Xi'an, China, pp. 1–7.
8. Perdana C. R. A., Nugroho H. A., Ardiyanto I. Comparison of text-image fusion models for high school diploma certificate classification. *Communications in Science and Technology*, 2020, vol. 5(1), pp. 5–9.
9. Lawin F. J., Danelljan M., Tosteberg P., Bhat G., Khan F. S., and Felsberg M. Deep projective 3d semantic segmentation. *International Conference on Computer Analysis of Images and Patterns*, 2017. arXiv:1705.03428v1 [cs.CV] 9 May 2017.
10. Tetreault J. *Deep Multimodal Fusion Networks for Semantic Segmentation*. 2017. All Theses. 2756. Available at: https://tigerprints.clemson.edu/all_theses/2756 (accessed 10 September 2020).
11. Gallo I., Calefati A., Nawaz S., Janjua M. K. *Image and Encoded Text Fusion for Multi-Modal Classification*. arXiv:1810.02001 [cs.CV] 3 Oct. 2018.
12. Karpathy A., Toderici G., Shetty S., Leung T., Sukthankar R., and Li Fei-Fei. Large-scale video classification with convolutional neural networks. *2014 IEEE Conference on Computer Vision and Pattern Recognition, Columbus, OH, 2014*, pp. 1725–1732, doi:10.1109/CVPR.2014.223
13. Jiang Y., Li W., Hossain M. S., Chen M., Al-Hammadi M. A snapshot research and implementation of multimodal information fusion for data-driven emo-

Conclusion

We have presented that combining x-ray images and accompanying free-text radiologists reports in neural network model training improves the quality of the model's decision in the classification task.

In the experiment, we have compared five training scenarios for the pneumonia classification task. Two individual classifiers based on each modality and three fused classifiers differ in training methods: late, middle, and early fusion. The proposed combined image-report classifier trained with the early-fusion method gives better performance than individual classifiers in the pneumonia classification problem. However, it is worth considering that better results cost the training time and required computation resources. Report-based training is much faster in training and less demanding for computation capacity.

Acknowledgment

This work was financially supported by Russian Science Foundation, Grant 19-19-00696.

- tion recognition. *Information Fusion*, Jan. 2020, vol. 53, pp. 209–221.
14. **Gravina R., Li Q.** Emotion-relevant activity recognition based on smart cushion using multi-sensor fusion. *Information Fusion*, Aug. 2019, vol. 48, pp. 1–10.
 15. **Zhiwei Jin, Juan Cao, Han Guo, Yongdong Zhang, Jiebo Luo.** Multimodal fusion with recurrent neural networks for rumor detection on microblogs. *Proceedings of the 25th ACM International Conference on Multimedia (MM'17)*, Oct. 2017, pp. 795–816. <https://doi.org/10.1145/3123266.3123454>
 16. **Afouras T., Chung J.S., and Zisserman A.** *The conversation: Deep audio-visual speech enhancement*. arXiv preprint arXiv:1804.04121, 2018.
 17. **Zitnik M., Nguyen F., Wang B., Leskovec J., Goldenberg A., Hoffman M. M.** Machine learning for integrating data in biology and medicine: Principles, practice, and opportunities. *Information Fusion*, Oct. 2019, vol. 50, pp 71–91.
 18. **Qiang He, Xin Li, D. W. Nathan Kim, Xun Ji, Xuejun Gu, Xin Zhen, Linghong Zhou.** Feasibility study of a multi-criteria decision-making based hierarchical model for multi-modality feature and multi-classifier fusion: Applications in medical prognosis prediction. *Information Fusion*, Mar. 2020, vol. 55, pp. 207–219.
 19. **Makiuchi M. R., Warnita T., Uto K., Shinoda K.** Multimodal fusion of BERT-CNN and gated CNN representations for depression detection. *Proceedings of the 9th International on Audio/Visual Emotion Challenge and Workshop (AVEC '19)*, Oct. 2019, pp. 55–63. <https://doi.org/10.1145/3347320.3357694>
 20. **Zhang Y.-D., Dong Z., Wang S.-H., Yu X., Yao X., Zhou Q., Hu H., Li M., Jiménez-Mesa C., Ramirez J., Martinez F. J., Gorritz J. M.** Advances in multimodal data fusion in neuroimaging: Overview, challenges, and novel orientation. *Information Fusion*, 2020, vol. 64, pp. 149–187.
 21. **Huang B., Yang F., Yin M., Mo X., and Zhong C.** A review of multimodal medical image fusion techniques. *Computational and Mathematical Methods in Medicine*, vol. 2020, Article ID 8279342. <https://doi.org/10.1155/2020/8279342>
 22. **Fan F., Huang Y., Wang L., Xiong X., Jiang Z., Zhang Z., and Zhan J.** *A semantic-based medical image fusion*. arXiv:1906.00225v2 [eess.IV] 11 Dec. 2019.
 23. **Huang C., Tian G., Lan Y., Peng Y., Ng E. Y. K., Hao Y., Cheng Y., and Che W.** A new Pulse Coupled Neural Network (PCNN) for brain medical image fusion empowered by shuffled frog leaping algorithm. *Front. Neurosci.*, 20 Mar. 2019. <https://doi.org/10.3389/fnins.2019.00210>
 24. **Huang Z., Lin J., Xu L., Wang H., Bai T., Pang Y., and Meen T.-H.** Fusion high-resolution network for diagnosing ChestX-ray images. *Electronics*, 2020, vol. 9, iss. 1, p. 190. doi:10.3390/electronics9010190
 25. **Razzak M. I., Naz S., and Zaib A.** *Deep Learning for Medical Image Processing: Overview, Challenges and Future*. In: *Classification in BioApps. Lecture Notes in Computational Vision and Biomechanics*. N. Dey, A. Ashour, S. Borra (eds). Springer, Cham, 2017. Vol. 26. Pp. 323–350.
 26. **Shen D., Wu G., and Suk H.-I.** Deep learning in medical image analysis. *Annu. Rev Biomed Eng.*, 2017, vol. 19, pp. 221–248.
 27. **Gao J., Li P., Chen Z., and Zhang J.** A survey on deep learning for multimodal data fusion. *Neural Computation*, May 2020, vol. 32, iss. 5, pp. 829–864.
 28. **Smirnov A., Levashova T.** Knowledge fusion patterns: A survey. *Information Fusion*, Dec. 2019, vol. 52, pp. 31–40.
 29. **Chen C.-I.** Fusion of PET and MR brain images based on HIS and Log-Gabor transforms. *IEEE Sensors Journal*, 2017, vol. 17, no. 21, pp. 6995–7010.
 30. **Cabezas M., Oliver A., Lladó X., Freixenet J., Cuadra M. B.** A review of atlas-based segmentation for magnetic resonance brain images. *Comput. Methods Programs Biomed.*, 2011, vol. 104, iss. 3, E158–E177.
 31. **Racoceanu D., Lacoste C., Teodorescu R., Vuilleminot N.** A semantic fusion approach between medical images and reports using UMLS. *Proceedings of Third Asia Information Retrieval Symposium, (AIRS 2006) "Information Retrieval Technology"*, Singapore, October 16–18, 2006, Springer, Berlin, Heidelberg, pp. 460–475.
 32. **Teodorescu R.-O., Cernazanu-Glavan C., Cretu V.-I., and Racoceanu D.** The use of the medical ontology for a semantic-based fusion system in biomedical informatics application to Alzheimer disease. *4th International Conference on Intelligent Computer Communication and Processing*, Cluj-Napoca, 2008, pp. 265–268. doi:10.1109/ICCP.2008.4648383
 33. **Yin M., Liu X., Liu Y., and Chen X.** Medical image fusion with parameter-adaptive pulse coupled neural network in nonsubsampling shearlet transform domain. *IEEE Transactions on Instrumentation and Measurement*, 2018, no. 99, pp. 1–16.
 34. **Mendhe M., Ladhake S. A., Ghate U. S.** An application of Shearlet transform for medical image fusion. *International Journal of Engineering Research & Technology (IJERT)*, May 2017, vol. 6, iss. 05, pp. 833–837.
 35. **Shabanzade F., and Ghassemian H.** Multimodal image fusion via sparse representation and clustering-based dictionary learning algorithm in nonsubsampling contourlet domain. *8th International Symposium on Telecommunications (IST)*, Tehran, Iran, Sept. 2016, pp. 472–477.
 36. **LeCun Y., Bengio, Y., & Hinton G. E.** Deep learning. *Nature*, 2015, vol. 521, iss. 7553, pp. 436–444.
 37. **Ma L., Lu Z., Shang L., & Li H.** Multimodal convolutional neural networks for matching image and sentence. *Proceedings of 2015 IEEE International Conference on Computer Vision*, Washington, DC, IEEE Computer Society, 2015, pp. 2623–2631.
 38. **Devlin J., Chang M.-W., Lee K., and Toutanova K.** *BERT: Pre-training of deep bidirectional transform-*

- ers for language understanding. arXiv preprint arXiv:1810.04805, 2018.
39. Mikolov T., Chen K., Corrado G., and Dean J. *Efficient estimation of word representations in vector space*. arXiv preprint arXiv:1301.3781, 2013.
 40. Arora S., May A., Zhang J., Ré C. Contextual embeddings: when are they worth it? *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, July 2020, pp. 2650–2663.
 41. Boitsov V., Vatian A., Egorov N., Klochkov A., Lobantsev A., Markova E., Gusarova N., Shalyto A., Zubanenko A., Soldatov R., Niyogi R. Software tools for manual segmentation of tomography images supporting radiologist's personal context. *25th Conference of Open Innovations Association (FRUCT)*, Helsinki, Finland, 2019, pp. 64–76. doi:10.23919/FRUCT48121.2019.8981541
 42. Si Y., Wang J., Xu H., Roberts K. E. Enhancing clinical concept extraction with contextual embeddings. *Journal of the American Medical Informatics Association*, July 2019, vol. 26, iss. 11, pp. 1297–1304. doi:10.1093/jamia/ocz096
 43. Khattak F. K., Jebblee S., Pou-Prom C., Abdalla M., Meaney C., Rudzicz F. A survey of word embeddings for clinical text. *Journal of Biomedical Informatics*, Dec. 2019, vol. 4, 100057.
 44. D'Ulizia A. *Exploring Multimodal Input Fusion Strategies*. In: *Handbook of Research on Multimodal Human Computer Interaction and Pervasive Services: Evolutionary Techniques for Improving Accessibility*. P. Grifoni (ed). IGI Publ., 2009. Pp. 34–57.
 45. Jaimes A. *Multi-Modal Fusion AI for Real-time Event Detection*. Febr. 18, 2020. Available at: <https://www.dataminr.com/blog/multi-modal-fusion-ai-for-real-time-event-detection> (accessed 5 August 2020).
 46. Li G., and Li N. Customs classification for cross-border e-commerce based on text-image adaptive convolutional neural network. *Electron. Commer. Res.*, 2019, vol. 19, iss. 4, pp. 799–800.
 47. Joze H. R. V., Shaban A., Iuzzolino M. L., Koishida K. *MMTM: Multimodal Transfer Module for CNN Fusion*. arXiv:1911.08670v2 [cs.CV] 30 Mar. 2020.
 48. Vatian A., Gusarova N., Dobrenko N., Klochkov A., Nigmatullin N., Lobantsev A., and Shalyto A. Fusing of medical images and reports in diagnostics of brain diseases. *Proceedings of the 2019 the International Conference on Pattern Recognition and Artificial Intelligence (PRAI '19)*, Aug. 2019, pp. 102–108. <https://doi.org/10.1145/3357777.3357793>
 49. Johnson A. E. W., Pollard T. J., Berkowitz S., Greenbaum N. R., Lungren M. P., Deng C.-Y., Mark R. G., Horng S. *MIMIC-CXR: A large publicly available database of labeled chest radiographs*. arXiv:1901.07042 [cs.CV] 14 Nov. 2019.
 50. *MIMIC-CXR-JPG — chest radiographs with structured labels 2.0.0*. Available at: <https://physionet.org/content/mimic-cxr-jpg/2.0.0/mimic-cxr-2.0.0-chexpert.csv.gz>, last access 20.08.2020 (accessed 5 August 2020).
 51. Johnson A. E. W., Pollard T. J., Shen L., Lehman L. H., Feng M., Ghassemi M., Moody B., Szolovits P., Celi L. A. & Mark R. G. MIMIC-III, a freely accessible critical care database. *Sci Data*, 2016, vol. 3, Article number 160035. <https://doi.org/10.1038/sdata.2016.35>
 52. van der Walt S., Schönberger J. L., Nunez-Iglesias J., Boulogne F., Warner J. D., Yager N., Gouillart E., Yu T. Scikit-image: Image processing in Python. *Peer J*, 2014, 2:e453. <https://doi.org/10.7717/peerj.453>
 53. Xie S., Girshick R., Dollar P., Tu Z., He K. *Aggregated Residual Transformations for Deep Neural Networks*. arXiv:1611.05431v2 [cs.CV] 11 Apr. 2017.
 54. Hu J., Shen L., Albanie S., Sun G., Wu E. *Squeeze-and-Excitation Networks*. arXiv:1709.01507v4 [cs.CV] 16 May 2019.
 55. Alsentzer E., Murphy J. R., Boag W., Weng W.-H., Jin D., Naumann T., McDermott M. B. A. Publicly available clinical BERT embeddings. *Clinical Natural Language Processing (ClinicalNLP) Workshop at NAACL*, 2019. <https://arxiv.org/abs/1904.03323>
 56. Loshchilov I., Hutter F. SGDR: Stochastic Gradient Descent with Warm Restarts. *ICLR 2017 Conference Paper*. arXiv:1608.03983 [cs.LG].
 57. Zhou B., Khosla A., Lapedriza A., Oliva A., Torralba A. Learning deep features for discriminative localization. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 1–10.
 58. Wang X., Peng Y., Lu L., Lu Z., Summers R. M. Tienet: Text-image embedding network for common thorax disease classification and reporting in chest x-rays. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018, pp. 1–16.
 59. Rajpurkar P., Irvin J., Zhu K., Yang B., Mehta H., Duan T., Ding D., Bagul A., Langlotz C., Shpanskaya K., Lungren M. P., Ng A. Y. *CheXnet: Radiologist-level pneumonia detection on chest x-rays with deep learning*. arXiv preprint arXiv:1711.05225, 2017.
 60. Khan W., Nazar Z., and Luqman A. *Intelligent pneumonia identification from chest x-rays: A systematic literature review*. medRxiv. 2020.

УДК 004.895

doi:10.31799/1684-8853-2020-5-70-79

Сравнительная оценка моделей слияния текста и изображения для медицинской диагностикиА. А. Лобанцев^а, инженер-программист, orcid.org/0000-0002-8314-5103Н. Ф. Гусарова^а, канд. техн. наук, доцент, orcid.org/0000-0002-1361-6037, natfed@list.ruА. С. Ватьян^а, канд. техн. наук, доцент, orcid.org/0000-0002-5483-716XА. А. Капитонов^б, аспирант, orcid.org/0000-0003-1378-1910А. А. Шалыто^а, доктор техн. наук, профессор, orcid.org/0000-0002-2723-2077^аУниверситет ИТМО, Кронверкский пр., 49, Санкт-Петербург, 197101, РФ^бБелорусский государственный медицинский университет, Дзержинского пр., 83, 220116, Минск, Белоруссия

Введение: в медицине при принятии решений характерны информационная перегрузка и сложность. В этих условиях эффективны методы слияния информации. Для диагностики и лечения пневмонии с использованием рентгеновских снимков и их текстовых описаний, выполняемых радиологами, перспективно использовать слияние текста с изображением. **Цель:** разработка моделей слияния изображения и текста при диагностике пневмонии с помощью нейронных сетей. **Методы:** использовался датасет 33 MIMIC-CXR; для обработки изображений использована сеть SE-ResNeXt101-32x4d; для обработки текста использована модель Bio-ClinicalBERT в сочетании со слоем ContextLSTM. Проведено экспериментальное сравнение пяти архитектур нейронной сети: классификатор изображений, классификатор текстов и три классификатора на основе слияния, а именно позднего, раннего и промежуточного слияния. **Результаты:** при использовании классификатора раннего слияния получено абсолютное превышение показателей (ROC AUC = 0,9933, PR AUC = 0,9907) даже по сравнению с идеализированным (т. е. без учета возможных ошибок радиолога) случаем текстового классификатора (ROC AUC = 0,9921, PR AUC = 0,9889). Время обучения сети варьировалось от 20 минут для позднего слияния до 9 часов 45 минут для раннего слияния. С использованием карты активации классов наглядно показано, что во всех классификаторах на основе слияния действительно выделяются наиболее характерные для классификации пневмонии области изображения. **Обсуждение:** слияние текста и изображений увеличивает вероятность правильной классификации изображений по сравнению с классификацией только изображений. Показано, что в задаче классификации пневмонии классификатор изображений и текстов, обученный с помощью метода раннего слияния, дает лучшую производительность, чем классификаторы изображений и текстов по отдельности. Однако стоит учесть, что лучшие результаты требуют затрат времени на обучение и вычислительных ресурсов. Обучение на основе текстовых отчетов проходит намного быстрее и требует меньших вычислительных ресурсов.

Ключевые слова — слияние текста и изображения, медицинская диагностика, позднее слияние, раннее слияние, промежуточное слияние, рентгеновское изображение.

Для цитирования: Lobantsev A. A., Gusarova N. F., Vatian A. S., Kapitonov A. A., Shalyto A. A. Comparative assessment of text-image fusion models for medical diagnostics. *Информационно-управляющие системы*, 2020, № 5, с. 70–79. doi:10.31799/1684-8853-2020-5-70-79

For citation: Lobantsev A. A., Gusarova N. F., Vatian A. S., Kapitonov A. A., Shalyto A. A. Comparative assessment of text-image fusion models for medical diagnostics. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 70–79. doi:10.31799/1684-8853-2020-5-70-79

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.

АБДУЛЛАХ
Али



Аспирант кафедры теоретических основ электротехники Санкт-Петербургского государственного электротехнического университета «ЛЭТИ». В 2019 году окончил Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» по специальности «Управление в технических системах». Область научных интересов — системы управления на основе обучения с подкреплением, глубокие нейронные сети, искусственный интеллект.
Эл. адрес: eliyaabdullah@gmail.com

ВАТЬЯН
Александра
Сергеевна



Ассистент факультета инфокоммуникационных технологий Университета ИТМО, Санкт-Петербург. В 2014 году окончила Университет ИТМО по специальности «Прикладная информатика». Является автором 21 научной публикации и шести РИД. Область научных интересов — машинное обучение, искусственный интеллект, автоматное программирование.
Эл. адрес: alexvatyan@gmail.com

ГРУБОВ
Вадим
Валерьевич



Старший научный сотрудник лаборатории нейронауки и когнитивных технологий Университета Иннополис. В 2012 году окончил Саратовский государственный университет им. Н. Г. Чернышевского по специальности «Радиофизика». В 2015 году защитил диссертацию на соискание ученой степени кандидата физико-математических наук. Является автором более 40 научных публикаций. Область научных интересов — анализ и обработка комплексных сигналов, вейвлетный анализ и его приложения в нелинейной динамике и нейронауке.
Эл. адрес: vvgrubov@gmail.com

ГУСАРОВА
Наталья
Федоровна



Старший научный сотрудник, доцент факультета инфокоммуникационных технологий Университета ИТМО, Санкт-Петербург. В 1974 году окончила Ленинградский институт точной механики и оптики по специальности «Опτικο-электронные приборы». В 1984 году защитила диссертацию на соискание ученой степени кандидата технических наук. Является автором 95 научных публикаций и 47 свидетельств о регистрации программного продукта. Область научных интересов — машинное обучение, искусственный интеллект, автоматное программирование.
Эл. адрес: natfed@list.ru

ДО
Фук Хао



Преподаватель факультета информационных технологий Данангского архитектурного университета, Дананг, Вьетнам. В 2017 году окончил магистратуру Данангского университета науки и технологий, Вьетнам, по специальности «Компьютерные науки». Является автором пяти научных публикаций. Область научных интересов — машинное обучение, базы данных.
Эл. адрес: haodp@dau.edu.vn

ЗОТИН
Александр
Геннадьевич



Доцент кафедры информатики и вычислительной техники Сибирского государственного университета науки и технологий им. академика М. Ф. Решетнёва, Красноярск. В 2005 году окончил магистратуру Сибирского государственного аэрокосмического университета им. академика М. Ф. Решетнёва по специальности «Информатика и вычислительная техника». В 2007 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором более 120 научных публикаций и 22 свидетельств на регистрацию программных продуктов. Область научных интересов — цифровая обработка изображений и видеопоследовательностей, параллельные алгоритмы обработки изображений и др.
Эл. адрес: zotin@sibsau.ru

**КАПИТОНОВ
Андрей
Андреевич**



Студент педиатрического факультета Белорусского государственного медицинского университета, Минск, Республика Беларусь.
Область научных интересов — информатизация медицины.
Эл. адрес: akapitonov1999@gmail.com

**КОСЕНКО
Петр
Олегович**



Ведущий научный сотрудник Научно-исследовательского технологического центра нейротехнологий Южного федерального университета, Ростов-на-Дону.
В 2001 году окончил бакалавриат по специальности «Естествознание. Биология, химия», в 2003 г. — магистратуру естественно-научного образования Южного федерального университета.
В 2010 году защитил диссертацию на соискание ученой степени кандидата биологических наук.
Является автором более 30 научных публикаций.
Область научных интересов — нейрофизиология, нейрохимия, сомнология.
Эл. адрес: peza-i@mail.ru

**КУРКИН
Семен
Андреевич**



Профессор лаборатории нейронауки и когнитивных технологий Центра технологий компонентов робототехники и мехатроники Университета Иннополис.
В 2003 году окончил Саратовский государственный университет им. Н. Г. Чернышевского по специальности «Радиофизика и электроника».
В 2017 году защитил диссертацию на соискание ученой степени доктора физико-математических наук.
Является автором более 150 научных публикаций, более 20 патентов на изобретения и свидетельств на программное обеспечение.
Область научных интересов — нейронаука, применение искусственных нейронных сетей, исследование когнитивных процессов, Data Science, нелинейная динамика, электроника и др.
Эл. адрес: kurkinsa@gmail.com

**ЛОБАНЦЕВ
Артем
Андреевич**



Инженер-программист факультета информационных технологий и программирования Университета ИТМО, Санкт-Петербург.
В 2020 году окончил аспирантуру Университета ИТМО по специальности «Информатика и вычислительная техника».
Является автором 14 научных публикаций.
Область научных интересов — применение нейросетевых моделей в медицине, робототехника, байесовские методы в машинном обучении.
Эл. адрес: lobantseff@gmail.com

**ЛОБЗЕНКО
Павел
Владимирович**



Доцент кафедры информатики и вычислительной техники Северо-Кавказского филиала Московского технического университета связи и информатики, Ростов-на-Дону.
В 1988 году окончил Ростовское высшее военное инженерное училище Ракетных войск по специальности «Системы управления летательных аппаратов».
В 1999 году защитил диссертацию на соискание ученой степени кандидата технических наук.
Является автором более 100 научных публикаций.
Область научных интересов — оптимальная идентификация, оценивание, стохастические динамические системы (объекты).
Эл. адрес: pasha.van@list.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

МИЛОСЕРДОВ
Дмитрий
Игоревич



Аспирант Санкт-Петербургского института информатики и автоматизации РАН. В 2018 году окончил Университет ИТМО по специальности «Информационная безопасность». Является автором семи научных публикаций. Область научных интересов — искусственный интеллект, нейронные сети.
Эл. адрес: dmmil94@yandex.ru

НГУЕН
Нанг Хунг Ван



Аспирант факультета информационных технологий Данангского университета науки и технологий, Дананг, Вьетнам. В 2011 году окончил магистратуру Данангского университета науки и технологий, Вьетнам, по специальности «Компьютерные науки». Является автором пяти научных публикаций. Область научных интересов — машинное обучение, геометрическая алгебра.
Эл. адрес: nguyenvan@dut.udn.vn

ОСИПОВ
Василий
Юрьевич



Профессор, главный научный сотрудник, руководитель лаборатории информационно-вычислительных систем и технологий программирования Санкт-Петербургского института информатики и автоматизации РАН. В 1981 году окончил Высшее военно-морское училище радиоэлектроники им. А. С. Попова по специальности «Радиотехнические средства». В 2000 году защитил диссертацию на соискание ученой степени доктора технических наук. Является автором более 100 научных публикаций и семи патентов на изобретения. Область научных интересов — интеллектуальные системы, нейронные сети, моделирование, информационная безопасность.
Эл. адрес: osipov_vasiliy@mail.ru

ПИЦИК
Елена
Николаевна



Младший научный сотрудник лаборатории нейронауки и когнитивных технологий Университета Иннополис. В 2017 году окончила Саратовский национальный исследовательский государственный университет им. Н. Г. Чернышевского по специальности «Программная инженерия». Область научных интересов — машинное обучение, искусственные нейронные сети, интерфейсы мозг-компьютер, анализ ЭЭГ, постинсультная реабилитация, нелинейная динамика.
Эл. адрес: e.pitsik@innopolis.ru

ПОЙМАНОВА
Екатерина
Дмитриевна



Старший преподаватель кафедры безопасности информационных систем Санкт-Петербургского государственного университета аэрокосмического приборостроения. В 2005 году окончила Санкт-Петербургский государственный университет телекоммуникаций им. проф. М. А. Бонч-Бруевича по специальности «Информационные системы в области связи». Является автором более 15 научных публикаций. Область научных интересов — системы и технологии хранения данных.
Эл. адрес: e.d.poymanova@gmail.com

СОВЕТОВ
Борис
Яковлевич



Профессор кафедры информационных систем Санкт-Петербургского государственного электротехнического университета «ЛЭТИ», заслуженный деятель науки и техники РФ, действительный член Российской академии образования. В 1960 году окончил Ленинградский электротехнический институт им. В. И. Ульянова (Ленина) по специальности «Автоматика и телемеханика». В 1974 году защитил диссертацию на соискание ученой степени доктора технических наук. Является автором более 400 научных публикаций. Область научных интересов — теория и практика информационных систем и технологий.
Эл. адрес: bysovetov@mail.ru

СОЛОВЬЕВА
Елена
Борисовна



Профессор, заведующая кафедрой теоретических основ электротехники, ученый секретарь Санкт-Петербургского государственного электротехнического университета «ЛЭТИ».

В 1987 году окончила Ленинградский электротехнический институт им. В. И. Ульянова (Ленина) по специальности «Информационно-измерительные системы».

В 2001 году защитила диссертацию на соискание ученой степени доктора технических наук.

Является автором более 250 научных публикаций, в том числе семи монографий.

Область научных интересов — теория нелинейных динамических систем, глубокие нейронные сети, цифровая обработка сигналов и др.

Эл. адрес: selenab@hotmail.ru

ТАТАРНИКОВА
Татьяна
Михайловна



Профессор кафедры безопасности информационных систем Санкт-Петербургского государственного университета аэрокосмического приборостроения.

В 1993 году окончила Восточно-Сибирский технологический институт по специальности «Электронно-вычислительные машины, комплексы, системы и сети».

В 2007 году защитила диссертацию на соискание ученой степени доктора технических наук.

Является автором более 100 научных публикаций.

Область научных интересов — инфокоммуникации, взаимодействие неоднородных сетей.

Эл. адрес: tm-tatarn@yandex.ru

ТАТИБАНА
Канта



Доцент университета Когакуйн, Токио, Япония.

В 1997 году окончил Нагойский Университет, Япония, по специальности «Информатика».

В 2002 году защитил диссертацию на соискание ученой степени кандидата технических наук (PhD) в Нагойском Университете.

Является автором 50 научных публикаций.

Область научных интересов — компьютерный интеллект, взаимодействие человека и компьютера

Эл. адрес:

kanta@cc.kogakuin.ac.jp

ФАВОРСКАЯ
Мargarита
Николаевна



Профессор, заведующая кафедрой информатики и вычислительной техники Сибирского государственного университета науки и технологий им. академика М. Ф. Решетнёва, Красноярск.

В 1980 году окончила Рыбинский авиационный технологический институт по специальности «Конструирование и производство электронно-вычислительной аппаратуры».

В 2011 году защитила диссертацию на соискание ученой степени доктора технических наук.

Является автором около 160 научных публикаций.

Область научных интересов — распознавание образов, цифровая обработка изображений, кластерный анализ, интеллектуальные технологии обработки данных и др.

Эл. адрес: favor'skaya@sibsau.ru

ФАМ
Конг Тханг



Преподаватель факультета информационных технологий Данангского университета науки и технологий, Дананг, Вьетнам.

В 2013 году окончил Тульский государственный университет по специальности «Вычислительные машины, комплексы, системы и сети».

В 2016 году защитил диссертацию на соискание ученой степени кандидата технических наук в Тульском государственном университете.

Является автором 20 научных публикаций.

Область научных интересов — обработка изображений, машинное обучение, наука о данных.

Эл. адрес: pcthang@dut.udn.vn

ФАМ
Минь Туан



Преподаватель факультета информационных технологий Данангского университета науки и технологий, Дананг, Вьетнам.

В 2007 году окончил университет Миэ, Япония, по специальности «Информационные технологии».

В 2012 году защитил диссертацию на соискание ученой степени кандидата технических наук в Нагойском Университете, Япония.

Является автором 50 научных публикаций.

Область научных интересов — искусственный интеллект, мягкие вычисления, геометрическая алгебра.

Эл. адрес: pmtuan@dut.udn.vn

**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

**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

**ЩЕРБАНЬ
Игорь
Васильевич**



Доцент, главный научный сотрудник Научно-исследовательского технологического центра нейротехнологий Южного федерального университета, Ростов-на-Дону.

В 1989 году окончил Ростовское высшее военное инженерное училище Ракетных войск по специальности «Системы управления летательных аппаратов».

В 2007 году защитил диссертацию на соискание ученой степени доктора технических наук.

Является автором более 100 научных публикаций и изобретений.

Область научных интересов — оптимальная идентификация, оценивание, стохастические динамические системы (объекты).
Эл. адрес: shcheri@mail.ru

**ЩЕРБАНЬ
Оксана
Георгиевна**



Доцент кафедры информационных и измерительных технологий Института высоких технологий и пьезотехники Южного федерального университета, Ростов-на-Дону.

В 1993 году окончила Южный федеральный университет по специальности «Математика, информатика и вычислительная техника».

В 2011 году защитила диссертацию на соискание ученой степени кандидата технических наук. Является автором 30 научных публикаций и изобретений.

Область научных интересов — цифровая обработка сигналов, непараметрическая идентификация, стохастические динамические системы (объекты).
Эл. адрес: shchero@mail.ru

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, doi;

— для журнальных статей — фамилия и инициалы авторов, полное название статьи, название журнала, год издания, номер журнала, номера страниц, doi;

— 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/paperules>): 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: i-us.spb@gmail.com

Сайт: www.i-us.ru