

Cybernetics and Computer Engineering

4 (206)/2021

SCIENTIFIC JOURNAL ■ FOUNDED IN 1965 ■ PUBLISHED 4 TIMES PER YEAR ■ KYIV

CONTENTS

Informatics and Information Technologies

MOROZ O.H., STEPASHKO V.S. Comparative Features of Multilayered Iterative Algorithm GMDH and Deep Feed-Forward Neural Networks GMDH and Deep Feed-Forward Neural Networks	5
СУРОВЦЕВ І.В., ВЕЛИКИЙ П.Ю., ГРИЦАЄНКО М.О., ГАЛІМОВА В.М. Аналітична система для моніторингу та оцінювання ризиків споживання питної води ...	17

Intelligent Control and Systems

VOLKOV O.Ye., TARANUKHA V.Yu., LINDER Ya.M., KOMAR M.M., VOLOSHENIUK D.O. Devising an Acoustic Method for Investigation of a Complex Form Object Parameters	39
---	----

Medical and Biological Cybernetics

KRYVOVA O.A., KOZAK L.M., KOVALENKO O.S., NENASHEVA L.V. Prediction of Surgery Control Parameters in Cardiology to Optimize the Emission Fraction Values with the Help of Neural Networks	54
VOVK M.I., KUTSIK O.A. Mobile AI-technology for Forming the Personalized Movement Rehabilitation Plan After a Stroke	73

System Index of Articles Published in 2021	89
To Attention of Authors	91

Cybernetics and Computer Engineering

4 (206)/2021

SCIENTIFIC JOURNAL ■ FOUNDED IN 1965 ■ PUBLISHED 4 TIMES PER YEAR ■ KYIV

CONTENTS

Informatics and Information Technologies

MOROZ O.H., STEPASHKO V.S. Comparative Features of Multilayered Iterative Algorithm GMDH and Deep Feed-Forward Neural Networks	5
SUROVTSEV I.V., VELYKYI P.Y., HRYTSAIENKO M.O., GALIMOVA V.M. Analytical System for Monitoring and Assessing of Risks of Drinking Water Consumption	17

Intelligent Control and Systems

VOLKOV O.Ye., TARANUKHA V.Yu., LINDER Ya.M., KOMAR M.M., VOLOSHENIUK D.O. Devising an Acoustic Method for Investigation of a Complex Form Object Parameters	39
---	----

Medical and Biological Cybernetics

KRYVOVA O.A., KOZAK L.M., KOVALENKO O.S., NENASHEVA L.V. Prediction of Surgery Control Parameters in Cardiology to Optimize the Emission Fraction Values with the Help of Neural Networks	54
VOVK M.I., KUTSIK O.A. Mobile AI-technology for Forming the Personalized Movement Rehabilitation Plan After a Stroke	73

System Index of Articles Published in 2021	89
--	----

To Attention of Authors	91
-------------------------------	----

Кібернетика 4 (206)/2021 та обчислювальна техніка

НАУКОВИЙ ЖУРНАЛ ■ ЗАСНОВАНИЙ У 1965 р. ■ ВИХОДИТЬ 4 РАЗИ НА РІК ■ КИЇВ

ЗМІСТ

Інформатика та інформаційні технології

- МОРОЗ О.Г., СТЕПАШКО В.С. Порівняльні особливості багаторядного ітераційного алгоритму МГУА та глибинних нейромереж прямого поширення 5
- СУРОВЦЕВ І.В., ВЕЛИКИЙ П.Ю., ГРИЦАЄНКО М.О., ГАЛІМОВА В.М. Аналітична система для моніторингу та оцінювання ризиків споживання питної води ... 17

Інтелектуальне керування та системи

- ВОЛКОВ О.С., ТАРАНУХА В.Ю., ЛІНДЕР Я.М., КОМАР М.М., ВОЛОШЕНЮК Д.О. Розроблення методу акустичного дослідження параметрів об'єкта складної форми 39

Медицина та біологічна кібернетика

- КРИВОВА О.А., КОЗАК Л.М., КОВАЛЕНКО О.С., НЕНАШЕВА Л.В. Прогнозування керувальних параметрів операційного втручання у кардіології для оптимізації значень фракції викиду за допомогою нейромережі 54
- ВОВК М.І., КУЦЯК О.А. Мобільна AI-технологія формування персоналізованого плану реабілітації рухів після інсульту 73

- Системний показник статей, опублікованих у 2021 році 89

- До уваги авторів 91

DOI: <https://doi.org/10.15407/kvt206.04.005>

UDC 0004.021

MOROZ O.H., PhD (Engineering),
Senior Researcher of the Dept. for Information
Technologies of Inductive Modeling
ORCID: 0000-0002-0356-8780,
e-mail: olhahryhmoroz@gmail.com

STEPASHKO V.S., DSc (Engineering), Professor,
Head of the Dept. for Information
Technologies of Inductive Modeling
ORCID: 0000-0001-7882-3208,
e-mail: stepashko@irtc.org.ua
International Research and Training Centre
for Information Technologies and Systems
of the National Academy of Sciences of Ukraine
and Ministry of Education and Science of Ukraine,
40, Acad. Glushkov av., Kyiv, 03187, Ukraine

COMPARATIVE FEATURES OF MULTILAYERED ITERATIVE ALGORITHM GMDH AND DEEP FEED-FORWARD NEURAL NETWORKS

Introduction. Deep neural networks are effective tools for solving actual tasks such as data mining, modeling, forecasting, pattern recognition, clustering, classification etc. They differ with respect to the architecture design, learning methods and so on. Most simple and widely used are deep feed-forward supervised NNs.

The purpose of the paper is to compare briefly main features of the deep feed-forward deterministic supervised networks with the Multilayered Iterative Algorithm of GMDH (MIA GMDH) and to formulate main ideas of constructing a new class of hybrid deep networks based on the MIA neural network.

Methods. Most usable deep feed-forward supervised neural networks have been studied: multilayered perceptron, convolutional NN and some its modifications, polynomial neural networks, genetic polynomial neural network etc.

Results. There was carried out a comparative analysis of main features of the MIA GMDH neural network with the characteristics of other deep deterministic supervised neural networks. The most promising approaches are identified to improve the performance of this network, particularly by hybridization with methods of computational intelligence. The main idea of building a new class of hybrid deep networks based on MIA GMDH is formulated.

Conclusions. *MIA GMDH and its modifications are original representatives of the self-organizing networks potentially giving best results, especially for big data case. Hybridization of GMDH-based NNs with stochastic methods of computational intelligence is suggested to achieve a synergetic effect.*

Keywords: *multilayered iterative algorithm of GMDH (MIA GMDH), self-organizing neural network, neural network architecture, deep neural networks, feed-forward neural networks, supervised neural networks, deep learning.*

INTRODUCTION

Deep neural networks (DNNs) [1] are effective tools for solving actual tasks such as forecasting, data mining, pattern recognition, clustering, classification etc. Under the term “deep neural networks” is most often understood a neural network with more than two hidden layers [2].

There are many various deep neural networks most usable of which are presented in [1, 3–7]. As to the learning methods, they may be divided into:

- supervised (algorithms are learned to predict outputs from the input data and all observations of a dataset are labeled);
- unsupervised (the internal structure is determined from the input data and all the observations belonging in a dataset are unlabeled);
- semi-supervised (only part of the dataset observations are labeled);
- with reinforcement learning (labeled input/output pairs are not needed, the machine is allowed to interact with its environment and is “rewarded” when it performs the task correctly).

By architecture design neural networks (NN) generally are divided into feed-forward and feedback neural networks (with memory cells). In this paper, the emphasis is placed only on deep feed-forward supervised NNs.

ANALYSIS OF THE PROBLEM

Deep feed-forward supervised NNs include *deterministic* NNs such as multilayered perceptron, extreme learning machines, liquid state machines, convolutional NN and some its modifications (Deconvolutional NN, Π -nets, residual network, GoogleNet, AlexNet, VGGNet). Besides, there are used networks with *probability rules* such as capsule network, deep belief networks, deep convolutional inverse graphics networks etc.

At the same time, there are known algorithms realizing principles of the Group Method of Data Handling (GMDH) and being typically interpreted as the Polynomial Neural Networks of deterministic type and the GMDH-based Genetic polynomial neural networks of probabilistic type.

Generally, modern deterministic deep feed-forward networks have such main disadvantages as overfitting, slow operation speed, a large amount of the needed computing resources. There is a need to search for such architecture of a neural network and methods for its training which could help to eliminate these shortcomings without appearing new ones.

PROBLEM STATEMENT

It is important to study the features of the deep networks, find ideas that contribute to the elimination of some of the above shortcomings, which could

help to create more efficient neural networks. Only strongly deep deterministic feed-forward neural networks (with more than three hidden layers) are considered below and compared with the architecture of the Multilayered Iterative Algorithm of GMDH (MIA GMDH) to determine most promising approaches to improving the deep NNs using some GMDH ideas.

Hence, the **purpose of this paper** is to compare briefly main features of the deep feed-forward deterministic supervised networks with the MIA GMDH neural network and to formulate main ideas of constructing a new class of hybrid deep networks based on MIA GMDH.

CHARACTERISTICS OF THE DEEP FEED-FORWARD DETERMINISTIC NEURAL NETWORKS

Multilayered perceptron (MLP) [9–11] feeds information from the input layer of the network to its output layer, and there is no feedback between the layers until inputs arrives at the outputs. The MLP consists of a large number of perceptrons organized in layers and each unit in a layer connects to all other neurons from the previous layer. Each connection is a parameter of the network. These connections are not all equal and can differ in strengths or weights. The weights of these connections represent the knowledge of the network. The MLP consist of three kinds of layers: 1) input layer with raw data; 2) hidden layer(s) with sequences of functions to be applied to the previous hidden layers inputs or outputs; 3) the output layer is a finite function or a set of functions.

The MLP can use linear or non-linear activation functions. Every layer node is a fully connected one, and in some realizations the nodes number in every layer is the same. In many realizations the activation function across hidden layers is identic. To find optimal parameters, a learning rule is needed. A general approach is to determine an error function along with an optimization algorithm for finding optimal parameters by minimizing the error for training data.

The MLP like most others feed-forward NN is trained by a back-propagation algorithm, although the Stochastic Gradient Descent is presently used for computational efficiency. The error being back-propagated is often some change of the difference between inputs and the outputs. Given that the NN has sufficiently hidden neurons, it can theoretically model ever relationship between the input and output. Practically, their use is a lot more limited but they are popularly hybridized with other networks for forming new NNs.

The Stochastic Gradient Descent computes a gradient for a set of randomly chosen training samples (batch) and updates the parameters for this batch sequentially. This leads to a quicker learning, a drawback is a growth in inaccuracy. But for big data sets the speed edge outweighs this drawback. Using the gradient descent leads to the overfitting that occurs when a function corresponds too closely to a particular set of data and the model cannot give correct results on samples that were not used as training samples.

The MLP output is obtained from the input as a model which can be usable without knowledge how the output should be structured to build a relatively fast and easy NN. The MLP NNs are good for both classification and prediction.

Convolutional NN (ConvNet) [12–15] receives images as an input, use them for training a classifier and consist of eight weight layers [13]. In this CNN

a neuron is only connected to nearby neurons in the next layer to essentially reduce the full parameters number in the network.

Convolutional Layer applies a convolution filter to the image for detection image features. In convolutional layers each node only concerns itself with close neighboring cells. These convolutional layers also tend to shrinking with an increase in the number of layers, by easily divisible input factors.

Each convolutional layer contains a series of filters known as convolutional kernels. The filter is a matrix of integers that are used on a subset of the input pixel values of the same size as the kernel. Each pixel is multiplied by corresponding value in the kernel, and then the result is summed up for a single value for simplicity representing a grid cell, like a pixel, in the output channel/feature map. These are linear transformations and each convolution is a type of affine function. In computer vision the input is often a three channel RGB image. The kernel strides over the input matrix of numbers moving horizontally column by column, sliding/scanning over the first rows in the matrix containing the images pixel values. Then the kernel strides down vertically to subsequent rows. Note, the filter may stride over one or several pixels at a time. In other non-vision applications, a one-dimensional convolution may slide vertically over an input matrix.

In CNN models there are often more than three convolutional kernels, 16 kernels or even 64 kernels in a convolutional layer are common. These different convolution kernels act as a different filter creating a channel/feature map representing something different. For example, kernels could filter top edges, bottom edges, and diagonal lines and so on. In much deeper networks these kernels could be filtered to animal features such as eyes or bird wings. Having a higher number of convolutional kernels creates a higher number of channels/feature maps and a growing number of data and uses more memory due to this.

A kernel will be shared totally with other neurons that are connected to their local receptive fields. The results of these calculations between the local receptive fields and neurons using the same kernel will be saved in a matrix defined as an activation map. Various kernels will result in various activation maps, and the kernels number can be regulated with hyper-parameters.

In this way, regardless of the full number of connections between neurons in a network, the full number of weights corresponds only to the size of the local receptive field (the size of the kernel). The convolutional network architecture generally consists of four types of layers: convolution, pooling, activation and fully connected.

ReLU Activation Layer. The convolution maps are passed through a nonlinear activation layer (such as Rectified Linear Unit (ReLU), tanh, sigmoid etc.) which substitutes filtered images negative numbers with zeros and often applied to the values from the convolutional operations between the input and the kernel. These values are stored in the activation maps, which will be passed to the next network layer. The shared local connectivity and weights help essentially in reducing the full network parameters number.

Besides, shared local connectivity and weights are important in effective images processing. Using a kernel that shares identic weights can find patterns from all the local regions in the image and various kernels can recover various kinds of patterns of the image.

Pooling Layer aims at decreasing the dimension of the input vector with some pre-specified pooling method with conserving as much information as

possible. Also a pooling layer is able to introduce spatial invariance into the network to improve the model generalization. To carry out pooling, such layer uses zero-padding, stride and a size of pooling window as hyper-parameters.

Pooling layers help to monitor overfitting by reducing the number of parameters and calculations in the network. There are many kinds of pooling methods, such as min-pooling, averaging-pooling, stochastic pooling and fractional max-pooling. The most usable pooling method is max-pooling which to be superior in dealing with images by capturing invariances efficiently. Max-pooling recovers the maximum value within each specified sub-window across the activation map.

Fully Connected Layers. After a few iterations of pooling and convolution layers, before output layer there is a classical MLP for further processing the data and to further model non-linear relationships of the input features. These networks are called DCNNs but the abbreviations and names between these two are often used exchangeable. Fully connected layers get an input vector containing the image flattened pixels which have been corrected, filtered and reduced using convolution and pooling layers. The softmax function is applied to the outputs of the fully connected layers to give the probability of a class the image belongs to.

However, newly the profit of this has been questioned because many parameters are introduced by this, leading potentially to overfitting. Consequently, many researchers started to construct CNN architecture without fully connected layer using other techniques such as max-over-time pooling to substitute the linear layers role.

Π -Nets [14] are a new class of DCNNs, particularly polynomial neural networks with output as high-order polynomial of the input, and can be implemented using special type of skip connections and their parameters can be represented via high-order tensors. The Π -Nets have better representation power than typical DCNNs and produce good results without the use of non-linear activation functions in a large tasks number.

The Π -Nets make state-of-the-art results in solving such tasks as image generation. In family of Π -Nets the output is a high-order polynomial of the input. For avoiding the combinatorial explosion in the parameters number of polynomial activation functions, Π -Nets use a special skip connections type to implement the polynomial expansion.

Normalisation [15] is the process of subtracting the mean and dividing by the standard deviation. It transforms the range of the data to be between -1 and 1 making the data use the same scale sometimes called Min-Max scaling. It is common to normalize the input features, standardizing the data by removing the mean and scaling to unit variance. It is often important when the input features are centered around zero and have variance of the same order. With some tasks such as image analysis the data are scaled so that its range is between 0 and 1 , most simply dividing the pixel values by 255 . This also allows the training process to find the optimal parameters quicker.

Batch normalization [15] has benefits of helping to make a network output giving more stable predictions, reduce overfitting through regularization and speed up training by an order of magnitude. Batch normalization is the process of carrying normalization within the scope activation layer of the current batch, subtracting the mean of the batches activations and dividing by the standard deviation of them. This is necessary as even after normalizing the input as some activation can be higher, which can cause the subsequent layers to act abnormally and make the network less stable.

As batch normalization has scaled and shifted the activation outputs, the weights in the next layer will no longer be optimal.

Stochastic gradient descent (SGD) would undo the normalization, as it would minimize the loss function. To prevent this effect, two trainable parameters can be added to each layer to allow SGD to deformalize the output. These parameters are a mean parameter “beta” and a standard deviation parameter “gamma”. Batch normalization sets these two weights for each activation output to allow the normalization to be reversed to get the raw input; this avoids affecting the stability of the network by avoiding update the other weights.

Universal approximation theorem [15]. A large enough CNN can solve any solvable problem. The *Universal approximation theorem* essentially states if a problem can be solved it can be solved by a deep neural network, given enough layers of affine functions layered with non-linear functions. Essentially a stack of linear functions followed by non-linear functions could solve any problem that is solvable.

Practically when implementing this, it can be many matrix multiplications with large enough matrices followed by RELU, stacked together these have a mathematical property resulting in being able to solve any arbitrary complex mathematical function to any arbitrary high level of accuracy assuming one have the time and resource to train it.

Whether this would give the neural network understanding is a debated topic, especially by cognitive scientists. The argument is that no matter how well you approximate the syntax and semantics of a problem, you never understand it. This is basically the foundation of Searle’s Chinese Room Argument. Some would argue that does it matter if you can approximate the solution to the problem well enough that it is indistinguishable from understanding the problem.

Deep convolutional NNs are mainly focused on applications such as detection of objects, processing of images, processing of audio and natural language processing, image classification, optical character recognition.

It is worth to emphasize that all the deep neural networks mentioned above are those with the given number of layers.

MULTILAYERED ITERATIVE ALGORITHM GMDH AS A SELF-ORGANIZING DEEP NEURAL NETWORK

The worldwide known MIA GMDH [16, 17] is effective data mining tool, one of the most successful inductive modeling methods which extraction knowledge directly from the data based on experimental measurements or statistical observations. It was developed by O. Ivakhnenko in 1965 as multilayer deep feed forward neural network that belongs to class of deep Polynomial Neural Networks with theoretically unlimited number of layers which are set during learning process. It is now considered as the first ever multi-layer self-organized NN and O. Ivakhnenko is often called as the father of deep learning [1, 16]. The GMDH algorithm was first used in modeling complex systems with a number of inputs and one output.

The main GMDH network goal is actually to construct a function in a feed-forward network on the basis of a second-degree transfer function. The method uses information directly from a data sample and minimizes the impact of an author a priori assumptions on the modeling results; finds regularity in data and selects informative input arguments; automatically finds the model structure and its parameters.

Any GMDH algorithm solves a discrete optimization task to construct the optimal complexity model by the given external criterion minimum based on the data sample separation:

$$f^* = \arg \min_{f \in \Phi} CR(f),$$

where CR is a selection criterion as a measure of the model $f \in \Phi$ quality. A model selection criterion is called "external" if it is based on additional information that is not contained in the data used for calculation of model parameters. The set Φ of models being compared can be formed using iterative and sorting-out generators of model structures of diverse complexities which differ by various variants of generation techniques and organization of minimum search of a given external criterion based on additional information that is not contained in the data used for calculation of model parameters.

For realizing the external supplement principle, the parameter estimations by the least squares method LSM (usually) and criteria values are calculated on various parts of a sample $W=[X, y]$, where X, y are a matrix and vector of n measurements of m arguments and one output respectively. The input sample W is splitted into two subsets: training (A) and checking (B). The *regularity criterion* calculated for a model $f \in \Phi$ is most commonly used among all GMDH criteria:

$$AR_{B|A}(f) = \|y_B - \hat{y}_{B|A}(f)\|^2 = \|y_B - X_{Bf} \hat{\theta}_{Af}\|^2$$

which means "a model f error on B with parameters obtained on A ", and X_{Af}, X_{Bf} are submatrices of the matrix X containing columns that correspond to a partial model $f \in \Phi$ being considered.

One of main elements of an iterative GMDH algorithm such as the polynomial partial description can be considered as an elementary neuron of GMDH neural network. The GMDH NN solves discrete optimization task by successive approaching to the criterion minimum: the models complexity on a layer arises due to the pairwise "crossing" F best models from the previous layer.

The complication process stops after the criterion starts to increase. Originality of the network with such neurons consists in high speed of local adjustment of neuron weights and automatic global optimization of units number. *The depth of MIA GMDH network is determined automatically.* The MIA GMDH is used in different problems of knowledge discovery and data analysis, modeling of nonlinear systems, function approximation, forecasting and modeling, classification, pattern recognition and clustering.

Therefore, MIA GMDH is a kind of deep neural networks without given number of layers. Other types of the GMDH-based networks are presented below.

GMDH-BASED DEEP POLYNOMIAL NNs

PNN [18] is a flexible neural architecture whose structure is developed through learning. This network eliminates some GMDH drawbacks such as 1) tending for generation quite complex polynomial for relatively simple systems; 2) tending to produce an overly complex model with highly nonlinear systems; 3) enabling to generate a highly versatile structure with less than three input variables.

The PNN come with a high flexibility level as each node (processing element forming a partial description (PD)) can have a various number of input variables as well as exploit a various order of the polynomial (linear, quadratic, cubic etc.). Architecture is not fixed in advance and becomes fully optimized parametrically and structurally. Particularly, the number of the PNN architecture layers can be modified by adding new layers, if necessary, namely network grows over the training period. In this sense, PNN is a *self-organizing network*. Performance of DPNN depends strongly on the input variables number and the polynomial order which are determined by trial and error approach.

Genetic polynomial neural network (GPNN) [19] is used for improving the PNN performance. GPNN determines the input variables number and the all neurons order with genetic algorithm (GA). Genetic algorithm used for searching between all possible values for the input variables number and the polynomial order. Each of the PD outputs is obtained by using a few kinds of high order polynomials (linear, quadratic, cubic) of the input variables. Although the PNN is structured by a systematic design procedure, it has some drawbacks to be solved. PNN productivity depends on the number of input arguments and the each PD order. These parameters must be determined by trial and error method, which has low efficiency and heavy computational load. The GPNN uses GA to alleviate the above averted drawbacks. The GA is used for determining the input variables number in each PD and to determine the appropriate kind of polynomials in each PD.

There are also many GMDH-type NNs [20] which are characterized by absence of the sample separation into training and checking parts and use various model quality criteria. But they generally retain the MIA GMDH main structure features, particularly selection process.

In general, the hybridization approach has proven to be effective for training neural networks, in particular the GMDH-based NNs.

COMPARATIVE ANALYSIS OF DEEP FEED-FORWARD DETERMINISTIC NEURAL NETWORKS

The main features of complex NNs analysis are following:

- 1) overfitting,
- 2) number of layers,
- 3) ability to dimension reduce,
- 4) ability to synthesize the models,
- 5) type of connections between neurons,
- 6) training method,
- 7) number of outputs,
- 8) application areas.

The comparison of these features in MIA GMDH and others deep feed-forward NNs is presented below.

Multilayered perceptron: 1) overfitting: exist; 2) number of layers: fixed; 3) availability of dimension reduce: absent; 4) ability to synthesizes the models: exist; 5) type of connections between neurons: fully connected; 6) learning algorithm: gradient descent; 7) number of outputs: many; 8) main application: classification, modelling, prediction.

Convolutional NNs: 1) overfitting: exist; 2) number of layers: constant; 3) availability of dimension reduce: absent; 4) ability to synthesizes the models: exist; 5) type of connections between neurons: fully connected; 6) learning algorithm: gradient descent; 7) number of outputs: many; 8) application: processing of images, audio, natural language, image classification.

GMDH-based NNs: 1) overfitting: absent; 2) number of layers: dynamic; 3) availability of dimension reduce: exist; 4) ability to synthesizes the models: exist; 5) type of connections between neurons: partly connected; 6) learning algorithm: LMS; 7) number of outputs: one; 8) main application: modeling, forecasting, classification, clasterization, clusterization.

Compared to MLP, CNN-based NNs possesses the following advantages: 1) local connections (each neuron connected only to a little number of neurons for speed up convergence and reducing parameters); 2) sharing of weight (a connections group can share the same weights for reducing parameters); 3) down-sampling reduction of dimensionality.

Neuron networks based on GMDH have the advantages in comparison with convolutional networks by the absence of overfitting, self-tuning of the architecture, the ability to obtain a model in explicit form, but their drawback is the existence of only one possible solution.

Therefore, the main idea of constructing a new class of hybrid deep networks based on MIA GMDH is to create hybrid structures with methods of computational intelligence, in particular genetic algorithms.

Table 1. These comparative features are presented below in the table.

Features	<i>Multilayered perceptron</i>	<i>Convolutional NNs</i>	<i>GMDH-based NNs</i>
Overfitting	present	present	absent
Number of layers	fixed	constant	dynamic
Availability of dimension reduce	absent	exists	exists
Ability to synthesize the models	exists	absent	exists
Type of connections between neurons	fully connected	partly connected	pairwise connected
Learning algorithm	gradient descent	gradient descent	LMS
Number of outputs	multiple	multiple	single
Main application areas	modelling, prediction, classification	processing of images, audio, natural language, images classification	modeling, forecasting, classification, clasterization

CONCLUSION

In this article a comparative analysis of neural networks based on GMDH and the most well-known deep supervised feed-forward neural networks is presented.

Deterministic networks include networks in which the number of layers is constant (extreme learning machines, liquid state machines, convolutional NN and some her modifications), ones with given layers number that can change due to the peculiarity of the problem being solved (multilayered perceptron), and neural networks with a dynamic number of layers that is adjusted by the network itself during the learning process.

The main representative of the latest self-organizing networks, which potentially give the best results, especially in the case of a large number of input data, is MIA GMDH and its modifications such as Deep polynomial neural network, Genetic polynomial neural network and GMDH-type NNs. These NNs do not use gradient-based methods for training and do not suffer from the overfitting.

The main output of this analysis is that hybridization of GMDH-based NN with stochastic methods of computational intelligence is promising to achieve a synergetic effect.

REFERENCES

1. Schmidhuber J. Deep Learning in Neural Networks: An Overview. *Neural Networks*. 2015, Vol. 61, pp. 85–117.
2. Bengio Y. Learning Deep Architectures for AI. *Foundations and Trends in Machine Learning*. 2009, Vol. 2: No. 1, pp. 1–127.
3. Li Deng. A tutorial survey of architectures, algorithms, and applications for deep learning. APSIPA Transactions on Signal and Information Processing, Volume 3, E2, 2014, pp.1-29. doi:10.1017/atsip.2013.9
4. Li Deng, Dong Yu. Deep Learning: Methods and Applications. *Foundations and Trends in Signal Processing*. 2014, Vol. 7: No. 3–4, pp. 197–387.
5. Shahrudnejad A. A Survey on Understanding, Visualizations, and Explanation of Deep Neural Networks. CoRR, 2021, URL: <https://arxiv.org/pdf/2102.01792v1.pdf> (Last accessed: 10.08.2021)
6. Shaveta D., Munish K., Maruthi Rohit A., Gulshan K. A Survey of Deep Learning and Its Applications: A New Paradigm to Machine Learning. *Archives of Computational Methods in Engineering*. 2020, 27 (4), pp. 1071–1092.
7. URL: <https://www.mdpi.com/2504-3900/47/1/9> (Last accessed: 15.08.2021)
8. Ivakhnenko A.G., Lapa V.G.. Cybernetic Predicting Devices. *CCM Information Corporationm*, 1965, 256 p. (In Russia)
9. Ben-Bright B., Zhan Y., Ghansah B., Amankwah R., Keddy Wornyo D., Ansah E. Taxonomy and a Theoretical Model for Feedforward Neural Networks. *International Journal of Computer Applications*. 2017, 163(4), pp. 39–49.
10. Hopfield J.J. Neural Networks and physical systems with emergent collective computational abilities. *Proc. Natl. Acad. Sci. USA*, 1982, 79, pp. 2554–2558.
11. Li Z., Yang W., Peng S., Liu F. A Survey of Convolutional Neural Networks. *Analysis, Applications, and Prospects*. 2020, pp.21
12. URL: https://fanchenyou.github.io/homepage/docs/cnn_survey.pdf (Last accessed: 10.07.2021)
13. Srinivas S. et al. A Taxonomy of Deep Convolutional Neural Nets for Computer Vision. *Frontiers in Robotics and AI*. 2016, pp.?
14. Chrysos G., Moschoglou S., Bouritsas G., Deng J., Panagakis Y., Zafeiriou S. Deep Polynomial Neural Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence (T-PAMI)*, 2021.

15. URL: <https://towardsdatascience.com/an-introduction-to-convolutional-neural-networks-eb0b60b58fd7> (Last accessed: 17.07.2021)
16. Stepashko V. Developments and Prospects of GMDH-Based Inductive Modeling. *Advances in Intelligent Systems and Computing II: Selected Papers from the International Conference on Computer Science and Information Technologies CSIT 2017* / N. Shakhovska, V. Stepashko, Editors. AISC book series, Springer, 2018, Vol. 689, pp. 474–491.
17. Stepashko V. On the Self-Organizing Induction-Based Intelligent Modeling. *Advances in Intelligent Systems and Computing III: Selected Papers from the International Conference on Computer Science and Information Technologies CSIT 2018* / N. Shakhovska, M.O. Medykovsky, Editors. AISC book series, Springer, 2019, Vol. 871, pp. 433–448.
18. Oh S.-K., Pedrycz W., Park B.-J. Polynomial neural networks architecture: analysis and design. *Computers and Electrical Engineering*. 2003, 23, pp. 703–725.
19. Farzi S. A New Approach to Polynomial Neural Networks based on Genetic Algorithm. *International Scholarly and Scientific Research & Innovation*. 2008, 2(8), pp. 2700–2707.
20. Moroz O.H., Stepashko V.S. An overview of hybrid structures of GMDH-like neural networks and genetic algorithms. *Inductive modeling of complex systems: Coll. sciences works*. 2015, 7, K. : IRTC ITS NASU, pp. 173–191.

Received 03.08.2021

Мороз О.Г., канд. техн. наук,
старш. наук. співроб. відд. інформаційних
технологій індуктивного моделювання
ORCID: 0000-0002-0356-8780,
e-mail: olhahryhmoz@gmail.com

Степашко В.С., д-р. техн. наук, професор
зав. відд. інформаційних технологій
індуктивного моделювання
ORCID: 0000-0001-7882-3208,
e-mail: stepashko@irtc.org.ua

Міжнародний науково-навчальний центр
інформаційних технологій та систем
НАН України та МОН України,
пр. Академіка Глушкова, 40, м. Київ, 03187, Україна

ПОРІВНЯЛЬНІ ОСОБЛИВОСТІ БАГАТОРЯДНОГО ІТЕРАЦІЙНОГО АЛГОРИТМУ МГУА ТА ГЛИБИННИХ НЕЙРОМЕРЕЖ ПРЯМОГО ПОШИРЕННЯ

Вступ. Глибинні нейронні мережі є ефективним інструментом для розв’язання актуальних задач: аналізу даних, моделювання, прогнозування, розпізнавання образів, кластеризації, класифікації тощо. Вони відрізняються між собою зокрема архітектурою, методом навчання. Найпростішими і широко використовуваними є глибинні нейромережі прямого поширення.

Метою статті є коротке порівняння основних особливостей глибинних детермінованих контрольованих нейронних мереж прямого поширення з нейронною мережею багаторядного ітераційного алгоритму (БІА) МГУА та формулювання основних ідей побудови нового класу гібридних глибинних мереж на основі БІА МГУА.

Методи. Було вивчено найбільш використовувані глибинні контрольовані нейронні мережі прямого поширення: багатошаровий персептрон, згорткову нейромережу та деякі її модифікації, поліноміальну нейронну мережу, генетичну поліноміальну нейронну мережу тощо.

Результати. Здійснено порівняльний аналіз основних особливостей нейронної мережі БІА МГУА з характеристиками інших глибоких детермінованих контрольованих нейронних мереж. Визначено найбільш перспективні підходи до вдосконалення продуктивності цієї мережі, зокрема, на основі гібридизації з методами обчислювального інтелекту. Сформульовано основну ідею побудови нового класу гібридних глибоких мереж на основі БІА МГУА.

Висновки. Оригінальним представником самоорганізованих мереж, які потенційно дають кращі результати, особливо в разі великих даних, є БІА МГУА та його модифікації. Запропоновано гібридизацію нейромереж на основі МГУА зі стохастичними методами обчислювального інтелекту для досягнення синергетичного ефекту.

Ключові слова: багатошаровий ітераційний алгоритм МГУА (БІА МГУА), самоорганізована нейронна мережа, архітектура нейронної мережі, глибокі нейронні мережі, нейронні мережі прямого поширення, нейронні мережі з учителем, глибоке навчання.

DOI: <https://doi.org/10.15407/kvt206.04.017>

УДК: 004.67: 543.062

СУРОВЦЕВ І.В.¹, д-р техн. наук, старш. наук. співроб.,
зав. відд. екологічних цифрових систем
ORCID: 0000-0003-1133-6207,
e-mail: dep115@irtc.org.ua,

ВЕЛИКИЙ П.Ю.¹, аспірант,
відд. екологічних цифрових систем
ORCID: 0000-0002-8118-9348,
e-mail: velykyi305@gmail.com

ГРИЦАЄНКО М.О.², аспірант,
Об'єднаний дослідницький підрозділ 7504,
ORCID: 0000-0002-5979-0663,
e-mail: maryna.hrytsaienko@ipcms.unistra.fr, gmari@ukr.net

ГАЛІМОВА В.М.³, канд. хім. наук,
доцент кафедри аналітичної
і біоорганічної хімії та якості води
ORCID: 0000-0001-9602-1006,
e-mail: galimova2201@gmail.com

¹ Міжнародний науково-навчальний центр
інформаційних технологій та систем
НАН України та МОН України,
пр. Акад. Глушкова, 40, Київ, 03187, Україна

² Страсбурзький інститут фізики і хімії матеріалів,
Національний центр наукових досліджень — Університет Страсбурга,

⁴ вул. Блеза Паскаля 4, Страсбург, 67081, Франція

³ Національний університет біоресурсів
і природокористування України,
вул. Героїв Оборони, 17, корп. № 2, Київ, 03041, Україна

АНАЛІТИЧНА СИСТЕМА ДЛЯ МОНІТОРИНГУ ТА ОЦІНЮВАННЯ РИЗИКІВ СПОЖИВАННЯ ПИТНОЇ ВОДИ

Вступ. Використання електрохімічної аналітичної системи «Аналізатор ІХП» дає змогу проводити екологічний моніторинг питної води та водних об'єктів, оцінювати та прогнозувати ризики впливу токсикантів на здоров'я людей та навколишнє середовище.

Мета статті — вдосконалення інформаційної технології визначення концентрації хімічних елементів для експресного визначення якості питної води та методів оцінювання ризику їхнього впливу на біосферу.

© СУРОВЦЕВ І.В., ВЕЛИКИЙ П.Ю., ГРИЦАЄНКО М.О., ГАЛІМОВА В.М., 2021

ISSN 2663-2586 (Online), ISSN 2663-2578 (Print). Cyb. and Comp. Eng. 2021. № 4 (206)

Методи. Нова інформаційна технологія використовує для вимірювання концентрацій імпульсні методи хронопотенціометрії, хроноіонометричний метод прямої потенціометрії та методи оцінювання екологічного ризику впливу хімічних речовин на довкілля.

Результати. Розроблено інформаційну технологію з машинним навчанням, хмарними технологіями та використанням інтелектуальних моделей маси добавки хімічного елемента, яка дає змогу за результатами одного вимірювання експресно визначити концентрації елементів у водному об'єкті, використовуючи спосіб порівняння сигналів, та оцінити ризики впливу хімічних речовин на здоров'я людей у разі споживання забрудненої питної води.

Висновки. Удосконалена аналітична система «Аналізатор ІХП» забезпечує експресне вимірювання концентрацій 12 хімічних речовин (Pb, Cd, Cu, Zn, Se, I, K, Na, Ca, F, NO₃, NH₄) у водних об'єктах на місці та ще восьми токсичних елементів (Hg, As, Sn, Ni, Co, Mn, Cr, Fe) у лабораторії, що дає змогу оперативної та в повному обсязі визначати екологічну якість питної води та об'єктів навколишнього середовища. Застосування іон-селективних та вимірювальних електродів на основі благородних металів підвищує екологічність та швидкість виконання досліджень. Використання методології оцінювання ризику впливу хімічних елементів на людину та довкілля дає змогу прогнозувати виникнення захворювань внаслідок тривалого споживання забрудненої питної води чи визначати придатність водою для зрошування та риборозведення.

Ключові слова: концентрація хімічних елементів та сполук, екологічний ризик, іон-селективні електроди, інверсійна хронопотенціометрія, питна вода.

ВСТУП

Інтенсивний розвиток промисловості та зростання сільськогосподарського виробництва ведуть до поступового забруднення біосфери важкими металами і шкідливими хімічними речовинами. Активізація антропогенного впливу великої кількості токсикантів на людину та навколишнє середовище вимагає постійного моніторингу якості питної води та харчових продуктів і визначення екологічного стану водних об'єктів довкілля.

В Україні вода, призначена для споживання людиною, повинна відповідати Державним санітарно-гігієнічним нормам 2.2.4-171-10 [1], в країнах ЄС — Директиві 98/83/ЄС [2], згідно з якими визначені у воді санітарно-гігієнічні (токсикологічні) показники не повинні перевищувати гранично допустимих концентрацій (ГДК). Термін ГДК означає таку концентрацію хімічного елемента чи його сполук, яка за щоденного впливу на організм людини протягом тривалого часу не викликає патологічних змін чи захворювань, встановлюваних сучасними методами досліджень у будь-які періоди життя теперішнього і наступного поколінь.

Серед токсикологічних показників дуже небезпечними є важкі метали (свинець, кадмій, ртуть, миш'як та інші), які проявляють найбільший канцерогенний вплив на здоров'я людини, і їх обов'язково контролюють, під час моніторингу та визначення якості питної води [3].

Нагальною потребою є розроблення комп'ютерних систем та приладів екологічного контролю, побудованих з використанням сучасних бездротових технологій, хмарних сервісів та систем мобільного зв'язку [4].

Електрохімічні методи аналізу широко використовують для визначення концентрацій токсичних елементів у питній воді, харчових продуктах та в інших об'єктах навколишнього середовища. Поширеними є вольтамперометричні

лабораторні та мобільні переносні аналізатори, що їх випускають у багатьох країнах, наприклад, прилади VA 694 та 797 VA Computrace фірми METRONM (Швейцарія) [5], аналітична система Model 600C Series Electrochemical Analyzer/Workstation (США), автономний аналізатор PDV6000plus фірми Cogent Environmental (Велика Британія), російські прилади: АKB-07 МК, АВА-3, СТА-Елемент, ЭКОТЕСТ-ВА, Экспертиза-ВА-3D тощо.

Для моніторингу об'єктів навколишнього середовища перспективним є використання електрохімічних методів інверсійної хронопотенціометрії та прямої потенціометрії. У Міжнародному центрі інформаційних технологій та систем розроблено інформаційну технологію [6], реалізовану в аналітичній системі «Аналізатор ІХП», яка застосовує метод інверсійної хронопотенціометрії (ІХП), нові імпульсні методи інверсійної хронопотенціометрії (ІХП, ДІХП, ОІХП) [7] та метод хроноіометрії [8, 9] для лабораторного визначення концентрацій 20 хімічних речовин у питній воді, харчових продуктах та об'єктах довкілля.

Якість питної води залежить від екологічного стану джерел водопостачання. Близько 80 % питного водопостачання в Україні здійснюють з поверхневих водних об'єктів, в яких вода помірно забруднена або забруднена. Використання малоефективних технологічних схем водопідготовки не дозволяє забезпечити санітарну і токсичну безпеку питної води, тому необхідно мати можливість періодично оцінювати якість забрудненої питної води та оцінювати ризики захворюваності за її споживання.

У міжнародній практиці базовою методологією є комплексний аналіз екологічних ризиків (ERA — Environmental Risk Assessment), який охоплює структурований поетапний аналіз всіх можливих ситуацій, несприятливих для людини і навколишнього середовища [10]. У ЄС питання оцінювання ризику погіршення здоров'я населення затверджено законодавчо в багатьох директивах та технічних регламентах, які детально розглянуто в українських наукових працях [3, 11]. В Україні випущено методичні рекомендації оцінювання ризику для здоров'я населення від забруднення атмосферного повітря [12], в РФ користуються керівництвом оцінювання ризику для здоров'я населення у разі впливу забруднювальних хімічних речовин [13].

Можливість експресно визначати токсичні параметри та одночасно оцінювати ризики для здоров'я людини у разі споживання забрудненої питної води значно покращать функційні характеристики системи «Аналізатор ІХП».

ПОСТАНОВКА ПРОБЛЕМИ

Проведений аналіз шляхів виконання експресного вимірювання концентрацій хімічних елементів у питній воді із застосуванням електрохімічних методів хронопотенціометрії показав, що необхідно дотримуватись таких принципів:

- мінімальна кількість досліджень хімічних елементів у визначенні токсикологічної якості питної води;
- екологічність проведення дослідження (застосування вимірювальних твердих електродів з благородних металів, які зможуть срібний електрод з амальгамою ртуті, заборонений для використання Директивами ЄС в європейських країнах та використання доступних хімічних реактивів з екологічно допустимою концентрацією);

– використання інтелектуальних математичних моделей інверсії (застосування адаптивних моделей маси добавки хімічного елемента, побудованих шляхом машинного навчання, з урахуванням об'єкта водокористування та умов проведення електрохімічного аналізу);

– мобільність проведення досліджень (можливість виконання аналізу у природних умовах із застосуванням переносних приладів та сучасних технологій зв'язку).

Для впровадження методів експресного визначення якості питної води необхідно збільшити швидкість вимірювання концентрацій хімічних елементів, але не погіршити метрологічні характеристики аналізу. Це можливо здійснити за рахунок застосування нових підходів до оброблення електрохімічної інформації:

1) визначення концентрацій токсичних елементів за способом порівняння сигналів інверсії у природній воді (без підготовки проби) із сигналами інверсії шаблонів бази даних, одержаних за результатами дослідження близького за характеристиками об'єкта, для якого вимірюно концентрації в аналітичній системі за способом добавки;

2) застосування електрохімічного методу іонометрії, ґрунтованого на принципах прямої потенціометрії з використанням іон-селективних електродів, для експресного вимірювання у воді концентрацій найрозповсюдженіших хімічних елементів та сполук (калію, натрію, кальцію, фтору, нітратів, аміаку) приладом для хронопотенціометричного аналізу [8, 9, 14–19].

У технічних системах вимірювання інформаційна технологія (ІТ) забезпечує оброблення отриманих сигналів, які характеризують фізичний об'єкт, у вигляді послідовності обчислювальних процедур, формуючи за потреби математичні моделі досліджуваних процесів. Це дає змогу отримати кількісні та якісні оцінки об'єкта — результат вимірювання.

ІТ нерозривно пов'язана з поточним станом пристрою вимірювання, тому будь-яка суттєва зміна технічних характеристик (чутливості, методів дослідження, інтерфейсу передавання даних тощо) спричиняє потребу в удосконаленні або розробленні нової інформаційної технології, яка враховуватиме особливості вхідних сигналів, об'єктів дослідження, фізичних процесів та вимог до результатів вимірювання.

За загальною схемою використання ІТ в технічних системах вимірювання (рис. 1), пристрій отримує інформацію про поточний стан об'єкта дослідження (питної води) і передає інформаційній технології отримані значення (змінні, сигнали, образи тощо), а інформаційна технологія обробляє отримані дані, створює моделі процесів, формує кількісні та якісні оцінки стану об'єкта у вигляді результатів вимірювання.

ІТ визначення екологічного стану об'єктів навколишнього середовища, реалізована в аналітичній системі «Аналізатор ІХП», дає змогу визначити масову концентрацію 14 токсичних елементів (ртуті, арсену, свинцю, кадмію, цинку, міді, олова, нікелю, кобальту, заліза, марганцю, селену, йоду та хрому) за методами інверсійної хронопотенціометрії з чутливістю до 0,01 мкг/дм³ [6, 7] та 6 хімічних речовин (калію, натрію, кальцію, фтору, нітратів, аміаку) за методом хроноіонометрії (прямої потенціометрії з іон-селективними електродами) [8, 9].

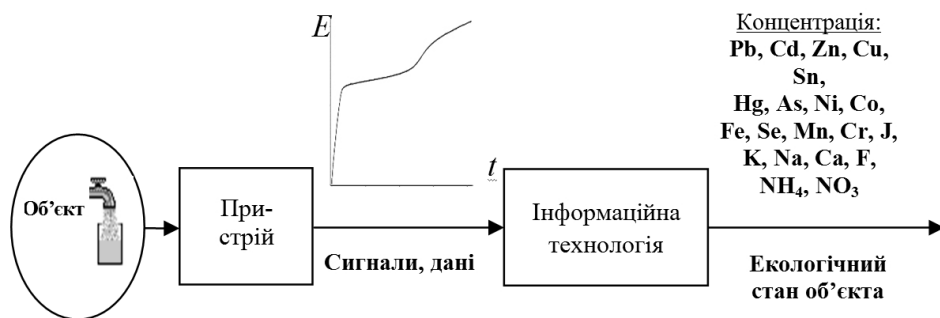


Рис. 1. Схема використання ІТ для визначення екологічного стану об'єкта

Мета — вдосконалення ІТ визначення екологічного стану об'єктів доквілля для експресного визначення якості питної води шляхом використання імпульсних методів хронопотенціометричного аналізу та розроблення нового методу експресного вимірювання концентрацій.

ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ ВИЗНАЧЕННЯ КОНЦЕНТРАЦІЙ ХІМІЧНИХ ЕЛЕМЕНТІВ ТА СПОЛУК

ІТ складається з інформаційної системи (ІС) оброблення аналітичних даних, електрохімічного блоку вимірювання аналітичних сигналів, пристрою візуалізації результатів визначення концентрацій та оцінювання ризиків для здоров'я людини (комп'ютер, планшет, мобільний пристрій). ІС зберігає в розташованій у хмарному сховищі базі даних (БД) таку інформацію, як значення ГДК різних типів об'єктів: харчових продуктів (хліба, молока, зерна, дитячого харчування), продукції рослинництва та тваринництва, води різного природного походження (питної, поверхневої, підземної, очищеної), ґрунтів різних типів, повітря робочої зони тощо. У БД зберігаються параметри оцінювання ризиків для здоров'я людини, шаблони електрохімічних параметрів вимірювання хімічних речовин для різних методів дослідження, оброблені аналітичні сигнали, результати вимірювання концентрацій хімічних елементів та визначені значення ризиків. Можливість використання такої БД спрощує та покращує сервісне обслуговування діяльності хіміка-аналітика.

Концентрацію токсичного елементу визначають за методами інверсійної хронопотенціометрії (ІХП) способом добавки відомої маси стандартного зразка іонів хімічної речовини. Суть методу ІХП полягає в електрохімічному концентруванні на вимірювальному електроді іонів важких металів та їхньому електророзчиненні за вольтамперостатичного режиму (інверсії).

Основними аналітичними функціями методу ІХП є час інверсії елемента, який за стандартизованих умов концентрування та вимірювання є прямо пропорційним його концентрації в розчині, та пік потенціалу інверсії — якісна характеристика елемента.

Процес інверсії накопичених елементів здійснюється в режимі постійного струму та фіксується у вигляді хронопотенціограми $E(t)$ (значення потенціалів інверсії E у часі t). Час інверсії елемента визначається заданими електрохімічними параметрами вимірювання: потенціалом та часом

регенерації (електрохімічного очищення робочої поверхні електроду), потенціалом та часом концентрування, потенціалом розчинення, потенціалом оброблення (кінцевий потенціал хронопотенціограми) та значенням опору в ланцюзі розчинення, який регулює швидкість процесу інверсії іонів.

Концентрацію токсичних елементів визначають за методом добавки стандартного розчину іонів елемента у такій послідовності:

— аналізують фоновий розчин або холосту пробу та визначають час інверсії фону τ_f ;

— аналізують розчин проби та визначають час інверсії проби τ_p ;

— у пробу вносять добавку (одну або декілька добавок) стандартного розчину іонів елемента, що аналізують, та визначають час інверсії проби з добавкою τ_d ;

— за визначеними значеннями часу інверсії фону τ_f , проби τ_p , проби з добавкою τ_d та відомою масою добавки іонів m визначають концентрацію C елемента Me в аналізованому об'єкті за формулою

$$C_{Me} = \frac{T_p - T_f}{T_d - T_p} \cdot m \cdot k, \quad (1)$$

де k — коефіцієнт розрахунку масової концентрації елементу у пробі об'єкта за значеннями його концентрації в розчині проби [6].

ПРОБЛЕМА ЕКОЛОГІЧНОСТІ ЕЛЕКТРОХІМІЧНИХ ДОСЛІДЖЕНЬ

У розробленій аналітичній системі «Аналізатор ІХП» концентрації декількох токсичних елементів (свинцю, кадмію, міді, цинку, заліза, марганцю, хрому, селену, йоду) визначають з використанням вимірювального срібного електроду з амальгамою ртуті, що заборонено Директивами ЄС. Тому, одним з важливих завдань для створення технології експресного вимірювання токсикологічної якості питної води є застосування вимірювальних електродів з благородних металів, таких як платина та золото. Для цього необхідно для кожного токсичного елемента підібрати вид електрода, електролітичний розчин та параметри електрохімічного дослідження.

Серед забруднювачів, які потрапляють до питної води, найнебезпечнішим є свинець, який належить до речовин першого класу небезпеки, і тому його вміст у воді, харчових продуктах та атмосферному повітрі строго контролюють. Відомо, що він є одним з важливих видів мінеральної сировини і, водночас, є одним з глобальних і наднебезпечних забруднювачів довкілля, віднесених до класу канцерогенних для людини.

За результатами досліджень встановлено, що найефективнішим для визначення концентрацій свинцю у питній воді є платиновий вимірювальний електрод. Розглянемо приклад вимірювання концентрацій свинцю у питній воді з використанням платинового та срібного електродів з амальгамою ртуті.

Виконаємо вимірювання свинцю у модельному розчині 10 мл 2М HCl з концентрацією $C_{Pb} = 10 \text{ мкг/дм}^3$ ($0,01 \text{ мкг/см}^3$), що відповідає гранично допустимій концентрації (ГДК) свинцю у питній воді $0,01 \text{ мг/дм}^3$ [1]. Електрохімічні параметри та похибки вимірювання концентрацій свинцю у модельному розчині $C_{Pb} = 0,01 \text{ мг/дм}^3$ наведено в табл. 1.

Таблиця 1. Електрохімічні параметри та похибки концентрації свинцю

Електрод	Потенціал концентрування, мВ	Час концентрування, с	Потенціал зчитування, мВ	Час інверсії проби,	Виміряна концентрація, мкг/см ³	Відносна похибка, %
Срібний з амальгамою ртуті	-900	90	-280	0,52	0,00962	3,8
Платиновий	-600	90	+150	51,9	0,00947	5,3

Результати порівняння свідчать, що електрохімічні умови вимірювання концентрацій на індикаторних електродах відрізняються, час інверсії свинцю для срібного електрода набагато менше ніж для платинового електрода, відносні похибки визначення концентрацій свинцю на обох електродах менше ніж нормована похибка 10 % [2], але платиновий електрод має більшу чутливість.

Застосування платинового та золотого електродів для вимірювання концентрацій токсичних елементів за методами ІХП є можливим, що уможливило розроблення інформаційної технології експресного визначення якості питної води та води різного природного походження.

МАТЕМАТИЧНА МОДЕЛЬ МАСИ ДОБАВКИ ХІМІЧНОГО ЕЛЕМЕНТА

Однією з невирішених проблем застосування електрохімічних методів ІХП в аналітичних дослідженнях є процес визначення маси добавки стандартного зразку іонів елемента у вимірюванні концентрацій способом добавки для об'єктів довкілля з невідомою концентрацією досліджуваних елементів, коли необхідно шляхом експериментального підбору визначити необхідні електрохімічні параметри дослідження або вибрати шаблон визначення заданої концентрації.

Цей процес потребує багато часу, тому нагальною проблемою є його автоматизація шляхом побудови математичної моделі визначення маси добавки інверсії елемента залежно від значень електрохімічних параметрів дослідження.

Згідно з теоретичними основами інверсійної хронопотенціометрії, основне аналітичне рівняння методу має вигляд:

$$\tau_i = \frac{kRC_{Me}}{\varphi_i} t_{kon}, \quad (2)$$

де τ_i — час інверсії, k — перехідний коефіцієнт, R — опір у зовнішньому ланцюзі вимірювання, C_{Me} — концентрація елемента, t_{kon} — час концентрування, φ_i — потенціал інверсії.

З рівняння (2) випливає, що за незмінності інших параметрів (об'єму, температури тощо) час інверсії є прямо пропорційним концентрації іону елемента в розчині, часу концентрування та опорів у зовнішньому ланцюзі вимірювання.

З іншого боку, згідно з інформаційною технологією [6], концентрація елемента C_{Me} (маса іонів у розчині проби m) у разі використання однієї або декількох добавок визначається за зворотною електродною характеристикою — лінійною залежністю маси m іонів елемента від часу інверсії t_{inv} :

$$m = S_0^* + S^* \cdot t_{inv}, \quad (3)$$

де m — маса добавки стандартного зразка іонів елемента, S_0^* — параметр достовірності вимірювання концентрацій за способом багатьох добавок, приймають рівним нулю; $S^* = m / t_{inv}$ — нахил зворотної хроноелектродної характеристики (чим він менше, тим чутливішою та якіснішою є пара електродів за однакових умов вимірювання); $t_{inv} = \tau_i = t_d - t_p$; — різниця між часом інверсії добавки t_d та часом інверсії проби t_p (приріст часу інверсії за рахунок добавлення в розчин маси іонів m).

Підсумовуючи, зробимо висновок, що процес інверсії у кожному діапазоні концентрацій, за стабільних значень інших змінних, залежить від трьох параметрів:

- 1) маси добавки m стандартного зразка іонів елемента;
- 2) часу інверсії t_{inv} ;
- 3) часу концентрування t_{kon} .

Крім того, згідно з рівнянням (3), залежність маси добавки m та часу інверсії t_{inv} від параметру нахилу зворотної хроноелектродної характеристики можна надати у вигляді

$$m = t_{inv} \cdot f(t_{kon}). \quad (4)$$

Розглянемо алгоритм побудови математичної моделі маси добавки елемента на прикладі вимірювання концентрації свинцю на платиновому електроді.

АЛГОРИТМ ПОБУДОВИ МАТЕМАТИЧНОЇ МОДЕЛІ МАСИ ДОБАВКИ

Алгоритм побудови математичної моделі маси добавки хімічного елемента складається з таких кроків.

Крок 1. Вимірювання концентрацій у стандартних розчинах способом добавки. Виконуємо вимірювання масової концентрації іонів елемента свинцю C_{pb} у стандартних фонових розчинах 2М НСІ, об'ємом 10 см^3 , для значень шаблонів: 1 мкг/см^3 ; $0,1 \text{ мкг/см}^3$; $0,01 \text{ мкг/см}^3$; $0,001 \text{ мкг/см}^3$ (рис. 2).

Для кожного сигналу інтенсивності виконуємо моделювання та визначаємо час інверсії фону t_f , проби t_p та добавки t_d за площею відповідних компонентів у спектрах [6]. За значеннями цих параметрів будуємо зворотну хроноелектродну характеристику (рис. 3).

Розраховуємо значення концентрації свинцю C_{pb} за формулою (1) для кожного стандартного розчину.

Крок 2. Формування електрохімічних параметрів дослідження. Формуємо та зберігаємо значення електрохімічних параметрів проведених вимірювань концентрацій елемента (табл. 2):

— маса добавки стандартного зразка іонів свинцю m [мкг], наприклад, для концентрації $C_{pb} = 1 \text{ мкг/см}^3$, $m = 10 \text{ см}^3 \cdot 1,0 \text{ мкг/см}^3 = 10 \text{ мкг}$;

— час інверсії свинцю [с] розраховуємо як різницю між часом інверсії добавки t_d та часом інверсії проби t_p після моделювання, за площею компонентів свинцю у спектрах сигналів інтенсивності:

$$t_{inv} = t_d - t_p;$$



Рис. 2. Сигнали інтенсивності вимірювання свинцю $C_{Pb} = 0,001 \text{ мкг/см}^3$ (нижня крива (зеленого кольору) – фоновий розчин, середня крива (синього кольору) – розчин проби, верхня крива (червоного кольору) – розчин проби з добавкою $m = 0,01 \text{ мкг}$)

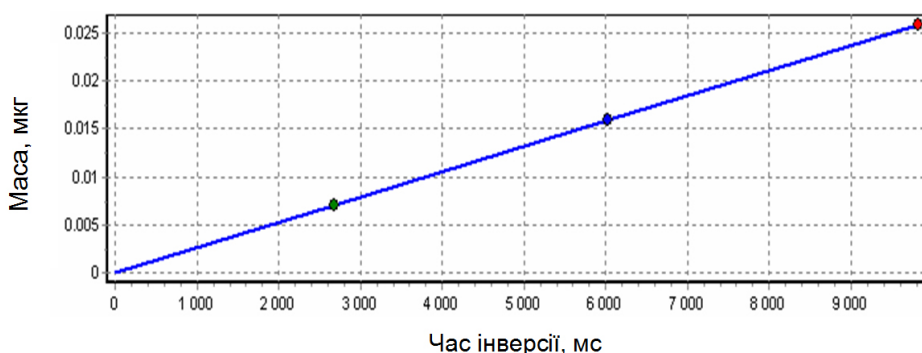


Рис. 3. Зворотна хроноелектродна характеристика вимірювання свинцю

Таблиця 2. Електрохімічні параметри вимірювання та визначення концентрацій свинцю у різних діапазонах

Концентрація, C , мкг/см^3	Виміряна концентрація C_{Pb} , мкг/см^3	Маса добавки m , мкг	Час інверсії $t_{ин}$, с	Нахил звор. характеристики, S^* , мкг/с	Час концентрування, $t_{кон}$, с
1,0	0,986	10	1,163	8,6	60
0,1	0,1001	1,0	1,330	0,752	90
0,01	0,0979	0,1	2,933	0,0341	120
0,001	0,001015	0,01	3,636	0,00275	150

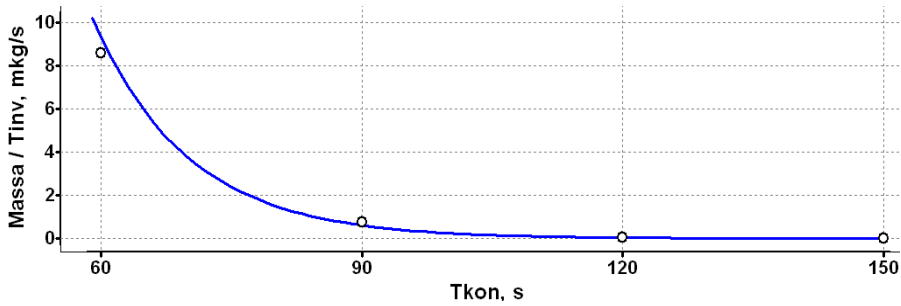


Рис. 4. Експериментальні дані та модельна залежність $S^* = f(t_{kon})$

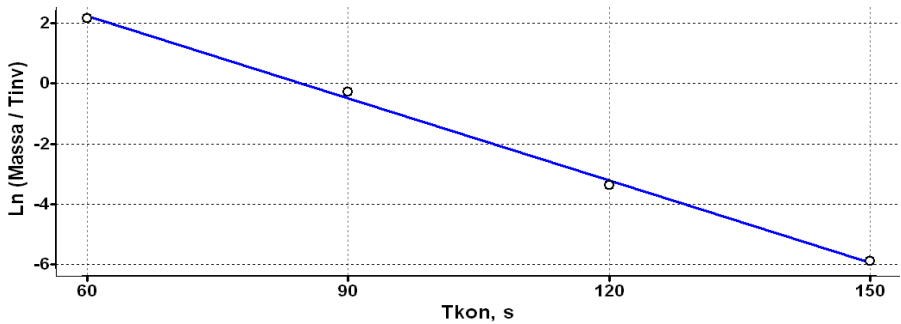


Рис. 5. Лінійна логарифмічна модель залежності $\ln(S^*) = f(t_{kon})$

Таблиця 3. Статистичні характеристики математичної моделі маси інверсії свинцю

Концентрація, C , мкг/см ³	Маса добавки m , мкг	Час інверсії t_{inv} , с	Час концен- трування t_{kon} , с	Модельна маса добав- ки m^* , мкг	Відносна похибка моделі ε , %
1,0	10	1,163	60	10,83	8,37
0,1	1,0	1,330	90	0,813	18,7
0,01	0,1	2,933	120	0,118	17,7
0,001	0,01	3,636	150	0,00957	4,3

— нахил або тангенс кута зворотної характеристики розраховуємо для кожної концентрації за залежністю $S^* = m / t_{inv}$ [мкг/см³] (рис. 3).

Крок 3. Побудова експериментального графіку залежності $S^* = f(t_{kon})$. Визначаємо точки експериментальних даних залежності нахилу зворотної характеристики S^* [мкг/с] від часу концентрування t_{kon} [с] (рис. 4).

Крок 4. Розрахунок моделі $S^* = f(t_{kon})$. Для лінеаризації даних логарифмуємо ординати S^* та будуємо графік $\ln(S^*) = f(t_{kon})$ (рис. 5).

Виконуємо лінійну апроксимацію логарифмічних експериментальних даних за методом найменших квадратів та визначаємо коефіцієнти рівняння $\ln(S^*) = a + b \cdot t_{kon}$ ($a = 7,68$; $b = -0,0908$).

Тоді, модель $S^* = f(t_{kon})$ матиме вигляд:

$$S^* = \exp(7,68 - 0,0908 \cdot t_{kon}). \quad (5)$$

Графічно зображуємо експоненціальну модельну залежність (5) на рис. 4.

Крок 5. Математична модель маси добавки токсичного елемента. Згідно із залежністю (5) математична модель маси добавки свинцю m^* у разі вимірювання концентрацій платиновим електродом за способом добавки матиме вигляд

$$m^* = t_{\text{inv}} \cdot \exp(7,68 - 0,0908 \cdot t_{\text{kon}}). \quad (6)$$

Визначимо статистичні характеристики (табл. 3.) побудованої моделі за експериментальними даними, де відносна похибка моделі $\varepsilon = (m - m^*) \cdot 100/m$.

За даними табл. 3, математична модель маси добавки свинцю адекватно описує експериментальні дані з максимальною відносною похибкою 18,7 %, що не перевищує нормативної відносної похибки 20 %, згідно з методиками вимірювання концентрацій свинцю у воді за методами ІХП.

МЕТОД ЕКСПРЕСНОГО ВИЗНАЧЕННЯ КОНЦЕНТРАЦІЙ У ПИТНІЙ ВОДІ

Розроблена модель маси добавки дає змогу за результатами одного вимірювання часу інверсії визначити масу іонів у розчині проби та розрахувати концентрацію хімічного елемента в об'єкті.

Особливістю експресного визначення концентрацій елемента у природній питній воді є відсутність підготовки проби, а це з хімічної точки зору не дає змогу повністю визначити наявні рухомі форми іонів, бо частина маси іонів перебуває у зв'язаному стані органічними сполуками. Визначити ступінь зв'язаності іонів теоретичним шляхом неможливо, він залежить від багатьох природних факторів: складу розчинених у воді солей, наявності органічних домішок, лужності тощо.

Для вирішення цієї проблеми введемо поняття такого **коефіцієнта активності іона** токсичного елемента (p_{Me}) у водному розчині конкретного об'єкта водопостачання, який вказує, наскільки треба змінити розраховану масу іонів, одержану за моделлю маси інверсії, щоб вона відповідала реальній масі іонів, визначеній аналітичним шляхом способом добавки. За таким саме принципом у паспортних даних на іон-селективні електроди наводяться коефіцієнти активності іонів у пробі, залежно від їхніх концентрацій у фонових розчинах. Фактично, коефіцієнти активності іонів p_{Me} вказують на зв'язаність рухомих форм іонів токсичного елемента органічними сполуками у типових об'єктах водопостачання. Природно, що коефіцієнти активності іонів будуть різними для токсичних елементів, залежно від вимірювальних електродів та об'єктів водопостачання (підземної артезіанської води, води централізованого водопостачання — з крану, води криниць, поверхневої річкової та озерної води тощо).

Коефіцієнт активності іону p_{Me} розраховують за співвідношенням

$$p_{Me} = m_0 / m^*, \quad (7)$$

де m_0 — маса іонів елемента у воді, визначена за способом добавки після підготування проби води, згідно з методикою вимірювання; m^* — модельна маса добавки іонів елемента, визначена у природній воді та розрахована за моделлю маси інверсії, наприклад для вимірювання свинцю на платиновому електроді (6).

Орієнтуючись на формулу визначення концентрацій C_{Me} (1) за способом добавки, формула для експресного визначення концентрацій C елемента Me буде такою:

$$C_{Me} = p_{Me} \cdot m^* \cdot k, \quad (8)$$

де k — перевідний коефіцієнт для розрахунку масової концентрації елемента в водному об'єкті за значеннями його концентрацій у електрохімічній комірці:

$$k = \frac{V_1}{V_2 H}, \quad (9)$$

де V_1 — об'єм розчину з підготовленою прободою води, см^3 ; V_2 — об'єм розчину з підготовленою прободою води в електрохімічній комірці, взятого для аналізу, см^3 ; H — об'єм проби об'єкта водопостачання, взятої для мінералізації та підготовки проби води (см^3).

У випадку експресного вимірювання концентрацій елемента у природній воді $V_1 = V_2 = H$, формула для розрахунку перевідного коефіцієнта буде

$$k = \frac{1}{H}. \quad (10)$$

Остаточно, з урахуванням залежності (4) та (10), формула експресного визначення масової концентрації токсичного елемента у воді C_{Me} [$\text{мкг}/\text{см}^3$] матиме вид

$$C_{Me} = p_{Me} \cdot t_{inv} \cdot S^* / H, \quad (11)$$

де p_{Me} — коефіцієнт активності іону елемента в натуральній воді, t_{inv} — час інверсії елемента [с] за результатами моделювання сигналу інтенсивності, S^* — нахил зворотної електродної характеристики [$\text{мкг}/\text{с}$] залежно від часу концентрування $S^* = f(t_{kon})$, (для свинцю $f_{Pb}(t_{kon}) = \exp(7,68 - 0,0908 \cdot t_{kon})$), H — об'єм води, взятої для аналізу, см^3 .

Наведемо у табл. 4 розраховані значення нахилу S^* для свинцю на платиновому електроді залежно від часу концентрування t_{kon} з кроком 30 с.

Формулу (11) для вимірювання свинцю в питній воді можна спростити для конкретного об'єкта водопостачання. Проведені хімічні дослідження вказують, що в артезіанській воді бюветів міста Києва реальна концентрація свинцю не перевищує значення $\text{ГДК}_{Pb} = 0,01 \text{ мкг}/\text{см}^3$ [11]. Для визначення концентрацій свинцю на платиновому електроді в артезіанській воді необхідно використати електрохімічні параметри шаблону $0,001 \text{ мкг}/\text{см}^3$ з $t_{kon} = 150 \text{ с}$ (табл. 2), взяти пробу натуральної води $H = 5 \text{ мл}$, додати 5 мл фоновому розчину соляної кислоти (4М HCl) та виконати дослідження.

Згідно з описаною методикою експресного вимірювання свинцю в артезіанській воді, для $S^* / H = 0,002632 / 5 = 0,0005264$ формула (11) буде:

$$C_{Pb} = 0,0005264 \cdot p_{Me} \cdot t_{inv}, \quad (12)$$

Таблиця 4. Значення нахилу зворотної електродної характеристики для свинцю на платиновому електроді

Час концентрування $t_{кон}, c$	Нахил зворотної характеристики $S^*, мкг/с$
30	142,0
60	9,319
90	0,6114
120	0,04012
150	0,002632
180	0,0001727

Отже, математична модель маси добавки (6) дає змогу експресно визначити концентрацію свинцю в питній артезіанській воді за формулою (12), виконавши тільки одне вимірювання.

АЛГОРИТМ ОЦІНЮВАННЯ РИЗИКІВ ПОЯВИ ЗАХВОРЮВАНЬ ЛЮДИНИ У РАЗІ СПОЖИВАННЯ ЗАБРУДНЕНОЇ ПИТНОЇ ВОДИ

Оцінювання ризиків появи захворювань у разі споживання забрудненої питної води здійснюється послідовним виконанням таких трьох етапів:

етап 1 — вимірювання концентрацій хімічних елементів проб питної води;

етап 2 — оцінювання ризику для здоров'я людини;

етап 3 — аналіз результатів оцінювання ризиків у разі споживання забрудненої питної води.

На першому етапі за допомогою приладу «Аналізатор ІХП» виконуємо вимірювання концентрацій хімічних елементів у питній воді.

На другому етапі, відповідно до методичного підходу та рекомендацій [12, 13], оцінюємо ризик для здоров'я людини окремо для неканцерогенних та канцерогенних ефектів.

Для оцінювання ризику для здоров'я людини, пов'язаного із забрудненням питної води токсичними речовинами, використовуємо безпорогову модель оцінювання потенційного неканцерогенного ризику, що базується на ймовірнісних оцінках розвитку несприятливих ефектів.

Оцінку потенційного неканцерогенного ризику впливу i -ої хімічної речовини, що міститься у питній воді та має токсичний ефект впливу, визначаємо за рівнянням

$$Risk_i = 1 - \exp \left(- \left(\ln(0,84) / (ГДК_i \times K_{ri}) \right) \times C_i \right), \quad (13)$$

де $Risk_i$ — імовірність розвитку неспецифічних токсичних ефектів за хронічної інтоксикації (від 0 до 1); C_i — концентрація хімічної i -ої речовини у питній воді: середня добова концентрація речовини, що потрапляє в організм людини з питною водою впродовж тривалого часу; для оцінювання ефектів від тривалого (хронічного) впливу речовин використовуємо значення їхніх середніх концентрацій (щонайменше за 1 рік); $ГДК_i$ — норматив гранично допустимої концентрації речовини (табл. 6.5); K_{ri} — коефіцієнт запасу (табл. 5).

Оцінку сумарного (комбінованого) неканцерогенного ризику $Risk_n$ від впливу всіх m забруднювальних речовин визначаємо за допомогою рівняння

$$Risk_n = 1 - (1 - Risk_1) \times (1 - Risk_2) \times \dots \times (1 - Risk_m), \quad (14)$$

де $Risk_1, Risk_2, \dots, Risk_m$ — неканцерогенний ризик від впливу кожної речовини, або розраховуємо згідно з методологією визначення екологічного ризику комбінованого впливу кількох хімічних речовин для оцінювання здоров'я людей [20].

Основним параметром для оцінювання канцерогенного ризику є чинник канцерогенного потенціалу SF_o , що відображає верхню, консервативну оцінку канцерогенного ризику за очікуваної (середньої) тривалості життя людини (70 років). Цей чинник характеризує міру додаткового індивідуального канцерогенного ризику або ступінь збільшення ймовірності розвитку раку внаслідок впливу канцерогену.

Оцінку канцерогенного ризику речовини, що має токсичний ефект, визначаємо за використання експоненціальної моделі:

$$Risk_i = 1 - \exp(-SF_o \times LADD_i), \quad (15)$$

де $LADD_i$ — величина середньодобової дози, яку визначаємо таким чином:

$$LADD_i = (C_i \times CR \times ED \times EF) / (BW \times AT \times 365), \quad (16)$$

де C_i — концентрація речовини у питній воді, мг/л; CR — швидкість потрапляння (кількість за одиницю часу) питної води в організм людини, л/добу (2 л/добу — дорослі, 1 л/добу — діти); ED — тривалість впливу, років (30 років — дорослі, 6 років — діти); EF — частота впливу, днів/рік (350 днів); BW — маса тіла людини, кг (70 кг — дорослі, 15 кг — діти); AT — період експозиції, років (70 років); 365 — кількість днів у році.

Якщо отримане значення ризику $Risk_k$ є вищим за 0,001, тоді сумарний канцерогенний ризик перераховуємо за рівнянням (14).

Загальну оцінку ризиків появи захворювань у разі споживання забрудненої питної води $Risk$ визначаємо як суму оцінок неканцерогенного та канцерогенного впливу:

$$Risk = Risk_n + Risk_k. \quad (17)$$

На третьому етапі аналізуємо одержані значення оцінок ризиків появи захворювань.

Кожна шкідлива речовина, що потрапила у навколишнє середовище, створює ризик загрози здоров'ю. Цей ризик залежить від дози речовини, що потрапила в організм людини.

Для аналізу величини оцінки хронічного неканцерогенного ризику використовуємо значення $Risk_n$ та відповідний вплив хронічного неканцерогенного ризику, згідно з табл. 6.

Таблиця 5. Параметри оцінювання хронічного неканцерогенного ризику у разі споживання забрудненої питної води

CAS	Речовина	RfD мг/кг	Коефі- цієнт запасу, K _r	Чинник канцеро- генного ризику SF ₀ , [мг/(кг·добу)] ⁻¹	Вразливі органи та системи
6484-52-2	Амоній	-	10	-	кров
7439-89-6	Залізо	0,3	10	-	слиззова, шкіра, кров, імунна сис- тема
7553-56-2	Йод	0,017	-	-	гормони, щитоподібна залоза
7440-43-9	Кадмій	0,0005	100	0,38	нирки, гормони
7681-11-0	Калій	0,017	-	-	
7440-70-2	Кальцій	41,4	-	-	нирки,
7440-48-4	Кобальт	0,02	10	-	кров
7439-96-5	Марганець	0,14	10	-	ЦНС, кров
7440-50-8	Мідь	0,019	10	-	шлунок, нирки, печінка
7440-38-2	Миш'як	0,0003	100	1,75	шкіра, ЦНС, серце, імунітет, гормо- ни, система вуглеводного обміну, шлунок
7440-23-5	Натрій	34,3	-	-	серце
7440-02-0	Нікель	0,02	10	-	печінка, серце, шлунок, кров, система обміну речовин
14797-55-8	Нітрати	1,6	10	-	кров, серце
7440-31-5	Олово	0,6	10	-	печінка, нирки, шлунок
7439-97-6	Ртуть	0,0003	10	-	імунна система, нирки, ЦНС, гор- мони, репродуктивна система
7439-92-1	Свинець	0,0035	3	0,047	ЦНС, кров, гормони, розвиток, репродукційна система
7782-49-2	Селен	0,005	10	-	шкіра, печінка, волосся, селезінка
7782-41-4	Фтор	0,06	10	-	зуби, кістки
7440-47-3	Хром	0,005	10	0,42	печінка, нирки, шлунок, слизові
7440-66-6	Цинк	0,3	10	-	кров

Примітки: CAS — номер за реєстром хімічних речовин Американського хімічного товариства; RfD — референтна доза, тобто величина, яка характеризує добову дію хімічної речовини протягом всього життя і, ймовірно, не призводить до виникнення неприйнятного ризику для здоров'я чутливих груп; ЦНС — центральна нервова система.

Таблиця 6. Вплив хронічного неканцерогенного ризику на здоров'я людини у разі споживання забрудненої питної води

Діапазон оцінок	Значення впливу хронічного неканцерогенного ризику
< 0,5	прийнятний, відсутні несприятливі медико-екологічні тенденції
0,05 - 0,16	викликає побоювання, виникає тенденція до зростання неспецифічної патології
0,16-0,50	небезпечний, виникає достовірна тенденція до зростання неспецифічної патології у разі появи одиничних випадків
0,50-0,84	надзвичайно небезпечний, виникає достовірне зростання неспецифічної патології у разі появи значної кількості випадків, а також тенденція до збільшення смертності населення
~ 1,0	катастрофічний, забруднення навколишнього середовища перейшло в інший якісний стан (поява випадків хронічного отруєння, зміна структури захворюваності, тенденція до збільшення смертності тощо)

У більшості країн Західної Європи та в Україні індивідуальний загальний *Risk* та канцерогенний ризик $Risk_k$, якому піддається людина, вважається дуже малим, якщо його рівень не перевищує величини 10^{-6} за рік. Тобто, від цієї причини може загинути одна людина на мільйон осіб. За цих умов додаткових дій до зниження ризику у разі споживання питної води не потрібно.

За значенням ризику вищим за 10^{-6} до 10^{-4} необхідним є оповіщення всіх зацікавлених осіб, організацій, установ та вирішення питання щодо зниження рівня ризику.

Верхня межа допустимого ризику (максимально допустимий ризик) є різною для населення і для персоналу, який працює у шкідливих умовах. Згідно з нормативами верхня межа допустимого ризику від впливу речовин з канцерогенними властивостями для людини в Україні становить 10^{-4} , що потребує проведення розширених досліджень та здійснення екстрених заходів щодо зниження ризику для здоров'я населення.

Якщо концентрації хімічних елементів є близькими або перевищують значення ГДК, то аналізуємо можливість появи змін здоров'я, складаючи вплив токсичних елементів на вражені органи та системи людини. В результаті аналізу формується висновок щодо токсикологічної якості питної води [21–28].

Отже, інформаційна технологія експресного визначення концентрацій хімічних елементів у питній воді, реалізована в аналітичній системі «Аналізатор ІХП», складається з п'яти блоків: бази даних у хмарному сховищі, блоків експрес-аналізу токсичності питної води за новим методом порівняння сигналів, аналізу екологічної якості об'єктів довкілля з використанням для вимірювання концентрацій нових імпульсних методів хронопотенціометрії, іонометричного аналізу за новим методом хроноіонометрії та блоку оцінювання ризиків появи захворювань людини у разі споживання забрудненої питної води (рис. 6).

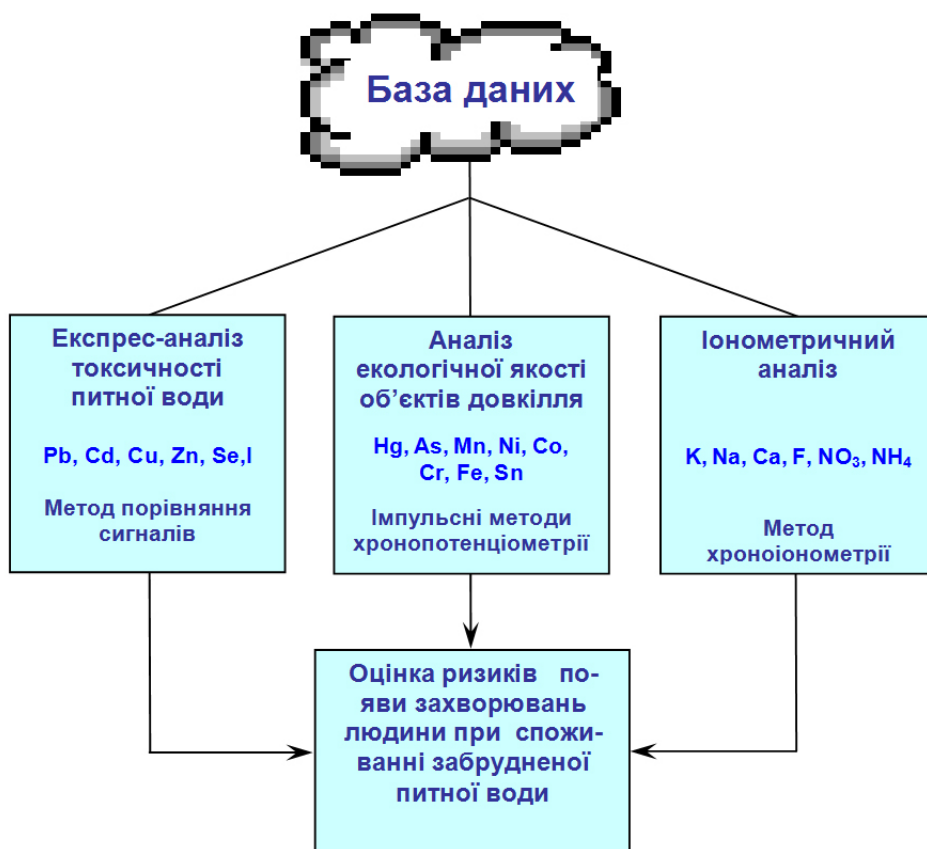


Рис. 6. Схема інформаційної технології експресного визначення концентрацій

Застосування розробленої технології забезпечує запобігання появи захворювань, спричинених вживанням неякісної питної води. Подальші зусилля буде спрямовано на розроблення мобільних застосунків, які використовують хмарні технології для зберігання даних вимірювання концентрацій хімічних елементів, одержаних приладами типу «Аналізатор ІХП».

ВИСНОВКИ

Удосконалена аналітична система «Аналізатор ІХП» забезпечує експресне вимірювання концентрації 12 хімічних речовин (Pb, Cd, Cu, Zn, Se, I, K, Na, Ca, F, NO₃, NH₄) у водних об'єктах на місці та ще вісім токсичних елементів (Hg, As, Sn, Ni, Co, Mn, Cr, Fe) в лабораторії що дає змогу оперативно та в повному обсязі визначати екологічну якість питної води та об'єктів навколишнього середовища.

Застосування іон-селективних та вимірювальних електродів на основі благородних металів підвищує екологічність та швидкість виконання досліджень. Використання методології оцінювання ризику впливу хімічних елементів на людину та довкілля уможливило прогнозування виникнення захворювань внаслідок тривалого споживання забрудненої питної води або можливості використання водойм для зрошування та риборозведення.

ЛІТЕРАТУРА

1. ДСанПіН 2.2.4-171-10. Державні санітарні норми і правила "Гігієнічні вимоги до води питної, призначеної для споживання людиною." Наказ МОЗ України від 12.05.2010 № 400. Реєстр. 1 липня 2010 р. за N 452/17747.
2. Директива Ради 98/83/ЄС "Про якість води, призначеної для споживання людиною" від 03.11.1998, http://zakon5.rada.gov.ua/laws/show/994_963
3. Прокопов В.О. Питна вода України: медико-екологічні та санітарно-гігієнічні аспекти. К.: Медицина, 2016. 400 с.
4. Гриценко В.І., Бабак О.В., Суровцев І.В. Особливості взаємозв'язку мереж 5G, 6G з великими даними, інтернетом речей та штучним інтелектом. *Cyb. and comp. eng.*, 2021. №. 2 (204), 5–18. <https://doi.org/10.15407/kvt204.02.005>
5. Ammonium — fast and robust determination according to current ISO, EPA, and ASTM standards using direct measurement. 2020, URL: <https://www.metrohm.com/en-vn/company/news/news-ammonia-ab-133/>
6. Суровцев І.В., Галімов С.К., Татарінов О.Е. Інформаційна технологія визначення концентрації токсичних елементів в об'єктах навколишнього середовища. *Кибернетика и вычисл. техника*. 2018. № 191. 5–31. DOI: <https://doi.org/10.15407/kvt191.01.005>
7. Пристрій для вимірювання концентрації хімічних елементів методами імпульсної хронопотенціометрії: патент на винахід 123459, Україна: МПК G01N 27/48 (2006.01). / О.В. Бабак, І.В. Суровцев; заявник та власник Міжн. наук.-навч. центр інформ. техн. і систем; заявл. 12.03.2019; опубл. 07.04.2021, Бюл. № 14.
8. Surovtsev I.V., Velykyi P.Y., Galimova V.M., Sarkisova M.V. Ionometric method for determination of concentrations of microelements in research of digital medicine. *Cyb. and comp. eng.*, 2020. №. 4 (220), 25–43. DOI: <https://doi.org/10.15407/kvt202.04.025>.
9. Surovtsev I.V., Galimov S.K., Galimova V.M., Sarkisova M.V. Method of chronoionometric determination of concentrations of fluorine, nitrate, ammonium in drinking water. *Cyb. and comp. eng.*, 2021. №. 1 (203), 5–25. DOI: <https://doi.org/10.15407/kvt203.01.005/>
10. Environmental Protection Agency (EPA). Policy for use of probabilistic analysis in risk assessment at the US Environmental Protection Agency // Office of Research and Development, US EPA. Washington, DC, 1997. 701 p.
11. Зоріна О. В. Гігієнічні проблеми питного водопостачання України та шляхи їх вирішення в умовах євроінтеграції: дис. ... доктор біологічних наук: 14.02.01 «Гігієна та професійна патологія» (біологічні науки): ДУ «Інститут громадського здоров'я ім. О. М.Марзєєва НАМНУ», Київ, 2019, 382 с.
12. Методичні рекомендації МР 2.2.12-142-2007. Оцінка ризику для здоров'я населення від забруднення атмосферного повітря. Затв. Наказом МОЗ України від 13.04.07 № 184. Київ, 2007. 40 с.
13. Р 2.1.10.1920-04. Руководство по оценке риска для здоровья населения при воздействии химических веществ, загрязняющих окружающую среду. М.: Федеральная служба по надзору в сфере защиты прав потребителей и благополучия человека. 2004. 256 с.
14. Eric Bakker and Ernö Pretsch. Modern Potentiometry // *Angew Chem Int Ed Engl*. 2007; 46(30): 5660–5668. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2515866>
15. Scientific Opinion on Dietary Reference Values for water. EFSA Panel on Dietetic Products, Nutrition, and Allergies (NDA) // *EFSA Journal* 2010; 8(3):1459
16. Huang, Y.; Wang, T.; Xu, Z.; Hughes, E.; Qian, F.; Lee, M.; Fan, Y.; Lei, Y.; Brückner, C.; Li, B. Real-time in situ monitoring of nitrogen dynamics in wastewater treatment processes using wireless, solid-state, and ion-selective membrane sensors. *Environ. Sci. Technol.* 2019, 53, 3140–3148.
17. Gemene Kebede L. Bakker E. Measurement of total calcium by flash chronopotentiometry at polymer membrane ion-selective electrodes. *Analytica Chimica Acta*. 2009. Vol. 648, 240–245.

18. Roy, S.; David-Pur, M.; Hanein, Y. Carbon nanotube-based ion selective sensors for wearable applications. *ACS Appl. Mater. Interfaces* 2017, 9, 35169–35177.
19. Umezawa, Y.; Bühlmann, P.; Umezawa, K.; Tohda, K.; Amemiya, S. Potentiometric selectivity coefficients of ion-selective electrodes. Part I. Inorganic cations (technical report). *Pure Appl. Chem.* 2000, 72, 1851–2082.
20. Guidance on harmonised methodologies for human health, animal health and ecological risk assessment of combined exposure to multiple chemicals // *EFSA Journal* 2019;17(3):5634. doi: 10.2903/j.efsa.2019.5634
21. Baas J, Augustine S, Marques GM and Dorne JL, 2018. Dynamic energy budget models in ecological risk assessment: from principles to applications. *Science of the Total Environment*, 628–629, 249–260
22. Bopp S, Berggren E, Kienzler A, van der Linden S and Worth A, 2015. Scientific methodologies for the assessment of combined effects of chemicals — a survey and literature review. *JRC Technical Reports*, 64.
23. ECETOC (European Centre for Ecotoxicology and Toxicology of Chemicals), 2012. The European Centre for Ecotoxicology and Toxicology of Chemicals (ECETOC) 2012 Annual Report. Available online: http://www.ecetoc.org/wp-content/uploads/2013/06/ECETOC_2012_Annual_Report.pdf
24. EFSA PPR Panel (EFSA Panel on Plant Protection Products and their Residues), 2014. Scientific Opinion on good modelling practice in the context of mechanistic effect models for risk assessment of Plant Protection Products. *EFSA Journal* 2014;12(3):3589, 92 pp. <https://doi.org/10.2903/j.efsa.2014.3589>
25. Meek ME, Boobis AR, Crofton KM, Heinemeyer G, Van Raaij M and Vickers C, 2011. Risk assessment of combined exposure to multiple chemicals: A WHO/IPCS framework. *Regulatory Toxicology and Pharmacology*, 60, S1–S14
26. Solomon KR, Wilks MF, Bachman A, Boobis A, Moretto A, Pastoor TP, Phillips R and Embry MR, 2016. Problem formulation for risk assessment of combined exposures to chemicals and other stressors in humans. *Critical Reviews in Toxicology*, 46, 835–844
27. US EPA (Environmental Protection Agency), 2011. Vocabulary Catalog List Detail-Integrated Risk Information System (IRIS) Glossary
28. Van Gestel CAM, Jonker MJ, Kammenga JE, Laskowski R and Svendsen C, 2011. Mixture Toxicity. Linking Approaches from Ecological and Human Toxicology. SETAC Press, Pensacola, USA, 320 pp. ISBN 9781439830086

Отримано 26.09.2021

REFERENCES

1. DSanPiN 2.2.4-171-10. "Hygienic requirements for drinking water intended for human consumption". *Order of the Ministry of Health of Ukraine* dated 12.05.2010 No.400. Register. July 1, 2010 for No. 452/17747 (in Ukrainian).
2. COUNCIL DIRECTIVE 98/83/EC of 3 November 1998 on the quality of water intended for human consumption (OJ L 330, 5.12.1998, p. 32), <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:01998L0083-20151027&from=EN>
3. Prokopov VO Drinking water of Ukraine: medical-ecological and sanitary-hygienic aspects. *Kyiv, Medytsyna*, 2016, 400 p. (in Ukrainian).
4. Gritsenko V.I., Babak O.V., Surovtsev I.V. Peculiarities of interconnection 5g, 6g networks with big data, internet of things and artificial intelligence. *Cyb. and comp. eng.*, 2021. № 2 (204), 5–18. <https://doi.org/10.15407/kvt204.02.005> (in Ukrainian).
5. Ammonium – fast and robust determination according to current ISO, EPA, and ASTM standards using direct measurement. 2020, URL: <https://www.metrohm.com/en-en/vn/company/news/news-ammonia-ab-133/>
6. Surovtsev I.V., Galimov S.K., Tatarinov O.E. Information technology for determining the concentration of toxic elements in environmental objects. *Kibernetika i vychislitel'naâ tekhnika*. 2018, No.1(191), pp. 5–33. DOI: <https://doi.org/10.15407/kvt191.01.005> (in Ukrainian)
7. Device for measuring the concentration of chemical elements by pulse chronopotentiometry: pat. 123459, Ukraine: IPC. G01N 27/48. № a201902429; claimed 12.03.2019; published 07.04.2021, *Bull.* № 14 (in Ukrainian).

8. Surovtsev I.V., Velykyi P.Y., Galimova V.M., Sarkisova M.V. Ionometric method for determination of concentrations of microelements in research of digital medicine. *Cyb. and comp. eng.*, 2020. №. 4 (220), 25–43. DOI: <https://doi.org/10.15407/kvt202.04.025>.
9. Surovtsev I.V., Galimov S.K., Galimova V.M., Sarkisova M.V. Method of chronoionometric determination of concentrations of fluorine, nitrate, ammonium in drinking water. *Cyb. and comp. eng.*, 2021. №. 1 (203), 5–25. DOI: <https://doi.org/10.15407/kvt203.01.005/>
10. Environmental Protection Agency (EPA). Policy for use of probabilistic analysis in risk assessment at the US Environmental Protection Agency // *Office of Research and Development*, US EPA. Washington, DC, 1997. 701 p.
11. Zorina OV Hygienic problems of drinking water supply of Ukraine and ways to solve them in terms of European integration: dis. ... Doctor of Biological Sciences: 14.02.01 "Hygiene and Occupational Pathology" (biological sciences): *SI "Institute of Public Health. OM Marzeeva NAMNU"*, Kyiv, 2019, 382 p (in Ukrainian).
12. Methodical recommendations of MR 2.2.12-142-2007. Assessment of the risk to public health from air pollution. *Approved Order of the Ministry of Health of Ukraine* dated 13.04.07 № 184. Kyiv, 2007. 40 p. (in Ukrainian)
13. P 2.1.10.1920-04. Guidelines for Assessing Public Health Risks from Exposure to Chemicals Polluting the Environment. *Moscow: Federal Service for Supervision of Consumer Rights Protection and Human Welfare*. 2004. 256 p (in Russian).
14. Eric Bakker and Ernö Pretsch. Modern Potentiometry // *Angew Chem Int Ed Engl*. 2007; 46(30): 5660–5668. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2515866>
15. Scientific Opinion on Dietary Reference Values for water. *EFSA Panel on Dietetic Products, Nutrition, and Allergies (NDA)* // *EFSA Journal* 2010; 8(3):1459
16. Huang, Y.; Wang, T.; Xu, Z.; Hughes, E.; Qian, F.; Lee, M.; Fan, Y.; Lei, Y.; Brückner, C.; Li, B. Real-time in situ monitoring of nitrogen dynamics in wastewater treatment processes using wireless, solid-state, and ion-selective membrane sensors. *Environ. Sci. Technol.* 2019, 53, 3140–3148.
17. Gemene Kebede L. Bakker E. Measurement of total calcium by flash chronopotentiometry at polymer membrane ion-selective electrodes. *Analytica Chimica Acta*. 2009. Vol. 648, 240–245.
18. Roy, S.; David-Pur, M.; Hanein, Y. Carbon nanotube-based ion selective sensors for wearable applications. *ACS Appl. Mater. Interfaces* 2017, 9, 35169–35177.
19. Umezawa, Y.; Bühlmann, P.; Umezawa, K.; Tohda, K.; Amemiya, S. Potentiometric selectivity coefficients of ion-selective electrodes. Part I. Inorganic cations (technical report). *Pure Appl. Chem.* 2000, 72, 1851–2082.
20. Guidance on harmonised methodologies for human health, animal health and ecological risk assessment of combined exposure to multiple chemicals // *EFSA Journal* 2019;17(3):5634. doi: 10.2903/j.efsa.2019.5634
21. Baas J, Augustine S, Marques GM and Dorne JL, 2018. Dynamic energy budget models in ecological risk assessment: from principles to applications. *Science of the Total Environment*, 628–629, 249–260
22. Bopp S, Berggren E, Kienzler A, van der Linden S and Worth A, 2015. Scientific methodologies for the assessment of combined effects of chemicals — a survey and literature review. *JRC Technical Reports*, 64.
23. ECETOC (European Centre for Ecotoxicology and Toxicology of Chemicals), 2012. *The European Centre for Ecotoxicology and Toxicology of Chemicals (ECETOC) 2012 Annual Report*. Available online: http://www.ecetoc.org/wp-content/uploads/2013/06/ECETOC_2012_Annual_Report.pdf
24. EFSA PPR Panel (EFSA Panel on Plant Protection Products and their Residues), 2014. Scientific Opinion on good modelling practice in the context of mechanistic effect models for risk assessment of Plant Protection Products. *EFSA Journal* 2014;12(3):3589, 92 pp. <https://doi.org/10.2903/j.efsa.2014.3589>
25. Meek ME, Boobis AR, Crofton KM, Heinemeyer G, Van Raaij M and Vickers C, 2011. Risk assessment of combined exposure to multiple chemicals: A WHO/IPCS framework. *Regulatory Toxicology and Pharmacology*, 60, S1–S14

26. Solomon KR, Wilks MF, Bachman A, Boobis A, Moretto A, Pastoor TP, Phillips R and Embry MR, 2016. Problem formulation for risk assessment of combined exposures to chemicals and other stressors in humans. *Critical Reviews in Toxicology*, 46, 835–844
27. US EPA (Environmental Protection Agency), 2011. *Vocabulary Catalog List Detail-Integrated Risk Information System (IRIS) Glossary*
28. Van Gestel CAM, Jonker MJ, Kammenga JE, Laskowski R and Svendsen C, 2011. Mixture Toxicity. Linking Approaches from Ecological and Human Toxicology. *SETAC Press, Pensacola, USA*, 320 pp. ISBN 9781439830086

Received 26.09.2021

*Surovtsev I.V.*¹, DSc (Engineering), Senior Researcher,

Head of the Ecological Digital Systems Department

ORCID: 0000-0003-1133-6207,

e-mail: dep115@irtc.org.ua

*Velykyi P.Y.*¹, PhD Student,

the Ecological Digital Systems Department

ORCID: 0000-0002-8118-9348,

e-mail: velykyi305@gmail.com

*Hrytsaienko M.O.*², PhD Student,

Joint Research Unit 7504,

ORCID: 0000-0002-5979-0663,

e-mail: maryna.hrytsaienko@ipcms.unistra.fr, gmari@ukr.net

*Galimova V.M.*³, PhD (Chemistry),

Associate Professor of the Department of Analytical

and Inorganic Chemistry and Water Quality

ORCID: 0000-0001-9602-1006,

e-mail: galimova2201@gmail.com

¹ International Research and Training Center

for Information Technologies and Systems

of the National Academy of Sciences of Ukraine

and Ministry of Education and Science of Ukraine,

40, Acad. Glushkov av., Kyiv, 03187, Ukraine

² Strasbourg Institute of Material Physics and Chemistry,

National Center for Scientific Research – University of Strasbourg,

4 Rue Blaise Pascal, 67081 Strasbourg, France

³ National University of Life and Environmental Sciences of Ukraine,

17, bldg. № 2, Heroes of Defense str., Kyiv, 03041, Ukraine

ANALYTICAL SYSTEM FOR MONITORING AND ASSESSING OF RISKS OF DRINKING WATER CONSUMPTION

Introduction. The use of the electrochemical analytical system "Analyzer SCP" allows the environmental monitoring the conditions of drinking water and water objects, assessing and predicting the risks of toxicants on human health and the environment.

The purpose of the paper is to improve information technology for determining the concentrations of chemical elements for rapid assessment of drinking water quality and methods for assessing the risk of their impact on the biosphere.

Methods. Pulse methods of chronopotentiometry, chronoionometric method of direct potentiometry and methods of assessment of ecological risk of influence of chemicals on environment are used for measurement of concentrations.

Results. Developed information technology with machine learning, cloud technologies and the use of intelligent models of the mass of chemical element additives, that allows the results of one measurement to quickly determine the elements concentrations in the water objects by comparing signals and assess the impact risks of chemicals to human health when consuming contaminated drinking water.

Conclusions. Advanced analytical system "Analyzer SCP" allows you to quickly measure the concentration of 12 chemicals (Pb, Cd, Cu, Zn, Se, I, K, Na, Ca, F, NO₃, NH₄) in water bodies on site and eight more toxic elements (Hg, As, Sn, Ni, Co, Mn, Cr, Fe) in the laboratory, which allowed to quickly and fully determine the environmental quality of drinking water and the environment. The use of ion-selective and measuring electrodes based on precious metals increases the environmental friendliness and speed of research. The application of risk assessment methodology for the chemical elements impact on humans and the environment allows to predict the consequences and occurrence of diseases with long-term consumption of contaminated drinking water or the possibility of using water bodies for irrigation and fish farming.

Keywords: *concentration, ecological risk, ion-selective electrode, inversion chronopotentiometry, drinking water.*

Intelligent Control and Systems

DOI: <https://doi.org/10.15407/kvt206.04.039>

UDC 681.883

VOLKOV O.Ye., PhD, (Engineering),
Head of Intellectual Control Department
ORCID: 0000-0002-5418-6723,
e-mail: alexvolk@ukr.net

TARANUKHA V.Yu., PhD, (Phys.-Math.),
Senior Researcher of Intellectual Control Department
ORCID: 0000-0002-9888-4144,
e-mail: taranukha@ukr.net

LINDER Ya.M., PhD, (Phys.-Math.),
Senior Researcher of Intellectual Control Department
ORCID: 0000-0003-1076-9211,
e-mail: dep185@irtc.org.ua

KOMAR M.M., PhD (Engineering),
Senior Researcher of Intellectual Control Department
ORCID: 0000-0001-9194-2850,
e-mail: nickkomar08@gmail.com

VOLOSHENIUK D.O.,
Researcher of Intellectual Control Department
ORCID: 0000-0003-3793-7801,
E-mail: p-h-o-e-n-i-x@ukr.net
International Research and Training Center
for Information Technologies and Systems
of the National Academy of Sciences of Ukraine
and Ministry of Education and Science of Ukraine,
40, Acad. Glushkova av., Kyiv, 03187, Ukraine

DEVISING AN ACOUSTIC METHOD FOR INVESTIGATION OF A COMPLEX FORM OBJECT PARAMETERS

***Introduction.** The general principles of the technique of synthesis of reflective characteristics of complex surfaces for small wavelengths are considered in the article. The problem is set in the conditions of using sound waves and sonar. The calculated scattering characteristics are obtained using a facet model.*

© VOLKOV O.Ye., TARANUKHA V.Yu., LINDER Ya.M., KOMAR M.M., VOLOSHENIUK D.O., 2021

ISSN 2663-2586 (Online), ISSN 2663-2578 (Print). Cyb. and Comp. Eng. 2021. № 4 (206)

Purpose. The purpose of the paper is to create a method of acoustic research and determination of spatial characteristics of objects of complex shape, which contains the developed facet model of the object and the model of the reflected signal. This method consists artificial models of objects and models of the reflected signal, with the further purpose of research and determination of spatial characteristics of objects, recognition of objects, etc. It is expected that based on the simulation of signals reflected from these models, it will be possible to classify objects. An important difference from most studies is a number of assumptions about what to do with the model and how to calculate the result, because, as a rule, the main element of such studies is the reflection surface only.

Results. For the purpose of this research simplified model of signal reflection from a surface area in space is considered. We established a correspondence between wave propagation in the space and change of the value of the function representing reflecting wave. At any given moment of time the total reflected signal is the sum of all reflected signals from all surfaces. The integral form was proposed for this purpose. The analytical formula intended for the integral was designed for one of the specific cases of reflection. There were numerical experiments performed to test such formula with regard of facet model of the ship. Resulting waveform looks in accordance to expectations.

Conclusion. In accordance with the task the paper demonstrates the method of constructing a model of objects and sound signals reflected from them, paper also considers the general principles of the method of synthesis of reflective characteristics of complex surfaces for small wavelengths. It is shown why and how exactly such a model is built and the presence of a significant difference in the signal characteristics for different angles is clearly demonstrated. The main advantage of this model is the ability to conduct experiments exclusively in digital form, without the need for expensive field experiments. Further research should continue in the direction of selecting or creating an optimal recognition system based on neural networks.

Keywords: facet model, remote sensing, underlying surface, sonar image.

INTRODUCTION

Nowadays, researches in the acoustic field and solving the task of determining the direction and distance to the sound source bear high relevance, especially in the context of developing information technology to improve the defense and security of the state [1, 2]. The transition from the development of methods and means of passive location of sound sources to active location is actively performed, which particularly affects hydroacoustics field. First of all, it has been widely adopted for practical marine problems solving, because no types of electromagnetic waves propagate in water over any significant distances due to its electrical conductivity. Therefore, the only effective type of waves to be created and propagated underwater is the acoustic wave.

Compared to the similar task of active location with the help of radio waves, ultrasonic location has a number of features that complicate the development and possible use of such tools. This is most pronounced in the problem of determining the parameters of the mobile maneuvering objects, foremost their shape. In the case of radiodetection, a high-speed maneuvering object is an aircraft, observation of which for a certain period of time, e.g., for half a minute, gives in addition to distance, speed, maneuverability such parameter values as radar cross-section (RCS) and its variance [3]. The value of the variance is an important parameter for identification. At the same time, for sound waves and marine transport due to much lower speeds and much less maneuverability of objects, the power of the reflected signal, which is a function of the radar cross-section, has much less informative variance because objects are irradiated by waves mainly from the singular direction. In addition, there are other features that require that the task of studying the sonar reflected signal is set and solved independently.

PROBLEM STATEMENT

Currently, the most interesting and promising tasks relate to the problem of probing objects with short wavelength sound, which potentially allows to obtain maximum information about the relief of the underlying surface or the shape of the object under study.

Audio frequencies from 300 to 20 kHz and ultrasounds from 20 kHz and above are used for communication and probing. In addition to communication and probing in hydroacoustics, the following tasks are set:

- detection of noise signals and determination of the direction unto them;
- classification of the received signals.

Today, a significant amount of research is focused on the collection and processing of natural data and the design of models for natural objects, as proposed in [4]. Also, the task of building object models uses additional sources of information. An example of developing a technology for the study of cultural heritage objects, which sunk underwater, is given in the source [5]. For moving objects (ships) the main source of information is the acoustic signature [6, 7].

Thus, for artificial but stationary objects or for objects that do not emit sound waves for one reason or another (including sunken ships) there are no reliable methods to determine the parameters and the fact of their artificial origin.

However, under visual inspection of the underwater part of an object, very often it is possible to make the conclusion about its artificial origin similarly to the definition of its parameters (size, shape, type).

The approach to the study is based on the construction of facet models similar to how it is done for radiodetection [8]. Based on the simulation of signals reflected from these models, it is possible to classify objects.

Thus, usually, the main element of such studies is the RCS [8-11]. However, as noted above, RCS and its variance are not always good sources of information. The study suggests that the reflection calculated from the facet model may provide enough information to identify both certain characteristics of the object and the complete identification of the object. For this purpose, a facet model of the object and a method of synthesis of the reflected signal were developed.

Accurate analysis of how the value of the amplitude of the reflected signal from the facet model is constructed was performed. For convenience, the system of the emitter and sensor is considered to be monostatic, i.e. the source of sound radiation and the receiver (microphone) are so close that the distance between them can be neglected.

The purpose of the paper is to create a method of acoustic research and determination of spatial characteristics of objects of complex shape, which contains the developed facet model of the object and the model of the reflected signal.

GEOMETRIC CHARACTERISTICS OF THE FACET MODEL SECTION

A simplified model of signal reflection from a surface section in space is considered. The section is represented by a triangle with a certain order of vertices $\{A, B, C\}$. The signal is represented by an arbitrary function $f(t)$. The spherical wave is most often considered. For sufficiently small areas, it is possible to consider a locally flat wave. Since the dimensions of the triangle are determined only by the choice of the

surface partition, a wave with a flat front will be considered. Due to this interpretation a rectangular coordinate system is used. Let's carry out the translation of the coordinate system so that the observation point (source and receiver) is at the origin. Let the vertices of a triangle have the following coordinates: $A = (A_x, A_y, A_z)$, $B = (B_x, B_y, B_z)$, $C = (C_x, C_y, C_z)$. According to the condition it is known that the wave front moves in the direction of the vector directed to the center of the triangle $I = (I_x, I_y, I_z)$, the coordinates of which are determined as follows:

$$a = \|B - C\|, b = \|A - C\|, c = \|A - B\| \quad (1)$$

$$I_x = \frac{(aA_x + bB_x + cC_x)}{a + b + c}, \quad (2)$$

$$I_y = \frac{(aA_y + bB_y + cC_y)}{a + b + c}, \quad (3)$$

$$I_z = \frac{(aA_z + bB_z + cC_z)}{a + b + c}, \quad (4)$$

The next step is to choose a convenient basis. In order to obtain the first vector of the new basis, the vector of the direction of motion of the wave front \bar{w} is fixed and normalized:

$$\bar{w}_{new} = \frac{\bar{w}}{\|\bar{w}\|}. \quad (5)$$

When passing the front of the wave cuts off the strips of the triangle in parallel lines. It is expedient to choose the second base vector as the directional for all such lines. Therefore, it must belong to the plane of the triangle and the front of the wave at the same time. Let \bar{n} be the vector normal to the surface of the triangle, the orientation of which depends on the order of the vertices:

$$\bar{n}_1 = \begin{bmatrix} B_x - A_x \\ B_y - A_y \\ B_z - A_z \end{bmatrix}, \quad \bar{n}_2 = \begin{bmatrix} C_x - A_x \\ C_y - A_y \\ C_z - A_z \end{bmatrix}, \quad (6)$$

$$\bar{n} = \bar{n}_1 \times \bar{n}_2. \quad (7)$$

Then the second basis vector:

$$\bar{y}_{new} = \frac{\bar{x}_{new} \times \bar{n}}{\|\bar{x}_{new} \times \bar{n}\|}. \quad (8)$$

The vector constructed in this way is orthogonal to the vectors of the wave front's normal and the plane of the triangle at the same time.

The new basis is expanded as follows:

$$\bar{z}_{new} = \frac{\bar{x}_{new} \times \bar{y}_{new}}{\|\bar{x}_{new} \times \bar{y}_{new}\|}. \quad (9)$$

Then the coordinates of the vertices of the triangle can be obtained from the following equations:

$$[\bar{x}_{new} | \bar{y}_{new} | \bar{z}_{new}] \cdot \begin{bmatrix} A_{x_{new}} \\ A_{y_{new}} \\ A_{z_{new}} \end{bmatrix} = \begin{bmatrix} A_x \\ A_y \\ A_z \end{bmatrix} \quad (10)$$

$$[\bar{x}_{new} | \bar{y}_{new} | \bar{z}_{new}] \cdot \begin{bmatrix} B_{x_{new}} \\ B_{y_{new}} \\ B_{z_{new}} \end{bmatrix} = \begin{bmatrix} B_x \\ B_y \\ B_z \end{bmatrix} \quad (11)$$

$$[\bar{x}_{new} | \bar{y}_{new} | \bar{z}_{new}] \cdot \begin{bmatrix} C_{x_{new}} \\ C_{y_{new}} \\ C_{z_{new}} \end{bmatrix} = \begin{bmatrix} C_x \\ C_y \\ C_z \end{bmatrix} \quad (12)$$

DESIGN OF THE REFLECTION MODEL

The projections will be considered in the next steps.

Let's project a triangle on a plane (fig. 1) $x_{new}Oy_{new}$:

Red lines represent the straight intersection of the wave front with the plane of the triangle at different points in time. We introduce the spatial step h and the moment in time t_0 at which the wave front first touches the triangle. Let the t_0 wave step pass for some time $t(h)$.

The purpose of the upcoming steps is to calculate the signal obtained by the receiver (microphone) at the time moments $2t_0$, $2t_0 + t(h)$, $2t_0 + 2t(h)$, $2t_0 + 3t(h)$, ... (starting from the moment of return of the first part of the reflected wave).

Given the flat front of the wave, let's assume that from the point of view of the source the triangle is visible in the projection on the front's plane. By definition, the new basis vectors are equivalent to the plane projection $z_{new}Oy_{new}$.

Where $z(t_0)$ is the coordinate of the peak closest to the wave's front. Note that the projection can always be oriented so that this vertex is on the left, without changing the area.

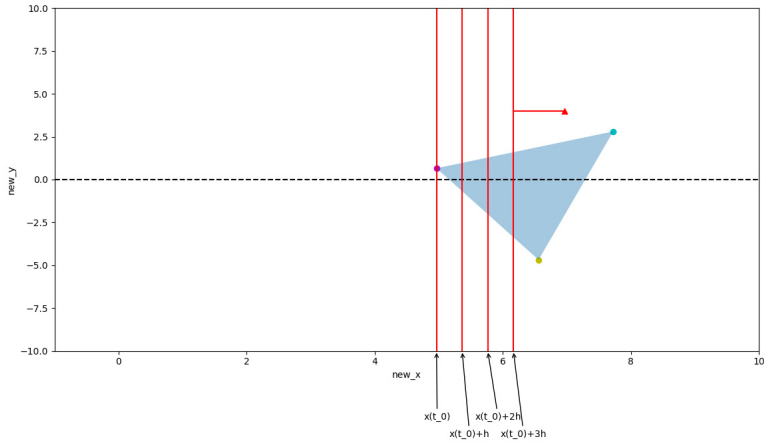


Fig. 1. Steps of wave propagation by projections

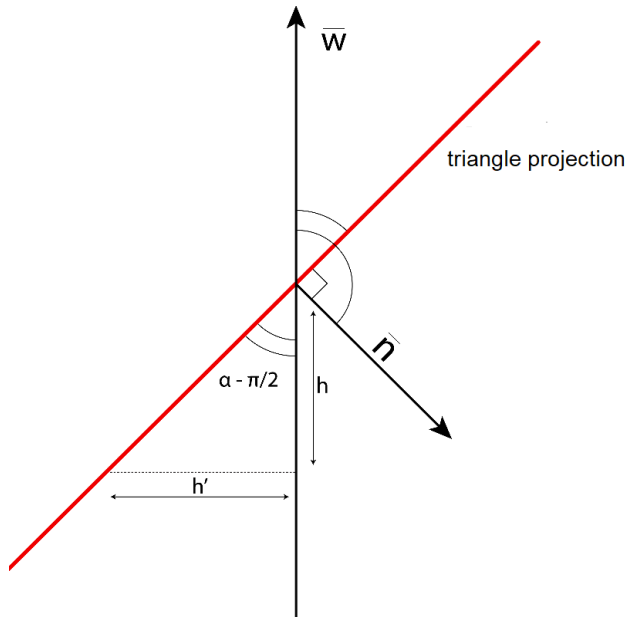


Fig. 2. The wave propagation step and its angles

Thus, during the elementary steps of time $t(h)$ in the plane $y_{new}Oz_{new}$ the wave will be reflected from the bands of the width triangle h' . Therefore, it is necessary to establish a correspondence between h and h' . To do this, first enter the angle between the normal vector to the plane of the triangle and the wave propagation vector α . Given the condition of visibility of the triangle, only the case $\frac{\pi}{2} < \alpha < \pi$ is considered. By construction, the vector of the normal \vec{n} lies in the plane $x_{new}Oz_{new}$. Therefore, the projection of the triangle on this plane will be a segment (Fig. 2).

According to fig. 2 we have:

$$h' = h \cdot \tan\left(\alpha - \frac{\pi}{2}\right). \quad (13)$$

Therefore, formula (13) establishes a correspondence between the step of wave propagation in space h , the step of changing the value of the function $h' = h \cdot \tan\left(\alpha - \frac{\pi}{2}\right)$ and the step of calculating the area of the triangle.

CONSTRUCTION OF THE INTEGRAL FORMULA OF THE REFLECTED SIGNAL

At any given time, the total reflected signal is the sum of all reflected signals from all bands. This approach, with explicit construction of the integral, differs significantly from the sum of the shiny dots, as done in [11].

Assume that from each band of a triangle of width h' some part of the signal is returned to the receiver. Denote this part of the reflected signal $g(f(t))$. Let the wave front correspond to the value $f(t_0)$. Thus, the part of the reflected signal that returned first corresponds to the value $g(f(t_0))$. Further, the receiver will record the return $g(f(t_0 - n \cdot h))$, $n \in N$. At each point in time, the superposition of signals reflected from the strips of the triangle with weights corresponding to the area of each section will be processed. Our goal in this step is to obtain a formula for the superposition of the signals received by the receiver at any given time.

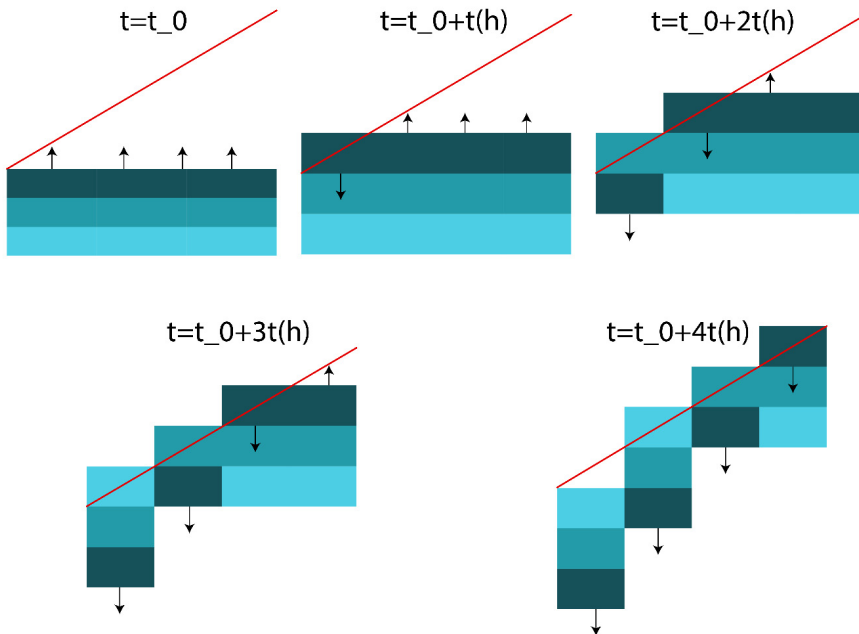


Fig. 3. The process of wave reflection

Again, consider the projection on the plane $x_{new}Oz_{new}$ and depict the stages of reflection of the wave with a time step $t(h)$ (Fig. 3).

In fig. 3 different colors of the oncoming wave correspond to different values $f(t)$. In order to simplify the illustration the condition $g(f) \equiv f$ was assumed.

From fig. 3 it is evident that the parts of the returning wave are shifted by $2t(h)$ (taking into account the full path in both directions). So, we can write the following sequence:

$$\begin{aligned}
 t &= 2t_0 + t(h): \\
 t &= 2t_0 + 2t(h): f(t_0)A(z(t_0) + h) \\
 t &= 2t_0 + 3t(h): f(t_0 - t(h))A(z(t_0) + h') \\
 t &= 2t_0 + 4t(h): f(t_0 - 2t(h))A(z(t_0) + h) + f(t_0)A(z(t_0) + 2h') \\
 t &= 2t_0 + 5t(h): f(t_0 - 3t(h))A(z(t_0) + h) + f(t_0 - t(h))A(z(t_0) + 2h') \\
 t &= 2t_0 + 6t(h): \\
 &f(t_0 - 4t(h))A(z(t_0) + h) + f(t_0 - 2t(h))A(z(t_0) + 2h') + f(t_0)A(z(t_0) + 3h') \\
 &\dots
 \end{aligned}$$

where $A(z(t_0) + it(h))$, $i \in N$ is the area of the corresponding projection band.

If the value of h is small enough it is convenient to replace calculation of the areas of trapezoids with calculation of the areas of rectangles. To do this, first perform a parallel translation of the projection of the triangle on the plane $z_{new}Oy_{new}$ so that the whole figure lay above the axis Oz_{new} . Next, we introduce a piecewise linear function $T(z)$, which is defined as the difference between the functions of the upper and lower sides of the triangle, and is identically equal to zero outside of it. So, the following generic formula is obtained:

$$S(\tau) := \sum_{i=0}^{\frac{t^{-1}(\tau)-h}{2t(h)}-0.1} g(f(t_0 + 2(i+1) \cdot t(h) - \tau)) \cdot h' \cdot T(z(t_0) + (i+1)h'). \quad (14)$$

Or, given the formula (13):

$$S(\tau) := \sum_{i=0}^{\frac{t^{-1}(\tau)-h}{2t(h)}-0.1} g(f(t_0 + 2(i+1) \cdot t(h) - \tau)) \cdot h \cdot \tan\left(\alpha - \frac{\pi}{2}\right) \cdot T\left(z(t_0) + (i+1) \cdot h \cdot \tan\left(\alpha - \frac{\pi}{2}\right)\right) \quad (15)$$

Finally, under $h \rightarrow 0+$ we get:

$$I(\tau) := \int_0^{t^{-1}(\tau)} \frac{1}{2} g(f(t_0 + t(x) - \tau)) \cdot \tan\left(\alpha - \frac{\pi}{2}\right) \cdot T\left(z(t_0) + \frac{x}{2} \tan\left(\alpha - \frac{\pi}{2}\right)\right) dx. \quad (16)$$

The resulting integral takes into account almost all characteristics of the signal.

CONSTRUCTION OF ANALYTICAL FORMULA FOR THE INTEGRAL FOR ONE OF THE CASES

Let's have a piecewise constant function as an input:

$$f(t) := \begin{cases} 0 & , \quad t_0 < t \\ C & , \quad t_0 - \text{length} \leq t \leq t_0 \\ 0 & , \quad t < t_0 - \text{length} \end{cases} \quad (17)$$

The speed of propagation: $v: t(x) = x/v$. The integral takes the form:

$$I(x) := \int_0^t \frac{v \cdot \tan(\beta)}{2} f(t_0 + x - t) T\left(\frac{xv}{2} \tan(\beta) + z(t_0)\right) dx \quad (18)$$

Perform the following transformations by replacing the variable:

$$\begin{aligned} & \int_0^t \frac{v \cdot \tan(\beta)}{2} f(t_0 + x - t) T\left(\frac{xv}{2} \tan(\beta) + z(t_0)\right) dx = \\ & = \frac{C \cdot v \cdot \tan(\beta)}{2} \int_0^t I_{\{t-x \leq \text{length}\}} T\left(\frac{xv}{2} \tan(\beta) + z(t_0)\right) dx = \\ & = \frac{C \cdot v \cdot \tan(\beta)}{2} \int_{t-\text{length}}^t T\left(\frac{xv}{2} \tan(\beta) + z(t_0)\right) dx = C \cdot \int_{z(t-\text{length})}^{z(t)} T(u) du \end{aligned} \quad (19)$$

Replace the variable in the last two lines as follows: $z(t) := \frac{tv}{2} \tan(\beta)$, which in fact it means the transition to the projection plane of the triangle.

From the previous stages we know the structure of the function for calculating the area of a triangle $T(z)$. It is guaranteed to have a bend at the midpoint of the triangle along the axis Oz_{new} . Let's mark this point as z_{mid} . Respectively, the beginning of the integration of the triangle and the end are denoted by $z_{\text{left}} = z(t_0)$ and z_{right} . It is necessary to investigate the location $z(t)$, $z(t - \text{length})$ relative to z_{left} , z_{mid} , z_{right} . Since the integrand is of the form $T(z) = 0$, $z \notin [z_{\text{left}}, z_{\text{right}}]$, simplify limits of integration:

$$\begin{aligned} b &:= \min\{z(t) - z_{\text{right}}\} \\ a &:= \max\{z(t - \text{length}), z_{\text{left}}\} \end{aligned} \quad (20)$$

Therefore, it is necessary to consider only the following cases:

$$\begin{aligned}
 b &< z_{left} \\
 b &< z_{mid} \\
 a &< z_{mid} < b \\
 z_{mid} &< a < b \\
 z_{right} &< a
 \end{aligned}$$

Denote the two nonzero components of the function $T(z)$:

$$f_1(z) = T(z), z \in [z_{left}, z_{mid}] \quad (21)$$

$$f_2(z) = T(z), z \in [z_{mid}, z_{right}] \quad (22)$$

Selecting and fixing two arbitrary corresponding antiderivatives $F_1(z)$ and $F_2(z)$ we get:

$$I(b) = \begin{cases} 0 & , \quad b < z_{left} \\ C \cdot (F_1(b) - F_1(a)) & , \quad b < z_{mid} \\ C \cdot (F_2(b) - F_2(z_{mid}) + F_1(z_{mid}) - F_1(a)) & , \quad a < z_{mid} < b \\ C \cdot (F_2(b) - F_2(a)) & , \quad z_{mid} < a < b \\ 0 & , \quad z_{right} < a \end{cases} \quad (23)$$

The final model is obtained by summarizing over time of all the models of individual sections.

MODEL OF A SUNKEN SHIP AND ITS REFLECTED SIGNAL

In fig. 4. shown a simplified facet model of a sunken ship, and in fig. 5 and fig.6 shown the shape of the reflected signal, for two different angles: on the bow-stern axis and on the starboard side. This model is obtained as the sum of signals from individual sections.

As can be seen from fig. 5 and fig. 6 there is a certain interdependence between the angle of the upcoming scanning wave and the shape of the reflected signal.

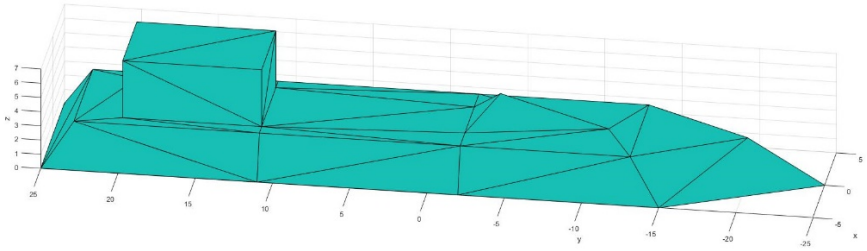


Fig. 4. Model of the ship.

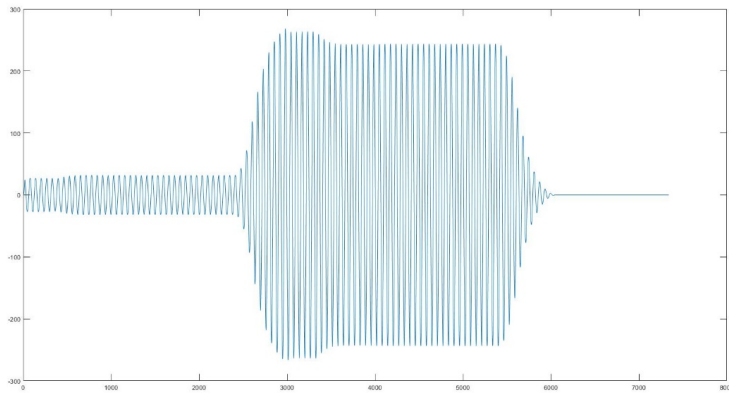


Fig. 5. The structure of the reflected signal when irradiated along the axis on the bow-stern axis

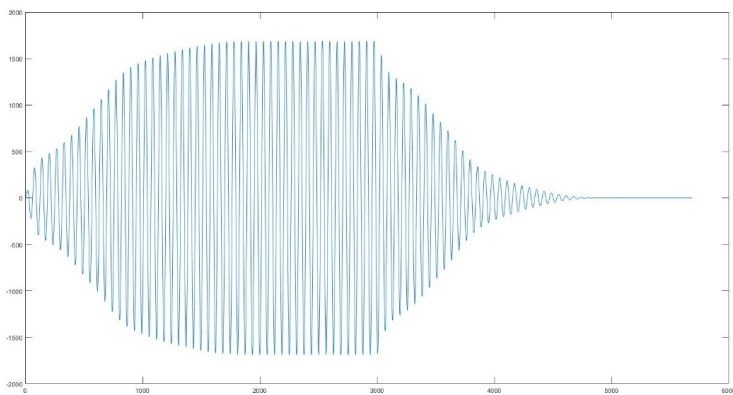


Fig. 6. The structure of the reflected signal when irradiated from the starboard side

Of particular interest are the sections corresponding to the following:

1. for a time interval until the wave has covered the ship completely and,
2. for a time interval when the wave no longer covers the ship completely.

Potentially, these areas contain much more information compared to the criterion proposed in [11] based on the frequency correlation of fluctuations of the effective scattering surface of the target with a discrete adjustment of the emitter frequency. Because both radars and sonars create oscillating processes with the same mathematical description.

Certain inaccuracies that distort the overall model are in fact insignificant as long as the following conditions are met:

1. data of the same nature is used for recognition: either only real data, or only modeling data, if it is necessary to distinguish between natural and artificial objects;
2. to determine the characteristics of a particular type of object a neural network trained on all perspectives of the potential target is used.

CONCLUSIONS

In accordance with the stated task the method of model construction of objects and the sound signals reflected from them is presented, the general principles of a synthesis technique of reflective characteristics of difficult surfaces for small wavelengths were considered. The purpose and the approach of such a model construction are shown, and the presence of a significant difference in the signal characteristics for different angles is clearly demonstrated.

The developed method and models allow conducting experiments exclusively in digital form, without the need for expensive field experiments. The application of the proposed models does not corrupt the effectiveness of the features that will be used in the future for objects recognition.

The proposed method provides more information about the object in comparison with the criterion based on the frequency correlation of fluctuations of the effective scattering surface of the target with a discrete adjustment of the frequency of the emitter. And it is also insensitive to inaccuracies introduced by distortions into the general model.

Further research will continue in the direction of selecting or creating an optimal recognition system based on neural networks.

REFERENCES

1. Anisimov A.V., Volkov O.Ye., Linder Ya.M. et al. Method of acoustic directed finding of mobile objects with unmanned aerial vehicle. *Collection of scientific works of the Military Institute of Kyiv National Taras Shevchenko University* 2019. (64). P. 14–24. (in Ukrainian)
2. Volkov O.Ye., Taranukha V.Yu., Linder Ya.M. et al. Acoustic monitoring technology, detection and localization of objects in a controlled space. *Control Systems and Computers*. 2020. № 4. P. 35–43. (in Ukrainian)
3. Kalinin T.V., Bartsevych A.V., Petrov S.A. et al. Radar recognition system modeling software package *Software products and systems*. 2017. V. 30. № 4. P. 733–738 (in Russian)
4. Scarafoni D. et al. Automatic target recognition and geo-location for side scan sonar imagery. *The Journal of the Acoustical Society of America* 141, no. 5 (2017): 3925–3925.
5. Brekhovskiy O.V., Grinberg Ye.E., Evseenko M.S. et al. Development of basics of technology of research for the objects of cultural heritage buried in uncompacted bottom sediments by a method of the parametric profilography with use of data of satellite navigation. *Oceanological research* 2018. Vol. 46. No 2. P. 5–14 (in Russian)

6. Liu, Yan-sen, Wang Yang, and Xue-Meng Yang. Acoustic spectrum and signature analysis on underwater radiated noise of a passenger ship target based on the measured data. *Eleventh International Conference on Signal Processing Systems*, 2019, Chengdu, China. Access: <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/11384/113840H/Acoustic-spectrum-and-signature-analysis-on-underwater-radiated-noise-of/10.1117/12.2559664.pdf>
7. Zhu C., Seri S.G., Mohebbi-Kalkhoran H. et al. Long-range automatic detection, acoustic signature characterization and bearing-time estimation of multiple ships with coherent hydrophone array. *Remote Sensing*, 2020. 12(22), p. 3731. Access: <https://www.mdpi.com/2072-4292/12/22/3731/pdf>
8. Khrychov V.S., Legenky M.M. Facet model of an object of complex shape for the calculation of electromagnetic scattering. *Bulletin of V.N. Karazin Kharkiv National University. Radiophysics and Electronics Series*, 2019. (28), P. 44–52. (in Ukrainian)
9. Maslovsky A.A., Legenky M.M. On reducing the visibility of radar targets located on the underlying surface. *Bulletin of V.N. Karazin Kharkiv National University. Radiophysics and Electronics Series*. 2014. Iss. 24. № 1115. P.14–22 (in Russian)
10. Youssef N.N. Radar cross section of complex targets *Proceedings of the IEEE*. 1989. Vol. 77, Issue 5. pp. 722–734.
11. Murashkin A.V., Yudin V.A. Experimental studies of the correlation two-frequency method for the recognition of aerodynamic targets. *Achievements of university science*. 2016. (21). C. 136–140. (in Russian).

Received 02.09.2021

ЛІТЕРАТУРА

1. Анісімов А., Волков О., Ліндер Я. та ін. Метод акустичної пеленгації динамічних об'єктів за допомогою безпілотного літального апарату. *Збірник наукових праць Військового інституту Київського національного університету імені Тараса Шевченка*, 2019. (64). С 14–24.
2. Волков О.Є., Тарануха В.Ю., Ліндер Я.М. та ін. Технологія акустичного моніторингу, виявлення та локалізації об'єктів у контрольованому просторі. *Control Systems and Computers*. 2020. № 4. С. 35–43.
3. Калинин Т.В., Барцевич А.В, Петров С.А и др. Программный комплекс моделирования системы радиолокационного распознавания *Программные продукты и системы*. 2017. Т. 30, № 4. С. 733–738
4. Scarafoni Daniel et al. Automatic target recognition and geo-location for side scan sonar imagery." *The Journal of the Acoustical Society of America* 141, no. 5 (2017): 3925–3925.
5. Бреховских О.В., Гринберг Е.И., Евсенок, М.С. и др. Разработка основ технологии исследования объектов культурного наследия, погребенных в донных уплотненных осадках, методом параметрического профилографа с использованием данных спутниковой навигации *Океанологические исследования* 2018. Том 46. No 2. С. 5–14
6. Liu, Yan-sen, Wang Yang, and Xue-Meng Yang. Acoustic spectrum and signature analysis on underwater radiated noise of a passenger ship target based on the measured data. *Eleventh International Conference on Signal Processing Systems*, 2019, Chengdu, China. Режим доступа: <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/11384/113840H/Acoustic-spectrum-and-signature-analysis-on-underwater-radiated-noise-of/10.1117/12.2559664.pdf>
7. Zhu C., Seri S.G., Mohebbi-Kalkhoran H. et al. Long-range automatic detection, acoustic signature characterization and bearing-time estimation of multiple ships with coherent hydrophone array. *Remote Sensing*, 2020. 12(22), p.3731. Режим доступа: <https://www.mdpi.com/2072-4292/12/22/3731/pdf>

8. Хричов В.С., Легенький М.М. Фасетна модель об'єкту складної форми для розрахунку електромагнітного розсіяння. *Вісник Харківського національного університету імені В.Н. Каразіна. Серія «Радіофізика та електроніка»*, 2019. (28), С. 44–52.
9. Масловский А.А. М.Н. Легенький О снижении заметности радиолокационных целей, расположенных на подстилающей поверхности *Вісник Харківського національного університету імені В. Н. Каразіна. Серія «Радіофізика та Електроніка»*. 2014. Вип. 24. № 1115. С. 14–22
10. Youssef N.N. Radar cross section of complex targets *Proceedings of the IEEE*. 1989. Vol. 77, Issue 5. pp. 722–734.
11. Мурашкин А.В., Юдин В.А. Экспериментальные исследования корреляционного двухчастотного способа распознавания аэродинамических целей. *Достижения вузовской науки*. 2016. (21). С. 136–140.

Отримано 02.09.2021

Волков О.Є., канд. техн. наук,
зав. відд. інтелектуального управління
ORCID: 0000-0002-5418-6723,
e-mail: alexvolk@ukr.net

Тарануха В.Ю., канд. фіз.-мат. наук,
старш. наук. співроб. відд. інтелектуального управління
ORCID: 0000-0002-9888-4144,
e-mail: taranukha@ukr.net

Ліндер Я.М., канд. фіз.-мат. наук,
старш. наук. співроб. відд. інтелектуального управління
ORCID: 0000-0003-1076-9211,
e-mail: dep185@irtc.org.ua

Комар М.М., канд. техн. наук,
старш. наук. співроб. відд. інтелектуального управління
ORCID: 0000-0001-9194-2850,
e-mail: nickkomar08@gmail.com

Волошенюк Д.О.,
наук. співроб. відд. інтелектуального управління
ORCID: 0000-0003-3793-7801, e-mail: p-h-o-e-n-i-x@ukr.net
Міжнародний науково-навчальний центр
інформаційних технологій та систем
НАН України та МОН України;
пр. Академіка Глушкова, 40, м. Київ, 03187, Україна

РОЗРОБЛЕННЯ МЕТОДУ АКУСТИЧНОГО ДОСЛІДЖЕННЯ ПАРАМЕТРІВ ОБ'ЄКТА СКЛАДНОЇ ФОРМИ

Вступ. У статті розглянуто загальні принципи методу синтезу відбивних характеристик складних поверхонь для малих довжин хвиль. Проблема визначена для умов використання звукових хвиль та гідролокатора. Розраховані характеристики розсіювання отримані за допомогою фасетної моделі.

Метою роботи є створення методу акустичного дослідження параметрів об'єкта складної форми, який містить моделі об'єктів та моделі відбитого сигналу, з подальшим дослідженням та визначенням просторових характеристик об'єктів, розпізнаванням об'єктів тощо. На основі моделювання відбитих сигналів за цими моделями можна буде класифікувати об'єкти. Важливою відмінністю цієї роботи є низка припущень про те, що робити з моделлю і як обчислити результат, оскільки, як правило, основним елементом таких досліджень є лише поверхня відбиття.

Результати. У дослідженні розглянуто спрощену модель відбиття сигналу від площі поверхні у просторі. Встановлено відповідність між поширенням хвилі у просторі та зміною значення функції, яка подає відбиту хвилю. У будь-який момент часу загальний відбитий сигнал є сумою всіх відбитих сигналів від усіх поверхонь. Для цього запропоновано інтегральну форму запису. Аналітичну формулу, призначену для інтегрування, розроблено для одного конкретного випадку відображення. Щоб перевірити формулу на фасетній моделі корабля, проведено чисельні експерименти. Отримана форма сигналу має очікуваний вигляд.

Висновок. Відповідно до поставленого завдання в роботі демонструється метод побудови моделі об'єктів та відбитих від них звукових сигналів, розглянуто загальні принципи методу синтезу відбивних характеристик складних поверхонь для малих довжин хвиль. Показано, чому і як саме будується така модель і наочно продемонстровано наявність істотної різниці в характеристиках сигналу для різних кутів. Основною перевагою цієї моделі є можливість проведення експериментів виключно в цифровій формі, без необхідності проведення дорогих польових експериментів. Подальші дослідження стосуватимуться напряму вибору чи створення оптимальної системи розпізнавання на основі нейронних мереж.

Ключові слова: *фасетна модель; дистанційне зондування; підстилаюча поверхня; гідролокаторне зображення.*

Medical and Biological Cybernetics

DOI: <https://doi.org/10.15407/kvt206.04.054>

UDC 004.75+004.932.2:616

KRYVOVA O.A.,

Researcher, Medical Information Systems Department

e-mail: ol.kryvova@gmail.com,

ORCID: 0000-0002-4407-5990

KOZAK L.M., DSc (Biology), Senior Researcher,

Leading Researcher, Medical Information Systems Department

e-mail: lmkozak52@gmail.com,

ORCID: 0000-0002-7412-3041

KOVALENKO O.S., DSc (Medicine), Professor,

Head of Medical Information Systems Department

ORCID 0000-0001-6635-0124,

e-mail: askov49@gmail.com

NENASHEVA L.V.

Junior Researcher, Medical Information Systems Department

e-mail: larnen@ukr.net

International Research and Training Center

for Information Technologies and Systems

of the National Academy of Sciences of Ukraine

and Ministry of Education and Science of Ukraine,

40, Acad. Glushkov av., Kyiv, 03187, Ukraine

PREDICTION OF SURGERY CONTROL PARAMETERS IN CARDIOLOGY TO OPTIMIZE THE EMISSION FRACTION VALUES WITH THE HELP OF NEURAL NETWORKS

Introduction. *In the Big Data era, decision tree methods, machine learning, and neural networks, along with other Data Mining methods became an alternative to classical statistical methods as a more useful tool for analyzing large and inhomogeneous data. Neural Networks methods have emerged as a more accurate and effective technology in a wide range of medical problems such as diagnosis, prediction, treatment.*

The purpose of the paper is to indentificate the control parameters of the surgical intervention to optimize the EF ejection fraction after the surgery using a Data Mining method (neural network) models.

Results. *The analysis of changes in hemodynamic parameters of children with severe heart defects due to surgery — implantation of conduit. Changes in these parameters after surgery were analyzed using analysis of variance for repeated measurements (RepANOVA).*

© KRYVOVA O.A., KOZAK L.M., KOVALENKO O.S., NENASHEVA L.V., 2021

It was determined that after the surgery there was a significant, statistically significant decrease in 3 hemodynamic parameters (end diastolic index, aortic pressure gradient, and augmentation index). According to the cluster analysis, three groups of patients were identified, which were differed in all hemodynamic parameters and in the peculiarities of changes in the studied parameters after surgery. A model based on a neural network of the RBF type (with radial-based activation functions) was built using the Data Mining Automated Neural Networks module of the STATISTICA package. According to the developed models, the dependence of the emission fraction after the surgery on the control parameters — dopamine dose and conduit diameter was determined.

Conclusions. *The use of predictive models of neural networks developed by the type of RBF network with radially symmetric functions in single-layer networks, allowed to analyze the effectiveness of surgical interventions in the case of congenital heart disease in infants and children. Taking into account the results of the developed prognostic model of the dependence of the cardiac output fraction on the parameters of surgery (dose, conduit diameter) and factors such as age, weight, hemodynamic status, gives the surgeon essential information to achieve good results of a surgery.*

Keywords: *Data Mining, classification models, predictive models, neural networks, surgical efficiency.*

INTRODUCTION

Severity scoring models that can be used to predict patient deterioration, care outcomes and the likelihood of patient mortality in intensive care units have been developed for more than 30 years. Today it is a recognized classic and available tool for risk assessment and an indicator of the quality of hospital work.

In recent years, intelligent data processing technologies for various fields of medicine have been developed. In the early 2000s [1, 2], a new strategy for developing prognostic models using an ensemble of methods was introduced. By definition, ensemble methods are learning algorithms that build a set of classifiers and then classify a new data by weighted forecast voting. It has been shown that there are no "ideal methods" that work equally well on different databases.

Already, in 2011 researchers began to use a hybrid approach in order to achieve greater efficiency of solutions [3–6]. Such schemes and algorithms use a combination of different types of machine learning methods (classification and clustering) to select informative features and improve model performance. It has been demonstrated in various data that accuracy depends not only on the method but also on the set of classification features.

PROBLEM STATEMENT

In the Big Data era, decision tree methods, machine learning, neural networks, along with other Data Mining methods, became an alternative to classical statistical methods as a more useful tool for analyzing large and inhomogeneous data.

Decision tree methods, which were developed more than 20 years ago, have become widespread in medical research in the last decade. They are easily perceived by professionals in clinical practice, because they are clear and turn into logical conditions (decisive rules, classification rules). Previously, classification trees were used, for example, to calculate the probability of death from coronary pathology [7], intracerebral hemorrhage or traumatic brain injury [8], to predict Parkinson's symptoms [9], to assess the severity of the disease [10–12], to strat-

ify patient groups by probability of mortality among the general population patients in intensive care [13–16].

Trujillano et al. [13] predicted the probability of hospital mortality using three decision tree classification algorithms: CART, CHAID and C4.5. All models are based on assessing the severity of patients during the first 24 hours after admission. The authors point out that the main advantages of decision trees are that the obtained decision-making rules can be easily interpreted, and the composition of the group of patients ("leaf" of the tree) obtained in each end node is relatively homogeneous.

In our previous studies, a method and information technology (IT) for classifying human health using a set of Data Mining methods based on objective and expert characteristics were developed [17, 18]. The use of IT to assess the disease activity of children with dysplasia made it possible to identify diagnostic markers of cardiovascular dysfunction and to develop diagnostic rules for determining the stages of the disease by ECG parameters (symmetry of the T wave, an integral indicator of the shape of the STT segment). The functional status and reliability of operators under conditions of intellectual load were also assessed. That made it possible to identify the most informative indicators of HRV, in which the changes of operators' reliability can be predicted, taking into account the type of autonomic regulation.

Note the intelligent support system for medical decision-making in intensive care units by the ensemble of classification models Data Mining — On-line knowledge discovery in the intensive care unit (INTCare), which is based on collecting data from bedside monitors and updating the model, which reduces the need for human intervention [16]. The system was used to predict organ failure (cardiovascular, coagulation, respiratory systems, liver and kidneys) and the treatment results of 129 patients (living or dead) of the Portuguese intensive care unit, based on the first five days of their stay. The system attributes were: monitor data, results of laboratory tests, systems of drugs and medical records. The predictive accuracy of the classification models ensemble varied from 43 % to 83 % (64 % to predict the outcome of treatment of an individual patient).

INTCare modeling and forecasting targets are survival and length of stay in bed. Note that the prognosis of patient length of stay (LOS) is considered as an indicator that helps to plan resuscitation resources and individualize patient care in the intensive care unit.

Two approaches were used to model and forecast these indicators. The first approach is to use data and physiological variables collected during the first 24 hours of inpatient treatment. The second approach used real-time patient clinical data.

The first approach achieved forecasting results with an accuracy of 73 %. However, when the duration of the stay was predicted using real-time data collected, efficiency increased (model sensitivity — 96.1 %). The following models were used: Support Vector Machine, Decision Trees, Naive Bayes. To predict survival, the Decision Trees method showed the best result (sensitivity — 87.3 %).

The most important feature of the intelligent decision support system INTCare is the ability to work autonomously and in real time. But such models, which are based on several measurements, are not designed to work with streaming data.

In recent years, in addition to decision trees [20], machine learning methods, artificial neural networks (ANN) [21], the method of support vectors machine (SVM) [22] have been increasingly used to verify and model the severity of patients. Intelligent systems for supporting hospital and diagnostic decisions with an accuracy of over 80 %

have been proposed [23–27]. Such systems use Data Mining methods and techniques. Once again, the advantage of decision trees is that they are clear and become logical conditions (classification rules).

Machine learning techniques can provide accurate predictions based on large data sets obtained from electronic medical records databases (EHRs). The most common goals of modern research are: predicting complications, mortality, length of hospital stay, improving health [27]. These authors have analyzed more than 150 articles on this subject and draw attention to the need of applying validation and verification procedures to avoid the risk of systematic modeling errors.

The conclusion concerning the possibility and usefulness of applying artificial intelligence methods for the evidence-based analysis of clinical data sets, the results of which are aimed at improving patient health, was made in 78 studies (2008–2018) in [29]. Such a study of analysis methods of clinical data stored in electronic medical records provide trustworthy evidence to support the decisions of health professionals.

Recently, there have been works that use *Deep Learning methods*, namely: Recurrent Neural Networks, neural networks with LSTM-blocks (Long Short-Term Memory) [30, 31]. It is demonstrated that predicting the patient's vital signs, using them to calculate the Prognostic Index and taking it into account in the treatment tactics development allows to predict future complications with high accuracy ($> 80\%$), which would be impossible using only the analysis of current vital signs patient: in $50\% - 60\%$ of cases, the probable deterioration of the patient's condition would not be detected [31].

Kwon J.M. [31] described a rapid response system for detecting and predicting cardiac death in a hospital. The system was developed as a deep learning-based early warning technology (DEWS). The DEWS system has a high sensitivity with a low error rate in detecting patients with in-hospital cardiac arrest. DEWS is easy to apply in different hospital settings, because it uses as input data time series of four vital signs. The DEWS artificial neural network consists of 3 recurrent layers with a short memory unit. For DEWS, the highest AUC ROC (Area Under the receiver operating Curve) values $> 0,85$ were obtained, which is higher than for the models of Logistic Regression, Random Forest and MEWS (Modified Early Warning Score), which is calculated according to six vital indicators [31].

Over the last fifteen years, another area of Data Mining has emerged — Mining symbolic time-intervals. Such methods use a subset of Allen time relations, KarmaLego algorithms and H-DFS (Hadoop Distributed File System) [33].

An example of such a development is Maitreya framework for the prediction of outcome events that leverages these symbolic time intervals. Symbolic elements based on clinical records are used as attributes: conditions, procedures, influence of hospital drugs. The Maitreya system uses the KarmaLego algorithm to form a complete set of templates named DharmaIndex [33]. It is argued that the use of this approach ("time pattern analysis") is more effective than other timeless methods.

Deep Neural Networks of different types have found application in cardiology for solving problems of diagnostics diseases, prediction cardiovascular events [34, 35].

The most common tools for Data Mining and IT development are software products such as: SAS Data Mining [36], Statistica Data Mining [37], WEKA [38], RapidMiner [39], KNIME [40], Python environment, R programming, among which are available, open source.

An example of such technology is the creation of predictive models of the critical patients' condition (survival) based on the integration of the clinical database MIMIC-II in the environment of Data Mining (RapidMiner) [41]. The RapidMiner platform supports scalable forecasting analytics according to the CRISP-DM standard process (CRoss-Industry Standard Process for Data Mining. RapidMiner) and with the help of visual tools (RapidMiner Radoop extension) allows to automate loading, data conversion, construction and evaluation of forecasting models according to various schemes function selection and parameter optimization. The authors concluded that prognostic analytics based on the accumulation of large amounts of medical data can stimulate the transformation of traditional medicine to prognostic, preventive and personalized medicine, which ultimately has a positive effect on both the cost and quality of care [41].

The Kong study [42] proposed a toolkit based on several machine learning methods (LASSO, RF, GBM, LR, implemented in the R environment) to predict in-hospital mortality in patients with sepsis. The efficiency of the developed models in comparison with the traditional SAPS II scale (Simplified acute physiology score). The MIMIC III clinical base was used for model training and validation. The advantage was shown by the GBM (Gradient Boosting Machine) model, which made it possible to identify a set of clinically significant variables that differ from those commonly used in practice (in the SAPS II scale).

The purpose of the paper is to identify control parameters of the surgical intervention to optimize the EF ejection fraction after the surgery Data Mining method (neural networks).

ANALYSIS OF CHANGES IN PATIENTS' CONDITIONS AS A RESULT OF SURGICAL INTERVENTION

The study was conducted based on the results of surgery - implantation of conduit, in patients with severe heart defects. Conduit implant surgery is performed to treat severe heart defects such as aortic stenosis, aortic valve abnormalities (or left ventricular outflow obstruction). The success of the operation depends on many factors, among which the choice of the conduit parameters and the drug dose are important. We analyzed the database provided by a private clinic in the field of pediatric cardiac surgery (Kyiv). The database contained data of 79 children (aged from birth to 18 years).

Here are the studied indicators for the following blocks.

Anthropometric indicators: age of the patient (X1); weight (X2).

Hemodynamic (cardiac) parameters before surgery:

- end diastolic index (X3 — before surgery, X7 — after it);
- aortic pressure gradient (X4 — before surgery, X8 — after it);
- augmentation index (X5 — before the operation, X9 — after it);
- ejection fraction (X6 — before the operation, X10 — after it).

Characteristics of the studied indicators.

End diastolic index (EDI, ml/m²) — the value of the end diastolic volume (EDV, ml) normalized by body surface area (BSA, m²) :

$$X3 = EDV / BSA.$$

Aortic pressure gradient (ΔP_m), which in a healthy person ranges from 3 to 14 mm Hg, in a person with a mild form of aortic stenosis: 12–53 mm Hg.

Augmentation index (AI), reflects the level of compression of the vessel under the influence of external factors (high blood pressure, etc.). Its value reflects the endothelial dysfunction: a high AI index is a cardiovascular complications predictor, an indicator of subclinical atherosclerosis and the severity of left ventricular hypertrophy. Norm AI is 0,4–1,4.

The ejection fraction (EF) is a percentage of the blood ejected from the heart into the aorta during each contraction. Usually, at rest, a healthy heart throws out 50–70 % of the blood that is in it. In many people with heart failure, the ejection fraction is less than 40 %.

The analysis also includes data that are control parameters.

- Dopamine dose (U1). Dopamine is a cardiotonic agent that increases cardiac output and provides increased oxygen delivery.

- Conduit diameter (U2). Conduit is a widely used in clinical practice — surgical treatment of ascending aortic aneurysms, which is a synthetic corrugated vascular prosthesis of constant cross-section with a mechanical or biological valve.

Descriptive statistics of all indicators are presented in table 1.

Analysis of changes in cardiac parameters. Changes in cardiac parameters after surgery were examined using the analysis of variance for repeated measurements (RepANOVA). It was determined that after the surgery there was a large, statistically significant decrease in 3 hemodynamic parameters — EDI, ΔP_m , AI, as well as some decrease in the average value of EF ($F(1,78) = 3,27, p = 0,07$) (Fig. 1, a-d).

Determination of typological groups according to the dynamics of the studied indicators. For in-depth analysis of the surgery effectiveness, a cluster analysis of data was performed to determine homogeneous groups. The k -means algorithm with 10-cross-validation is used, which allows to determine the optimal number of groups. The analysis was done on the basis of 4 hemodynamic parameters (before surgery). Three clusters are defined; cluster centers profiles are given in Figure 2.

Table 1. Indicators descriptive statistics

Model indicators	Mean	Minimum	Maximum	Std.Dev.
X1	119,10	0,67	216,63	66,67
X2	35,99	3,3	94	21,05
X3	83,62	32	211	36,71
X4	63,97	9	177	34,54
X5	2,10	0	4	1,27
X6	68,34	10	88	12,92
U1	302,68	137,5	488	89,89
U2	23,43	14	32	3,41
X7	59,73	22	133	18,10
X8	7,25	1	17	3,38
X9	0,75	0	5	0,92
X10	65,86	30	78	8,14

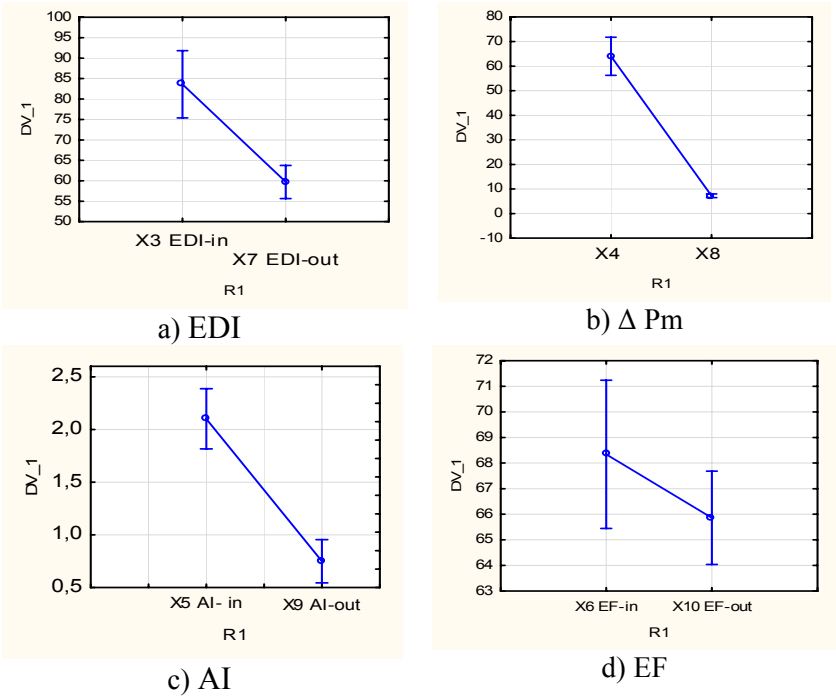


Fig. 1. Average values of cardiac parameters before and after surgery

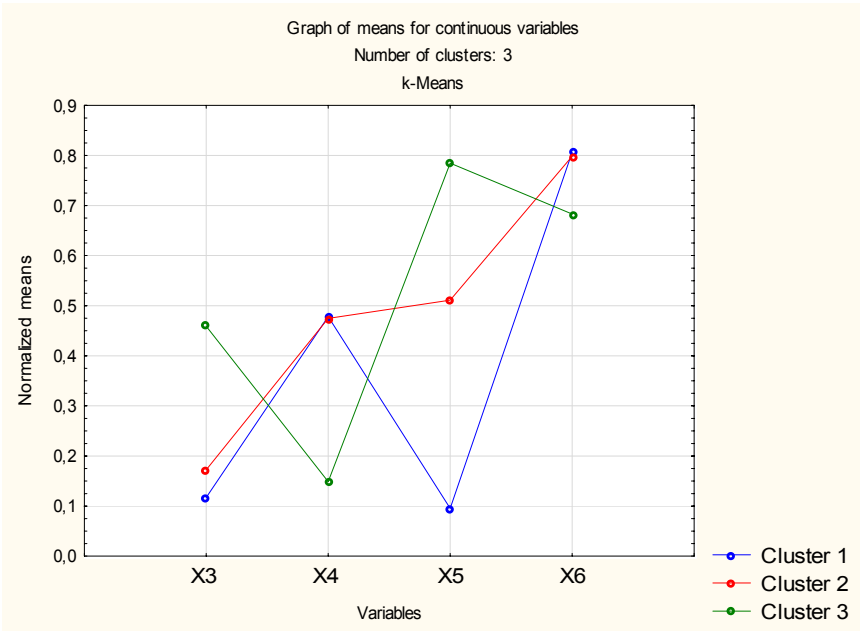


Fig. 2. Profiles of selected three clusters (groups)

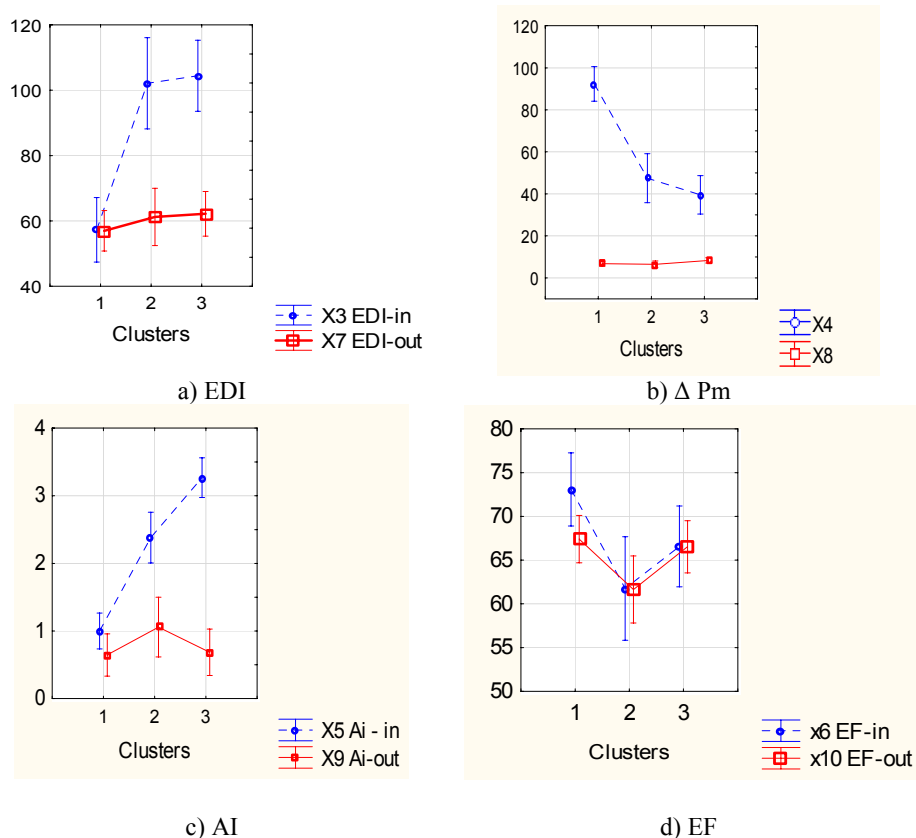


Fig. 3. Comparison of hemodynamic parameters in the three groups before (dashed line) and after (continuous line) surgery

Clusters differ significantly in all studied hemodynamic parameters. The following differences were found between the three identified groups of children.

Group 1 (cluster 1) included 34 children, average age 156 months (senior group). Feature of group 1: in children the lowest values of EDI are accompanied by the highest values of the pressure gradient on the aorta.

Group 2 (cluster 2) consists of 17 babies, the youngest aged — 28.2 months.

Group 3 (cluster 3) included 28 children aged 79 to 204 months, in whom the augmentation index was the highest.

An analysis of hemodynamic parameters changes in certain groups after surgery was performed (Fig. 3, a-d). The results of the analysis (Fig. 3) show that in all groups there is a large, statistically significant decrease in indicators and preservation of the level of PV, which was the purpose of the surgery. Only in the older group of children (cluster 1) with low EDI there is a slight but statistically significant decrease in EF: from 73,0 % to 67,4 %: $F(1, 33) = 10,055$, $p = 0,00327$.

CONSTRUCTION OF MODELS FOR PREDICTING THE PATIENT'S CONDITION AS A RESULT OF SURGERY

It is known that artificial neural networks can be used not only for recognition, classification, but also for predicting functional dependencies. That is, neural networks can reveal hidden dependencies, relationships between the input data and the target variable. And then, based on this predictive function, management decisions can be made.

One of the main problems of such modeling is the choice of the neural network model type. Given the peculiarities of the task — the prediction of the values of the many variables function, we chosen a neural network type RBF (with radial-based activation functions). The mathematical basis for choosing such a model is the statement that arbitrarily accurate approximation of functions is achieved by a combination of radially symmetric functions.

Traditionally, the term RBF network is associated with radially symmetric functions in single-layer networks that have the structure shown in Figure 4.

Define the input data vector as X . Each of the n components of the input vector is fed to the neural network input with consists of m neurons. The output of the RBF network is a linear combination of a basic functionsset

$$f(X) = \sum_{j=1}^m w_j h_j(X),$$

where w_j is weight j -neuron connection, $h_j(X)$ is the neuron activation function is radially symmetric, in our case it is a Gaussian function:

$$h(X) = \exp\left(-\frac{\|X - c\|^2}{r^2}\right),$$

where c is bias coefficient, r is range parameter.

The models were built using the Data Mining Automated Neural Networks module of the STATISTICA package. This module provides the ability to automatically search for the best neural network, allows you to configure the following learning parameters: network type (radial-based functions or multilayer perceptron), activation function, minimum and maximum number of neurons in the hidden layer, error function and others. That is, it is possible to adjust the complexity of the neural network, to control the parameters that affect the quality of the model, as well as the ability to import the resulting neural network in various programming languages such as Java or C +.

In network training, the task is to optimize the system parameters according to the selected criteria. Such a criterion, in particular, may be the criterion of the minimum mean square of the error on the learning set ($E(w)$):

$$E(w) = \frac{1}{p} \sum_{i=1}^p (y_i - d_i)^2,$$

where y_i is the value of the j -th output of the neural network, d_i is the target value of the i -th output, p is the number of neurons in the final layer.

Table 2. Performance indicators of the selected model

Net. name	Training perf.	Test perf.	Validation perf.	Training error	Test error	Validation error	Training algorithm	Error function
RBF 2-7-1	0,42	0,44	0,47	30,3	21,9	15,5	RBFT	SOS

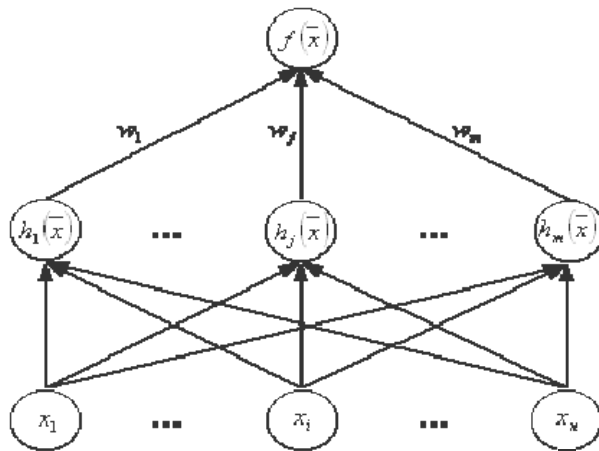


Fig. 4. The structure of the RBF neural network

Neural network learning outcomes. The entire data sample was divided into three parts: training — 75 %, control — 15 %, test (for validation) — 15 %. The criterion for selecting models is the minimization of the error function (SOS — the sum of squares of errors).

Automated search — training of the neural network under the conditions of initial selection (minimum number of neurons in the intermediate layer — 5, maximum — 16), enables to determine model of 7 neurons as the best one (table 2).

The parameters of the neural network model 2- RBF-2-7-1 are shown in the table 3.

Prediction of control parameters in surgical intervention to optimize the ejection fraction values. In the first step, the regression dependence of EF after surgery on the control parameters (model 2- RBF-2-7-1) have been determined, namely: conduit diameter and dopamine dose, the surface of the three-dimensional graph has a maximum (optimal value) EF, which depends on the diameter of the conduit and the dose of dopamine (Fig. 5). Visual analysis shows that the surface of the three-dimensional graph has a maximum of more than 70 % EF, which depends on the dopamine dose and the conduit diameter. The forecast of EF value was calculated for arbitrary values of control parameters that changed in ascending order in the given ranges (Table 4).

According to this model, the optimal value of EF — 70,7 %, can be obtained under the following conditions: dopamine dose — 280 ml and conduit diameter — 22 mm. Note that for this neural network, under the condition of a constant level of the parameter U1 (dopamine) and an increase in U2 (diameter of the conduit), the level of EF increases (see Fig. 5). Therefore, there is no global maxim for all possible values of control parameters in this model.

In order to improve the forecasting results, model studies were done to identify other possible predictors to achieve the maximum level of EFout (target function) and a number of possible predictors were identified (Table 5, the best predictors are sorted by F-criterion value).

Therefore, in addition to the control parameters U1, U2 (dopamine dose, conduit diameter), which were selected by experts and taken into account in the 2- RBF-2-7-1 model, the ejection fraction before surgery (EF-in, X6) can be predictors of EFout, as well as the child's weight -X2.

Table 3. Neural network parameters for 3- RBF-2-7-1. (дати анг назви)

N	Connections	Weight values
1	U1 dopamine dose --> hidden neuron 1	0,001912
2	U2 conduit diam.--> hidden neuron 1	0000
3	U1 dopamine dose --> hidden neuron 2	0,694722
4	U2 conduit diam.--> hidden neuron 2	0,388889
5	U1 dopamine dose --> hidden neuron 3	0,340086
6	U2 conduit diam.--> hidden neuron 3	0,500000
7	U1 dopamine dose --> hidden neuron 4	0,774608
8	U2 conduit diam.--> hidden neuron 4	0,555556
9	U1 dopamine dose --> hidden neuron 5	0,306705
10	U2 conduit diam.--> hidden neuron 5	0,666667
11	U1 dopamine dose --> hidden neuron 6	0,326676
12	U2 conduit diam.--> hidden neuron 6	0,888889
13	U1 dopamine dose --> hidden neuron 7	0,266762
14	U2 conduit diam.--> hidden neuron 7	0,333333
15	radial spread hidden neuron 1	0,425743
16	radial spread hidden neuron 2	0,184823
17	radial spread hidden neuron 3	0,169977
18	radial spread hidden neuron 4	0,184823
19	radial spread hidden neuron 5	0,169977
20	radial spread hidden neuron 6	0,223118
21	radial spread hidden neuron 7	0,182083
22	hidden neuron 1 --> X10 EF-out	0,035833
23	hidden neuron 2 --> X10 EF-out	0,013107
24	hidden neuron 3 --> X10 EF-out	0,069697
25	hidden neuron 4 --> X10 EF-out	0,017845
26	hidden neuron 5 --> X10 EF-out	-0,064549
27	hidden neuron 6 --> X10 EF-out	0,168681
28	hidden neuron 7 --> X10 EF-out	-0,011007
29	hidden bias --> X10 EF-out	0,561705

Modification of the model taking into account additional predictors. After training the model with 4 input variables based on radial functions, a neural network (index 3) with the number of neurons 7 was selected, which is denoted by RBF 4-7-1 (Table 6). Note that the model's performance was better in the training and test samples than in other models with the same number of neurons, and the validation error was smaller than in the previous model with two input variables — RBF 2-7-1.

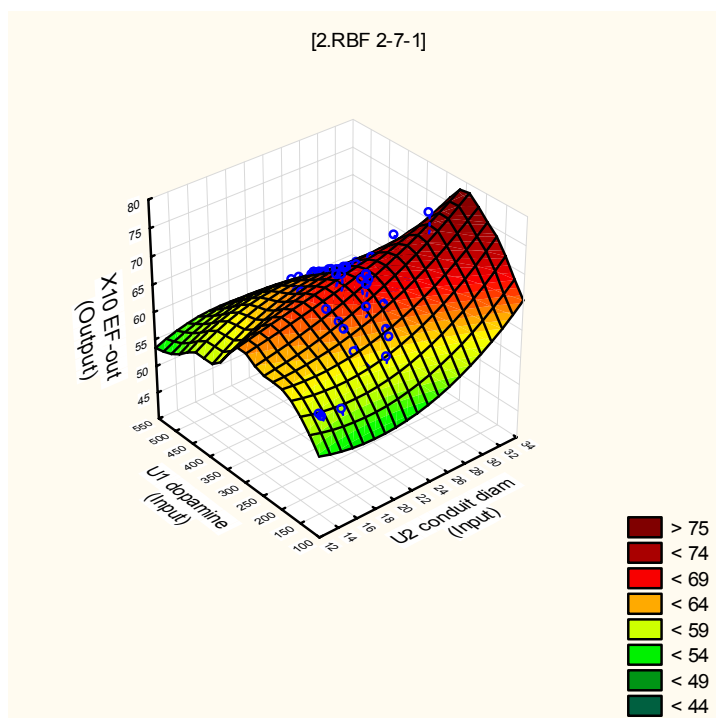


Fig. 5. Three-dimensional graph of the model 2-RBF-2-7-1 for forecasting the fraction of PV emissions after surgery, points on the surface — real data

Table 4. Forecasted values of the emission fraction calculated according to the model in case of control parameters change

№№ forecast option	2.X10 -EF out_(t)	U1 dopamine	U2 conduit diam
1	58,3	140	15
2	59,4	160	20
3	60,6	180	20
4	62,1	200	20
5	66,9	220	22
6	69,0	240	22
7	70,7	280	22
8	69,9	300	24
9	69,1	320	24
10	67,6	340	26
11	66,8	360	30
12	58,0	250	15

Table 5. Indicators — the best predictors of EF after surgery

EFout predictors	F-value	p-value
X7 EDI-out	8,167062	0,00001
X6 EF -in	7,682503	0,0002
X2 weight	3,795432	0,001490
U1 dopamine dose	2,434001	0,022043
U2 conduit diameter	2,190949	0,032986

Table 6. Performance indicators of the RBF 4-7-1 model in neural network training

Index	Net. name	Training perf.	Test perf.	Validation perf.	Training error	Test error	Validation error	Training algorithm	Error function
2	RBF 4-7-1	0,34	0,65	0,68	33,26	14,65	10,62	RBFT	SOS
3	RBF 4-7-1	0,50	0,47	0,59	27,47	25,84	13,02	RBFT	SOS
4	RBF 4-7-1	0,42	0,61	0,61	30,02	16,43	11,99	RBFT	SOS
5	RBF 4-16-1	0,60	0,33	0,61	23,43	27,37	12,79	RBFT	SOS
6	RBF 4-16-1	0,56	0,16	0,60	25,16	29,58	12,86	RBFT	SOS

The model with index 3 RBF 4-7-1 has 4 input variables and consists of seven neurons. Figure 6 shows graphs of the calculated surface of the dependence of EF values after surgery on the diameter of the conduit and dopamine. The marks in Figure 6 are the same as in Figure 5.

As can be seen from Figure 6 three-dimensional surface, calculated on the neural network 3- RBF-4-7-1, has a global maximum at the level of EF > 65 %.

More concrete results can be obtained if we approximate the dependences of EF on control parameters, taking into account their real values and calculated by the neural network. In Figure 7 shows such comparisons of dependences, which are approximated by polynomials (red line — values calculated by the neural network and blue line — real data).

By analyzing the data and calculations of the EFdependence on the conduit diameter (Fig. 7a) and the dopamine dose of (Fig. 7b), we can conclude that to achieve maximum EF (more 65 %) after the surgery there are the following optimal values of control parameters: conduit diameter — 20–26 mm, dopamine dose — 250–350 ml., depending on weight (age) child.

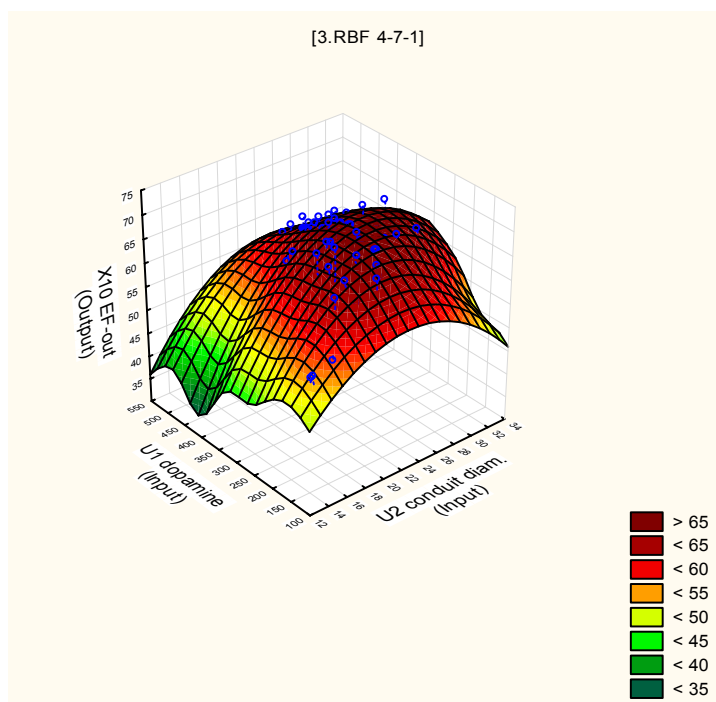


Fig. 6. Three-dimensional graph of EF dependence on 4 input parameters, calculated on the neural network 3- RBF-4-7-1

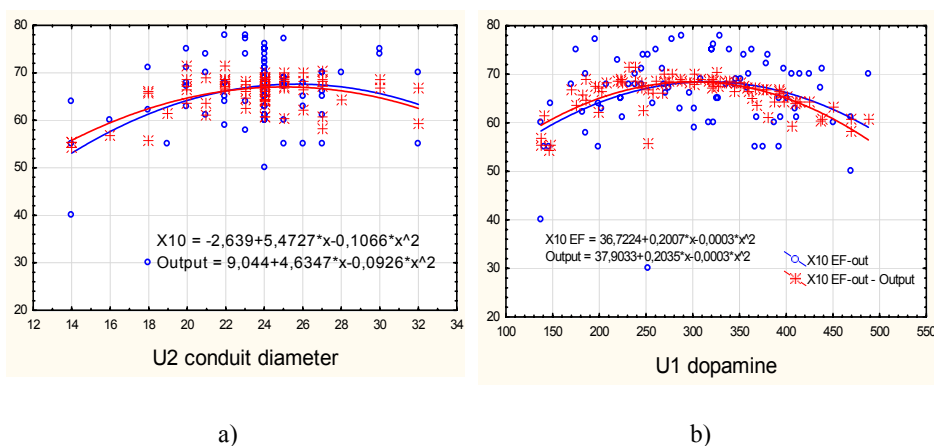


Fig. 7. Graphs of dependence of EF on the conduit diameter (a) and on the dopamine dose (b) (real data — blue and model — red)

Thus, with the help of the developed model it is possible to predict obtaining a satisfactory result according to the target indicator — the value of EF after surgery, using the input data: child's weight, EF before surgery, conduit diameter, dopamine dose.

CONCLUSIONS

A retrospective analysis of changes in the children cardiac parameters after surgery showed the expected changes in clinically significant indicators (decrease in the aortic pressure gradient and augmentation index). But the average value of the emission fraction after cardiac surgery has slightly decreased, although the main goal of the operation is to keep it at a level of at least 65 %.

The cluster analysis revealed three subgroups of children who differed in hemodynamic parameters before the surgery. In addition, these groups were distinct in age and weight. A subgroup of older children was identified in whom the effectiveness of the operation was somewhat unsatisfactory, as after the surgery the emission fraction values decreased statistically significantly.

The use of predictive models developed by the type of RBF neural network with radially symmetric functions in single-layer networks, allowed to analyze the surgical interventions effectiveness in the case of congenital heart disease in infants and children. Taking into account the results of the developed predictive model of the dependence of the cardiac output fraction on the control surgery parameters of dopamine dose, conduit diameter and factors such as age, weight, hemodynamic status, gives the surgeon essential information to make a more effective decision on the choice of control parameters.

REFERENCES

1. Kalantari A. et al. Computational intelligence approaches for classification of medical data: State-of-the-art, future challenges and research directions. *Neurocomputing*. 2018. № 2(7), p. 2–22.
2. Dietterich T. G. Ensemble Methods in Machine Learning. *International Workshop on Multiple Classifier Systems*, 2000, Springer, Berlin, Heidelberg. Vol 18576, pp. 1–15.
3. Acharya A., Hruschka E., Ghosh J., and Acharyya S. C3E: A framework for combining ensembles of classifiers and clusterers. *International Workshop on Multiple Classifier Systems*, 2011, Vol. 6 (15), P.269–278.
4. Rahman A., Verma B. Cluster-based ensemble of classifiers. *Expert Systems*, 2013, Vol. 30, No. 3, P. 270–282.
5. Shouman M, Turner T, Stocker R. Integrating Clustering with Different Data Mining Techniques in the Diagnosis of Heart Disease. *J. Comput. Sci. Eng*, 2013, Vol. 20(1), pp. 1–10.
6. Abawajy JH, Kelarev AV, Chowdhury M Multistage approach for clustering and classification of ECG data. *Computer methods and programs*, 2013, 112(3), pp. 720–730.
7. Mohan S, Thirumalai C, Srivastava G Effective heart disease prediction using hybrid machine learning techniques. *IEEE Access*, 2019, 7, pp.81542–81554.
8. Dolce G, Quinteri M, Serra S, Lagani V, Pignolo L: Clinical signs and early prognosis in vegetative state: a decisional tree, data-minig study. *Brain Inj*, 2008, 22 (7-8), pp. 617–623.
9. Exarchos T.P, Tzallas AT, D Baga, et al Using partial decision trees to predict Parkinson's symptoms: A new approach for diagnosis and therapy in patients suffering from Parkinson's disease. *Computers in biology and medicine*, 2012, 42 (2), 195–204
10. Koval S.N., Pershina E.S., Starchenko T.G., Arseniev A.V. Prediction of the severity of the course of hypertension in patients with type 2 diabetes mellitus by the method of classification trees. *Experimental and clinical medicine*, 2013, No. 3, pp. 41–45.
11. Kochina M.L., Nessonova M.N. Methods for assessing the severity of patients' condition. *Cybernetics and Computer Engineering*, 2014, Vol. 175, pp. 74–87.
12. Omirova N.I., Paley M.N., Evsyukova E.V., Tishkov A.V. Composition of decision trees for recognizing the severity of chronic obstructive pulmonary disease. *Information and control systems*, 2014, No. 5, pp. 115–118.
13. Takahashi O, Cook EF, Nakamura T, Saito J, Ikawa F, Fukui T. Risk stratification for in-hospital mortality in spontaneous intracerebral haemorrhage: a Classification and Regression Tree analysis. *QJM*, 2006, 99:743–50.

14. Gortzis LG, Sakellaropoulos F, Ilias I, Stamoulis K, Dimopoulou I: Predicting ICU survival: a meta-level approach. *BMC Health Serv Res*, 2008, 26:8-157.
15. Xie J., Su B., Li C., Lin K., Li H, Hu Y., Kong G. A review of modeling methods for predicting in-hospital mortality of patients in intensive care unit. *J Emerg Crit Care Med*, 2017, 1(8) pp. 1–10.
16. Trujillano J., Badia M., Serviá L. *et al.* Stratification of the severity of critically ill patients with classification trees. *BMC Med Res Methodol*, 2009, V. 9, no 83, pp. 1–80.
17. Romanyuk O.A., Kozak L.M., Kovalenko A.S., Kryvova O.A. Digital transformation in medicine: from formalized medical documents to information technologies of digital medicine. *Cybernetics and Computer Engineering*. 2018, no. 4(194), pp. 61–78.
18. Kryvova O.A., Kozak L.M. Information Technology for Classification of Donosological and Pathological States Using the Ensemble of Data Mining Methods. *Cybernetics and Computer Engineering*. 2021, no. 1(203), pp. 77–94.
19. Santos M., Portela F. and Vilas-Boas M. INTcare — Multi-agent Approach for Real-time Intelligent Decision Support in Intensive Medicine. In *Proceedings of the 3rd International Conference on Agents and Artificial Intelligence (ICAART-2011)*, SciTePress 2011, pp. 364–369.
20. Kim S, Kim W, Park RW. A Comparison of intensive care unit mortality prediction models through the use of data mining Techniques. *Healthc Inform Res*. 2011; 17:232-243.
21. Amin M. Chiam Y., Varathan K. Identification of significant features and data mining techniques in predicting heart disease. *Telematics and Informatics*, 2019, 36, pp. 82–93.
22. Rubini L. J., Perumal E. Efficient classification of chronic kidney disease by using multikernel support vector machine and fruit fly optimization algorithm. *International Journal of Imaging Systems and Technology*. 2020, 30 (3), pp. 660–673.
23. Volchek, Yu. A., Shishko O.N., Spiridonova O.S. Artificial neural network model position in medical expert systems. *Juvenis Scientia*, 2017 (9), pp. 4–9.
24. Shangareeva Z. A., Urazbakhitina Yu. O. The use of a neural network in the assessment of bronchial asthma data in children. *International research journal*. 2020. No. 7–1 (97), pp. 109–113.
25. Miroshnichenko N.S., Perova I.G. Medical diagnostics based on neural network technologies. *Applied radio electronics*. 2017, V. 16, No. 1–2, pp. 46–50.
26. Kochina M.L., Kaminsky A.A., Malenkin V.A. Information technology for predicting the functional state of the cardiovascular system. *Cybernetics and Computer Engineering*, 2012, Is. 170, pp. 15–27.
27. Gritsenko V.I., Fainzilberg L.S. Intelligent information technologies in digital medicine on the example of phasegraphy. Kiev: Naukova Dumka, 2019. 423 p.
28. Shillan D., Sterne J. A. C., Champneys, A. & Gibbison, G. Use of machine learning to analyze routinely collected intensive care unit data: a systematic review. *Critical Care*. 2019, 23 (1), pp. 284–295.
29. Kaieski N, da Costa CA, da Rosa Righi R, Lora PS. Application of artificial intelligence methods in vital signs analysis of hospitalized patients: *A systematic literature review Applied Soft Computing*, 2020, vol. 96, 106612.
30. da Silva D. B., Schmidt D., da Costa C. A., da Rosa Righi R. & Eskofier, B. DeepSigns: A predictive model based on Deep Learning for the early detection of patient health deterioration. *Expert Systems with Applications*, 2021, 165, 113905.
31. Kwon J.M., Lee Y., Lee Y., Lee S., Park J. An Algorithm Based on Deep Learning for Predicting In-Hospital Cardiac Arrest. *J Am Heart Assoc*, 2018, 7(13), e008678.
32. Papapetrou P., Kollios G., Sclaroff S., Gunopulos D. Mining frequent arrangements of temporal intervals. *Knowledge and Information Systems*. 2009, 21 (2), pp.133–171.
33. Moskovitch R., Choi H., Hripsak G., Tatonetti N. Prognosis of clinical outcomes with temporal patterns and experiences with one class feature selection. *EEE/ACM transactions on computational biology and bioinformatics*, 2016, 14(3), pp. 555–563.
34. Choi E, Schuetz A, Stewart WF, Sun J. Using recurrent neural network models for early detection of heart failure onset. *J Am Med Inform Assoc*, 2017, 24, pp. 361–370.
35. Bizopoulos P., Koutsouris D. *Deep learning in cardiology IEEE reviews in biomedical engineering*, 2018, 12, 168–193.
36. SAS Data Mining https://www.sas.com/ru_ua/industry/health-care.html (Last accessed: 6.08.2021)

37. Data Mining: общий обзор http://statsoft.ru/products/STATISTICA_Data_Miner/ (Last accessed: 6.08.2021)
38. WEKA <https://www.cs.waikato.ac.nz/ml/weka/> (Last accessed: 1.05.2021)
39. RapidMiner <https://rapidminer.com/> (Last accessed: 12.08.2021)
40. KNIME <https://www.knime.com/> (Last accessed: 20.07.2021)
41. Poucke S.V., Zhang Z., Schmitz M., Vukicevic M. Scalable Predictive Analysis in Critically Ill Patients Using a Visual iOpen Data Analysis Platform. *PLoS one*, 2016 V. 11(1), P. 1–21.
42. Kong G., Lin K., Hu Y. Using machine learning methods to predict in-hospital mortality of sepsis patients. *BMC medical informatics and decision making*, 2020, V. 20 (1), pp. 1–10.

Received: 01.09.2021

ЛІТЕРАТУРА

1. Kalantari A. et all. Computational intelligence approaches for classification of medical data: State-of-the-art, future challenges and research directions. *Neurocomputing*. 2018. № 2(7), p. 2–22.
2. Dietterich T. G. Ensemble Methods in Machine Learning. *International Workshop on Multiple Classifier Systems*, 2000, Springer, Berlin, Heidelberg. Vol 18576, pp. 1–15.
3. Acharya A., Hruschka E., Ghosh J., and Acharyya S. C3E: A framework for combining ensembles of classifiers and clusterers. *International Workshop on Multiple Classifier Systems*, 2011, Vol. 6 (15), P.269–278.
4. Rahman A., Verma B. Cluster-based ensemble of classifiers. *Expert Systems*, 2013, Vol. 30, No. 3, P. 270–282.
5. Shouman M, Turner T, Stocker R. Integrating Clustering with Different Data Mining Techniques in the Diagnosis of Heart Disease. *J. Comput. Sci. Eng*, 2013, Vol. 20(1), pp. 1–10.
6. Abawajy JH, Kelarev AV, Chowdhury M Multistage approach for clustering and classification of ECG data. *Computer methods and programs*, 2013, 112(3), pp. 720–730.
7. Mohan S, Thirumalai C, Srivastava G Effective heart disease prediction using hybrid machine learning techniques. *IEEE Access*, 2019, 7, pp.81542–81554.
8. Dolce G, Quinteri M, Serra S, Lagani V, Pignolo L: Clinical signs and early prognosis in vegetative state: a decisional tree, data-minig study. *Brain Inj*, 2008, 22 (7-8), pp. 617–623.
9. Exarchos T.P, Tzallas AT, D Baga, et all Using partial decision trees to predict Parkinson's symptoms: A new approach for diagnosis and therapy in patients suffering from Parkinson's disease. *Computers in biology and medicine*, 2012, 42 (2), 195-204.
10. Коваль С.Н., Першина Е.С., Старченко Т.Г., Арсеньев А.В. Прогнозирование тяжести течения гипертонической болезни у больных сахарным диабетом 2-го типа методом деревьев классификации. *Експериментальна і клінічна медицина*, 2013 № 3, С. 41–45.
11. Кочина М.Л., Нессонова М.Н. Методы оценки степени тяжести состояния пациентов. *Кибернетика и вычислительная техника*, 2014, Вып. 175, С. 74–87.
12. Омирова Н.И., Палей М.Н., Евсюкова Е.В., Тишков А.В. Композиция деревьев решений для распознавания степени тяжести хронической обструктивной болезни легких. *Информационно-управляющие системы*, 2014, №5, С. 115–118.
13. Takahashi O, Cook EF, Nakamura T, Saito J, Ikawa F, Fukui T. Risk stratification for in-hospital mortality in spontaneous intracerebral haemorrhage: a Classification and Regression Tree analysis. *QJM*, 2006, 99:743–50.
14. Gortzis LG, Sakellaropoulos F, Ilias I, Stamoulis K, Dimopoulou I: Predicting ICU survival: a meta-level approach. *BMC Health Serv Res*, 2008, 26:8-157.
15. Xie J., Su B., Li C., Lin K., Li H, Hu Y., Kong G. A review of modeling methods for predicting in-hospital mortality of patients in intensive care unit. *J Emerg Crit Care Med*, 2017, 1(8) pp. 1–10.
16. Trujillano J., Badia M., Serviá L. et al. Stratification of the severity of critically ill patients with classification trees. *BMC Med Res Methodol*, 2009, V. 9, no 83, pp. 1–80.
17. Romanyuk O.A., Kozak L.M., Kovalenko A.S., Kryvova O.A. Digital transformation in medicine: from formalized medical documents to information technologies of digital medicine. *Cybernetics and Computer Engineering*. 2018, no. 4(194), pp. 61–78.
18. Kryvova O.A., Kozak L.M. Information Technology for Classification of Donosological and Pathological States Using the Ensemble of Data Mining Methods. *Cybernetics and Computer Engineering*. 2021, no. 1(203), pp. 77–94.

19. Santos M., Portela F. and Vilas-Boas M. INTcare — Multi-agent Approach for Real-time Intelligent Decision Support in Intensive Medicine. In *Proceedings of the 3rd International Conference on Agents and Artificial Intelligence (ICAART-2011)*, SciTePress 2011, pp. 364–369.
20. Kim S, Kim W, Park RW. A Comparison of intensive care unit mortality prediction models through the use of data mining Techniques. *Healthc Inform Res.* 2011; 17:232–243.
21. Amin M. Chiam Y., Varathan K. Identification of significant features and data mining techniques in predicting heart disease. *Telematics and Informatics*, 2019, 36, pp. 82–93.
22. Rubini L. J., Perumal E. Efficient classification of chronic kidney disease by using multikernel support vector machine and fruit fly optimization algorithm. *International Journal of Imaging Systems and Technology*. 2020, 30 (3), pp. 660–673.
23. Волчек Ю.А., Шишко О.Н, Спиридонова О.С. Положение модели искусственной нейронной сети в медицинских экспертных системах. *Juvenis Scientia*, 2017 (9), с. 4–9.
24. Шангареева З.А., Уразбахтина Ю.О. Применение нейронной сети при оценке данных бронхиальной астмы у детей. *Международный научно-исследовательский журнал*. 2020. № 7–1 (97), С. 109–113.
25. Мирошниченко Н.С, Перова И.Г. Медицинское диагностирование на основе нейросетевых технологий. *Прикладная радиоэлектроника: науч.-техн. журнал*. 2017, Том 16. № 1, 2. С. 46–50.
26. Кочина М.Л., Каминский А.А., Маленкин В.А. Информационная технология прогноза функционального состояния сердечно-сосудистой системы. *Кибернетика и вычисл. техника*, 2012, Вып. 170, С. 15–27.
27. Гриценко В.И., Файнзилберг Л.С. Интеллектуальные информационные технологии в цифровой медицине на примере фазографии. Киев: Наукова Думка, 2019. 423 с.
28. Shillan D., Sterne J. A. C., Champneys, A. & Gibbison, G. Use of machine learning to analyze routinely collected intensive care unit data: a systematic review. *Critical Care*. 2019, 23 (1), pp. 284–295.
29. Kaieski N, da Costa CA, da Rosa Righi R, Lora PS. Application of artificial intelligence methods in vital signs analysis of hospitalized patients: *A systematic literature review Applied Soft Computing*, 2020, vol. 96, 106612.
30. da Silva D. B., Schmidt D., da Costa C. A., da Rosa Righi R. & Eskofier, B. DeepSigns: A predictive model based on Deep Learning for the early detection of patient health deterioration. *Expert Systems with Applications*, 2021, 165, 113905.
31. Kwon J.M., Lee Y., Lee Y., Lee S., Park J. An Algorithm Based on Deep Learning for Predicting In-Hospital Cardiac Arrest. *J Am Heart Assoc*, 2018, 7(13), e008678.
32. Papapetrou P., Kollios G., Sclaroff S., Gunopulos D. Mining frequent arrangements of temporal intervals. *Knowledge and Information Systems*. 2009, 21 (2), pp.133–171.
33. Moskovitch R., Choi H., Hripesak G., Tatonetti N. Prognosis of clinical outcomes with temporal patterns and experiences with one class feature selection. *EEE/ACM transactions on computational biology and bioinformatics*, 2016, 14(3), pp. 555–563.
34. Choi E, Schuetz A, Stewart WF, Sun J. Using recurrent neural network models for early detection of heart failure onset. *J Am Med Inform Assoc*, 2017, 24, pp. 361–370.
35. Bizopoulos P., Koutsouris D. *Deep learning in cardiology IEEE reviews in biomedical engineering*, 2018, 12, 168–193.
36. SAS Data Mining https://www.sas.com/ru_ua/industry/health-care.html (Last accessed: 6.08.2021).
37. Data Mining: общий обзор http://statsoft.ru/products/STATISTICA_Data_Miner/ (Last accessed: 6.08.2021).
38. WEKA <https://www.cs.waikato.ac.nz/ml/weka/> (Last accessed: 1.05.2021).
39. RapidMiner <https://rapidminer.com/> (Last accessed: 12.08.2021).
40. KNIME <https://www.knime.com/> (Last accessed: 20.07.2021).
41. Poucke S.V., Zhang Z., Schmitz M., Vukicevic M. Scalable Predictive Analysis in Critically Ill Patients Using a Visual iOpen Data Analysis Platform. *PLoS one*, 2016, V. 11(1), P. 1–21.
42. Kong G., Lin K., Hu Y. Using machine learning methods to predict in-hospital mortality of sepsis patients. *BMC medical informatics and decision making*, 2020, V. 20 (1), pp. 1–10.

Отримано: 01.09.2021

Кривова О.А.,

наук. співроб., відд. медичних інформаційних систем

ORCID 0000-0002-4407-5990,

e-mail: ol.kryvova@gmail.com

Козак Л.М., д-р біол. наук, старш. наук. співроб.,

провід. наук. співроб., відд. медичних інформаційних систем

ORCID 0000-0002-7412-3041,

e-mail: lmkozak52@gmail.com

Коваленко О.С., д-р мед. наук, проф.,

зав. відд. медичних інформаційних систем

ORCID 0000-0001-6635-0124,

e-mail: askov49@gmail.com

Ненасшева Л.В.,

молод. наук. співроб., відд. медичних інформаційних систем

e-mail: larnen@ukr.net

Міжнародний науково-навчальний центр

Інформаційних технологій та систем

НАН України та МОН України,

пр. Акад. Глушкова, 40, м. Київ, 03187, України

ПРОГНОЗУВАННЯ КЕРУВАЛЬНИХ ПАРАМЕТРІВ ОПЕРАЦІЙНОГО ВТРУЧАННЯ У КАРДІОЛОГІЇ ДЛЯ ОПТИМІЗАЦІЇ ЗНАЧЕНЬ ФРАКЦІЇ ВИКИДУ ЗА ДОПОМОГОЮ НЕЙРОМЕРЕЖІ

Вступ. В епоху Big Data методи дерев рішень, машинного навчання, нейронних мереж разом з іншими методами Data Mining стали альтернативою класичним статистичним методам як корисніший інструмент для аналізу великих та неоднорідних даних. Методи нейронних мереж стали точнішими та ефективнішими технологіями вирішення широкого спектру медичних проблем, таких як діагностика, прогнозування, лікування.

Мета роботи — визначити контрольні параметри хірургічного втручання для оптимізації фракції викиду після операції за допомогою моделей методу Data Mining (нейронної мережі).

Результати. Здійснено аналіз змін гемодинамічних показників стану дітей з тяжкими вадами серця внаслідок хірургічного втручання - вживлення кондуїту. Проаналізовано зміни цих показників після операції за допомогою дисперсійного аналізу для повторних вимірювань (RepANOVA). Визначено, що після операції спостерігалось значне, статистично значиме зменшення 3-х гемодинамічних показників — КДІ, Гр, АІ. За кластерним аналізом визначено три групи пацієнтів, які відрізнялись за всіма гемодинамічними показниками та за особливостями зміни досліджуваних показників після операційного втручання. Побудовано модель на основі нейромережі типу RBF (з радіально-базисними функціями активації) з використанням модулю Data Mining Automated Neural Networks пакету STATISTICA.

За розробленими моделями визначено залежність фракції викиду після операції від параметрів керування — дози допаміну та діаметру кондуїта. Встановлено, що модель нейронної мережі, яка додатково враховує вагу дитини та початковий рівень фракції викиду, має більшу продуктивність.

Висновки. Застосування прогнозних моделей нейромереж, розроблених за типом RBF мережі з радіально-симетричними функціями в одношарових мережах, дало змогу проаналізувати результативність операційних втручань у разі вроджених вад серця у немовлят та дітей. Врахування результатів застосування розробленої моделі залежності фракції серцевого викиду від параметрів операційного втручання (доза препарату, діаметр кондуїту) та таких факторів як вік, вага дитини, стан гемодинаміки, дає хірургу суттєву інформацію для прийняття ефективного рішення про головні керувальні параметри.

Ключові слова: класифікаційні моделі Data Mining, прогнозні моделі, нейромережі, ефективність хірургічного втручання.

DOI: <https://doi.org/10.15407/kvt206.04.073>

УДК: 615.47: 004.9

VOVK M.I., PhD (Biology), Senior Researcher,
Head of the Department of Bioelectrical Control
and Medical Cybernetics
ORCID: 0000-0003-4584-9553,
e-mail: vovk@irtc.org.ua

KUTSIAK O.A., PhD (Engineering),
Senior Researcher of the Department of
Bioelectrical Control and Medical Cybernetics
ORCID: 0000-0003-2277-7411,
e-mail: spirotech85@ukr.net
International Research and Training Center
for Information Technologies and Systems
of the National Academy of Sciences of Ukraine
and Ministry of Education and Science of Ukraine
40, Acad. Glushkov av. Kyiv, 03187, Ukraine

MOBILE AI-TECHNOLOGY FOR FORMING THE PERSONALIZED MOVEMENT REHABILITATION PLAN AFTER A STROKE

Introduction. *The consequences of stroke seriously change the quality of life. Especially suffers motor activity. Speech disorders occupy a significant place. Synthesis of effective technologies for recovery of the movements, fine motor skills of the hand, which plays a significant role in recovering the speech motility, is an the urgent scientific and applied task.*

Recently, the use of artificial intelligence (AI) in medicine has attracted attention. At the same time, mobile technologies are being developed. It is believed that AI in a smartphone will make the medicine of the future accessible to all.

The purpose of the paper is to develop a technology for movement recovery after a stroke which uses the AI tool to increase the effectiveness of rehabilitation process. This AI tool is a specialized software module for mobile platforms, which assists the user (physician) in creating personalized plans at different rehabilitation stages.

Results. *An Altechnology for creating a personalized movement training plan in patient after a stroke has been developed. This technology uses AI tool. The software module for information assistance in creating the plan "MovementRehabStroke 1.0 (MD)" installed on mobile platforms. This module provides the user with recommended movement training plan based on the results of quantitative assessment of movement disorders and the patient's general state. These disorders are determined by the software module "MovementTestStroke 1.1 (MD)". If necessary, this plan may be corrected by the user (physician).*

The structural and functional model of interaction of the user (physician) and software module "MovementRehabStroke 1.0 (MD)" is presented, and the algorithm for creating the personalized movement training plan, recommended and finally corrected by the user, is provided.

Conclusions. *The application of AI tools will help to reduce the physician's error in making diagnostic and treatment decisions, prevent complications, reduce the risk of acquired disability, and will improve the quality and widespread usage of medical and rehabilitation services for patients after a stroke.*

Keywords: *stroke, AI-technology, personalized plan, movement training, rehabilitation, diagnostics, software module, structural and functional model, algorithm.*

INTRODUCTION

Stroke is a common neurological disease and the leading cause of chronic disability worldwide. It is accompanied by various complications, including motor, speech, visual, perception and cognition disorders, and paresthesia. Stroke seriously affects the quality of daily life.

The increase of stroke severity among people of working age is of concern. Motor activity disorders, such as paralysis, paresis, problems with coordination, muscle hypertone, loss of sensitivity in the arms and legs are some of the main consequences of a stroke. According to the World Health Organization, 80 % of stroke survivors have varying degree of extremity dysfunction, and more than 60 % of them still have upper extremity dysfunction after the transition to a chronic phase.

Of high importance are also speech disorders, among which the most frequent is motor aphasia caused by damage to motor speech zone of cerebral cortex, where the motor program of speech is formed [1–8]. The number of people who need the rehabilitation after a stroke is growing rapidly, and the costs and pressure on medical budgets increase too [9, 10]. The quality care for stroke survivors can significantly reduce the risk of acquired disability. The synthesis of effective technologies for personalized restoration of voluntary extremity movements, including fine motor skills of the hand, which plays a significant role in restoring the speech motor skills [11], is the actual scientific and applied task.

Lately, more and more attention is paid to applying an artificial intelligence (AI) in medicine [12]. The Oxford Dictionary defines AI as the theory and development of computer systems that capable to perform the tasks that typically require human intelligence [13]. "AI is poised to play an increasingly prominent role in medicine and healthcare because of advances in computing power, learning algorithms and the availability of large datasets (big data) sourced from medical records and mobile health monitors" [14]. It is believed that AI in a smartphone will make the medicine of future accessible to everyone. Any mobile phone user will have a personal medical assistant, capable of solving problems related to an individual's health in real time. AI is already able to greatly facilitate the work of health professionals, increase the diagnostics accuracy and help patients to cope with everyday tasks [8, 15]. Computers can be programmed to make decisions in real situations. The integration of machines, software and specific information allows the system to transmit thought process, explanation and advice to the end-user [13–15].

Utilisation of AI tools will increase effectiveness and mass usage of rehabilitation services for patients after a stroke, and will improve the quality of these services. In particular, AI tools can be used for personalization and expansion of rehabilitation process functionality aimed at restoring the motor and, indirectly, speech functions, reducing the user's (physician's) error, and for personalization of preventive and rehabilitation measures based on disorders specifics.

The main purpose of the rehabilitation process is the utilization of methods and tools, which mobilize, trigger and strengthen patient's reserves, aimed at recovering the functions damaged by pathology, in accordance with their state at each rehabilitation stage, taking into account the patient's general state, concomitant diseases, etc.

Regarding the movement recovery, the reserves mobilization involves development and realization of the individual complex rehabilitation plans, where, along with medication, the programmed electromyostimulation as a method of training forced muscle contractions by certain programs, as well as by biological feedback (biofeedback) as a training method of voluntary muscle contractions. Innovative TRENAR[®] technology, which is implemented by portable electronic devices TRENAR-01 and TRENAR-02, uses a set of original programs for movement training by methods of programmed electrical stimulation and biofeedback. The general advantage of these programs is a combination of physical and cognitive influences that trigger and stimulate the patient's reserves to recover the movement and involve a patient in the training process, thus increasing the rehabilitation effectiveness.

The purpose of the paper is to create intelligent information technology to design a personalized rehabilitation plan after a stroke that uses AI tool for increasing the effectiveness of rehabilitation process. This AI tool is a specialized software module for Android mobile platforms to assist the user (physician) in designing a personalized plan. This plan consists of the method, program, movements and training duration with using TRENAR[®] devices.

To assist the user (physician) with rehabilitation decision-making, the specialized program module for designing personalized rehabilitation plans "MovementRehab-Stroke 1.0 (MD)" is used. This module provides the user with recommended movement training plan based on the results of the quantitative assessment of movement disorders, determined by the software module "MovementTestStroke 1.1 (MD)", and taking into account patient's neurological status, concomitant diseases, etc.

THE STRUCTURAL AND FUNCTIONAL MODEL OF THE USER AND SOFTWARE MODULE INTERACTION TO CREATE THE PERSONALIZED MOVEMENT TRAINING PLANS FOR MOBILE PLATFORMS

Creation of the personalized training plan using the AI tool, the specialized software module "MovementRehabStroke 1.0 (MD)" for mobile platforms, which provides information and consulting assistance to a physician in creating the personalized training plans for patients after a stroke, is provided and described on structural and functional model (Fig. 1).

This software module consists of the graphical user interface (GUI) and the main information units: I — Database, II — Unit for quantitative assessment of movement disorders "MovementTestStroke 1.1 (MD)" (hereinafter — Unit for movement diagnostics), III — Unit for creating the personalized movement training plans (Fig. 1).

These units are combined with a GUI that provides the user with a dialog mode of interaction with them:

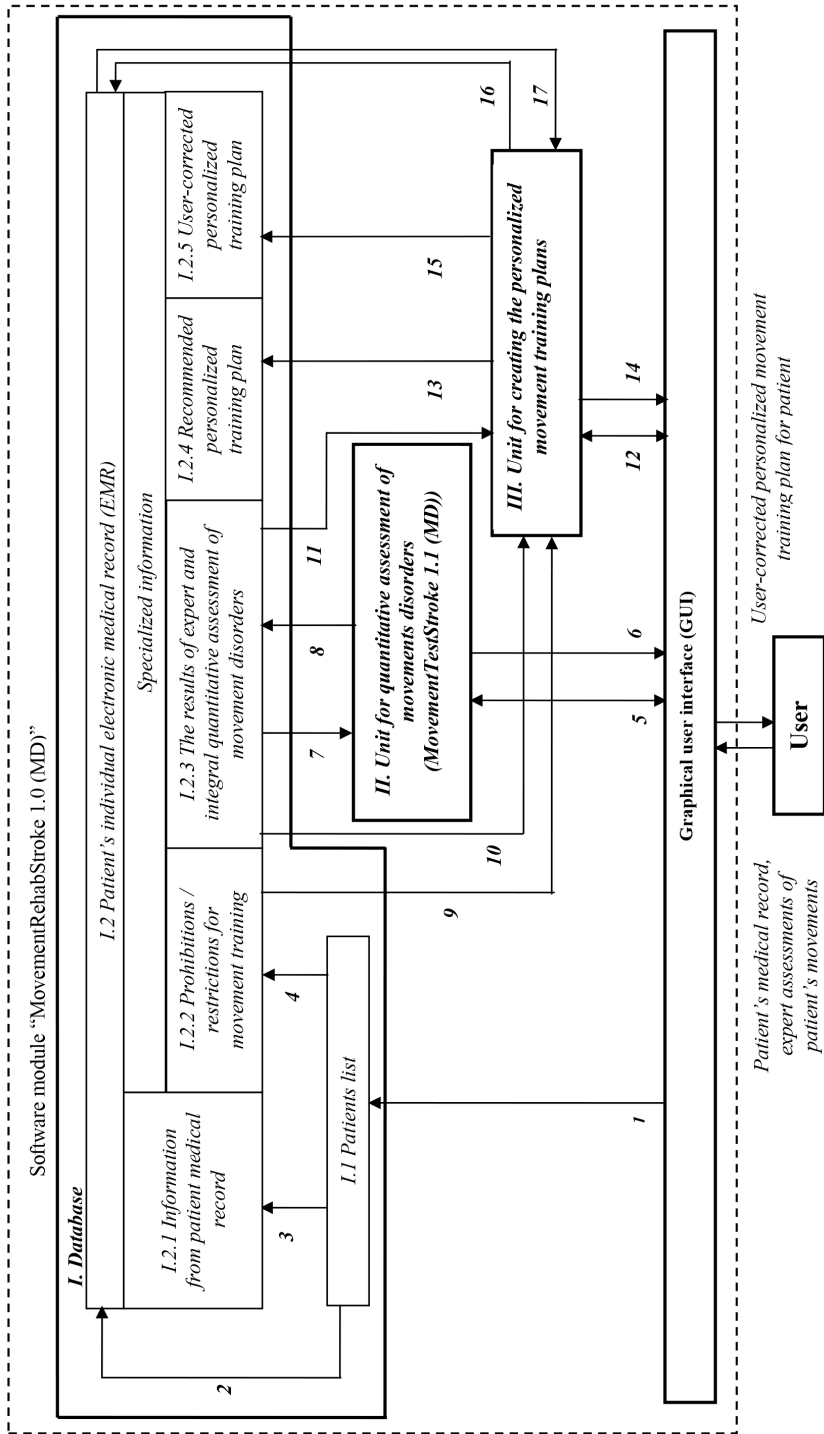


Fig. 1. Structural and functional model of the user and software module "MovementRehabStroke 1.0 (MD)" interaction (markings are in the text)

- inputting the patient's express information and information about a patient's general state in the Database (1);
- providing the access to the patient's individual electronic medical record (EMR) in the Database (2);
- inputting the information from the patient's medical record about the patient's general state, in particular the neurological status and concomitant diseases, in the Database (3);
- marking the concomitant factors of the patient that prohibit or restrict the patient's movement training (4);
- selecting the movement testing object (extremity, hand, gait) and evidence criteria for its assessment, selecting the right verbal characteristic on the assessment scale by selected evidence criterion, outputting the quantitative indicator of motor functions disorders in points by selected evidence criterion (5);
- outputting to the user (physician) the general results of distributed expert and integral quantitative assessment of movement, and movement recovery effectiveness (6);
- loading the data of integral quantitative assessment in points from the first test to assess the movement recovery effectiveness (7);
- storing the current results of distributed expert and integral quantitative assessment of movement in points in the Database (8);
- loading the information from the patient's medical record (9), information on prohibition / restriction for patient's movement training (10), the results of distributed expert assessment of movement disorders for current test from the Database (11) to create the recommended movement training plan for the patient;
- notifying on inability of the patient's movement training; outputting the recommended personalized movement training plan to the user; user's correction of the personalized training plan by selecting the specific movements, methods, programs in the recommended plan (12);
- storing the recommended personalized movement training plan in the Database (13);
- outputting the created recommended personalized movement training plan and the patient's information to the user (14);
- storing the user-corrected personalized movement training plan in the Database (15);
- sending the request to Database to display patient's information (16);
- loading the patient's information from Database (17).

Information unit I, "Database", is designed for storing the information about each patient who has already passed or is passing the rehabilitation for the first time. It contains two main components: I.1 "Patients list" and I.2 "Patient's individual electronic medical record".

Component I.1 is formed in the tabular list view. Each patient on the list is represented by the express information record (hospitalization date, patient's surname-initials-sex, medical record number, physician's surname) according to the standard (form 003/o "Medical record of the in-patient"). The user checks (1) the presence of the right patient. If the patient is absent, the user adds (1) to the Database this patient's express information from the medical record. The presence of a patient on the list makes it possible to provide (2) the access to his individual EMR in the *Database*.

From the medical record the user inputs (3) information about the patient's general state (indicators of neurological status, concomitant diseases, etc.) in the cluster *I.2.1 "Information from patient's medical record"* of the *Database*.

Component *I.2* of the *Database* receives the specialized information:

- the user-marked (4) prohibition / restriction factors of movement training (e.g., acute period of illness, diabetes mellitus on decompensation, the artificial cardiac pacemaker presence, etc.) are stored in the cluster *I.2.2 "Prohibitions / limitations for movement training"* of the *Database*;

- the results of expert and integral quantitative assessment of movement disorders before and after rehabilitation (8) from the *information unit II* (Unit for movement diagnostics) are stored in the cluster *I.2.3 "The results of expert and integral quantitative assessment of movement disorders"* of *Database*;

- recommended and user-corrected personalized movement training plans from *information unit III* (Unit for creating the personalized movement training plans) are respectively stored in the clusters *I.2.4 "Recommended personalized training plan"* and *I.2.5 "User-corrected personalized training plan"* of the *Database*;

Information unit II, the *Unit for movement diagnostics* (Software module for quantitative assessment of movement disorders "MovementTestStroke 1.1 (MD)" [16]), is designed for distributed expert and integral quantitative assessment based on relevant scales of the Protocol for quantitative assessment of movement disorders of a patient after a stroke [16, 17]:

- by main evidence criteria (muscle strength, volume of movements) [18] of movement disorders of upper and lower extremities at the level of individual joint in proximal (2 joints) and distal (1 joint) parts;

- by additional evidence criteria, such as fine motor skills of the hand (contrasting the thumb, flexing the hand's fingers in fist, the hand's main motor function (capturing), the hand's fingers extension) and structure of walking [17, 19];

- of muscle hyper- or hypotone [17, 18].

Also, the integral quantitative assessments at the level of one joint of aforementioned parts of upper and lower extremities or hand are calculated, and the movement recovery effectiveness are determined.

The functional purpose of the *Unit for movement diagnostics* is a separate presentation of movement testing objects (extremity, hand, gait) and the evidence-based evaluation criteria in tabular form. The movement disorders at the level of the joint of the proximal and distal parts of the upper and lower extremities, fine motor skills of the hand and the gait can be assessed by choice.

In this unit the user selects movement testing object and the evidence criteria of its assessment (5). Depending on the testing object the relevant assessment scales are loaded according to the selected evidence criteria. Based on the scale, the user chooses the right verbal characteristic of this criterion, which allows the program to assess and display on the GUI the quantitative indicator of the movement disorders in points (5).

Summarized results of distributed expert and integral quantitative assessment of movement disorders for current test are displayed for all chosen testing objects (6).

If test of the patient's movements is performed not for the first time in the rehabilitation course, integral assessments of movement disorders from the first test are automatically uploaded (7) to the *Unit for movement diagnostics* from

the cluster *I.2.3* of the *Database*. By comparing the integral assessments for the current and first tests in unit II, the movement recovery effectiveness are calculated, and also are output (6) to the user.

The results of the distributed expert and integral quantitative assessment of movement disorders for current test, and the movement recovery effectiveness are stored (8) in the cluster *I.2.3* of the *Database*.

It should be noted that in contrast to the PC version [20] there is no function for creating the *dynamics of the results of movement tests* in the information unit II (*Unit for movement diagnostics*). In addition, the limitation of the screen size of mobile devices causes a difference in the algorithms of interaction between the user and the information units.

Information unit III, the *Unit for creating the personalized movement training plans*, is used to create the personalized movement training plan, which activates additional patient's reserves for movement rehabilitation according to the severity of movement function disorders and the general state of the patient. The following information is uploaded to this unit from the *Database*:

from cluster *I.2.1*, the information on the neurological status, concomitant diseases, state of emotional and volitional sphere (9);

from cluster *I.2.2*, the prohibition / restriction factors for movement training (10);

from cluster *I.2.3*, the results of distributed expert and integral quantitative assessment of movement disorders for the current test (11), which differs from the PC version [20], where these results come to this unit directly from the *Unit for movement diagnostics*.

According to the relevant decision-making rules, this unit provides the permission / restriction / prohibition for movement training based on certain factors, the determination of permitted movements, methods, programs and movement training duration based on quantitative expert assessment of patient's movement disorders; the correction of these indicators with taking into account concomitant diseases and the state of emotional and volitional sphere; the distribution of the methods, programs, movements and their training duration by priority.

Giving the priority to method, training program comes from the principle of biologically adequate activation of additional patient's reserves to recovery movement at the current rehabilitation stage of the patient [21]. The priority for movement depends on the severity of movement disorders. However, if the patient has elements of motor aphasia, training of the fine motor skills of the hand gets a higher priority. The main factors, determining the training duration, are concomitant diseases, the state of emotional and volitional sphere, individual sensitivity to electrical stimulation, etc.

If there are factors prohibiting completely movement training, the user is notified and the session with the patient ends (12). In case of movement training restrictions, the program continues to work taking into account these restrictions.

The recommended personalized training plan according to priority of its components (methods, programs, movements and their training duration) is displayed on the GUI for the user (12) and is also stored (13) in cluster *I.2.4*, "*Recommended personalized rehabilitation plan*", of the *Database*.

The user checks (12) the recommended personalized plan and marks in this plan specific movements, methods, movement training programs, i.e. creates a personalized plan for movement training at a certain rehabilitation stage.

Next, the user-corrected personalized plan is stored (15) in the cluster *I.2.5*, “*User-corrected personalized rehabilitation plan*”, of *Database*, and is also displayed to the user (14).

According to the created personalized plan, the user begins to train the patient’s movements at a certain rehabilitation stage. After completing the movement training sessions, the user diagnoses the patient’s movements and determines the rehabilitation effectiveness [20].

ALGORITHM FOR CREATING A PERSONALIZED MOVEMENT TRAINING PLANS WITH A SPECIALIZED SOFTWARE MODULE FOR MOBILE PLATFORMS

Creating a personalized recommended and user-corrected movement training plans is based on the results of quantitative assessment of movement disorders taking into account the patient’s general state (neurological status, concomitant diseases, the state of emotional and volitional sphere, etc.).

The algorithm for creation of these plans with the specialized software module “MovementRehabStroke 1.0 (MD)” is aimed at providing the information and consulting assistance to the physician in forming the movement training plan of the patient after a stroke (Fig. 2–4).

According to the structural and functional model (Fig. 1) the creation of the personalized plans begins with *I. Operating with Database* (Fig. 2): loading the patients list, checking the presence of right patient on the list by the user (physician).

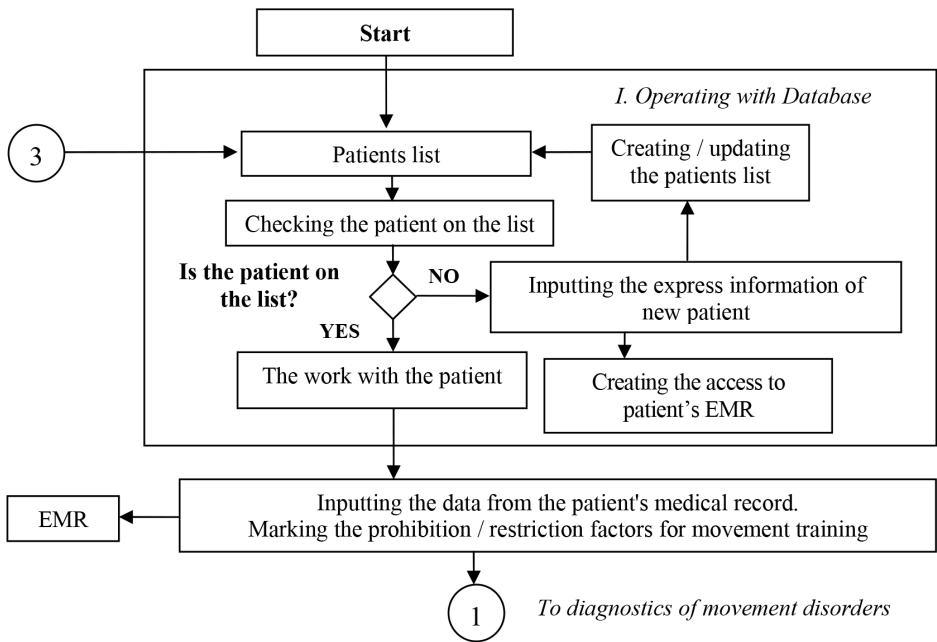


Fig. 2. Algorithm for creating a personalized movement training plans: Operating with Database, Inputting the data from the patient's medical record

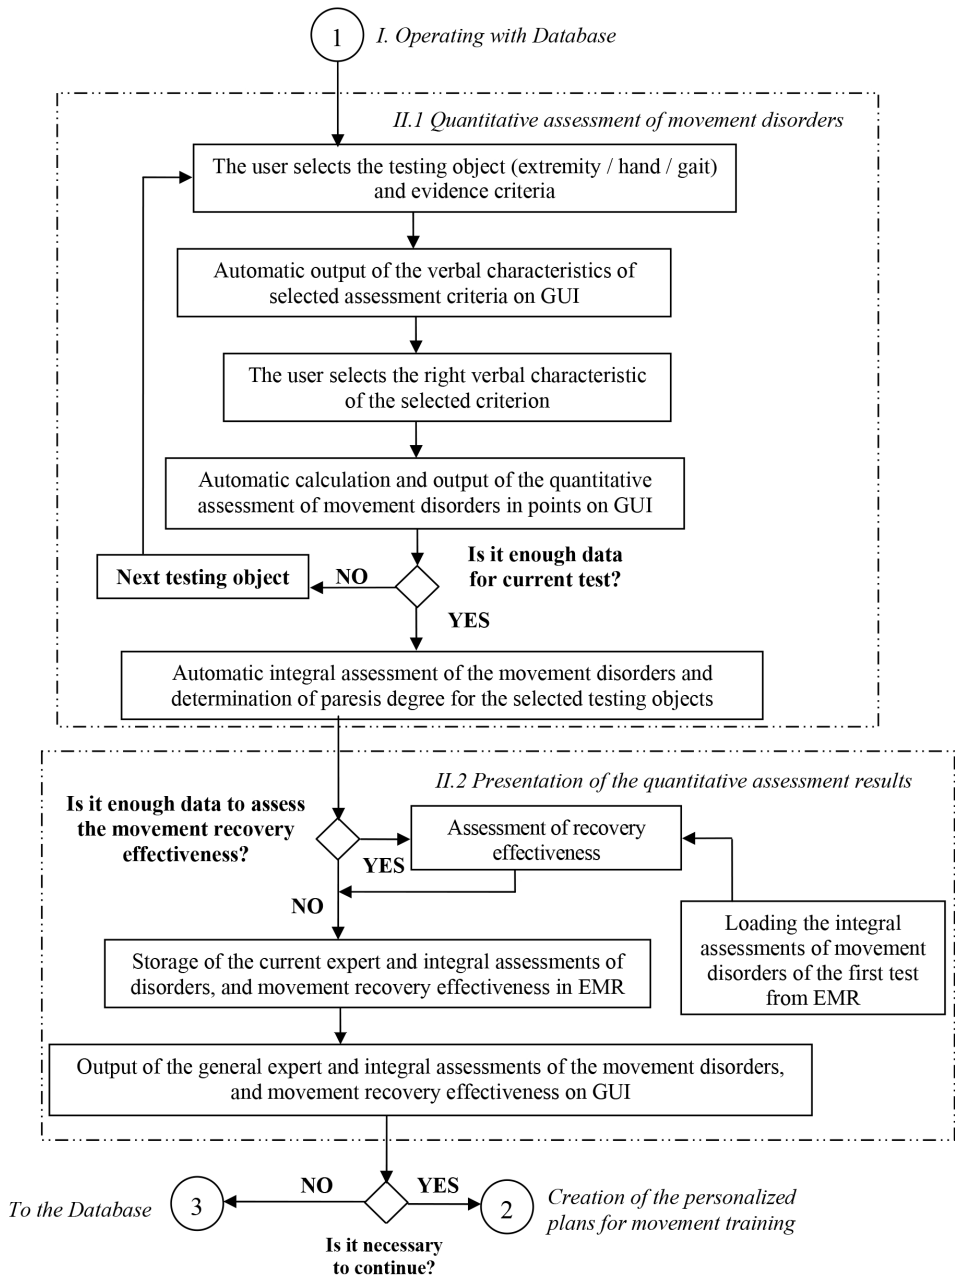


Fig. 3. Algorithm for creating the personalized movement training plans: diagnostics of movements disorders with an information unit for quantitative assessment of movement disorders (“MovementTestStroke 1.1 (MD)” software module)

If the list isn't yet created or such patient is absent, the user inputs express information from patient's medical record for creating / updating the patients list. At the same time, the access to patient's individual EMR is created. The user returns to the updated list.

Then the user inputs the information from the patient medical record (Fig. 2): neurological status, emotional state, concomitant diseases, as well as marks the prohibition / restriction factors for movement training in case of their presence. The information is stored in the patient's EMR.

After that the user moves to *II. Diagnostics of movement deficit*, which is performed by software module «MovementTestStroke 1.1 (MD)» [16]. The algorithm of diagnostics is separated on two parts: *II.1 Quantitative assessment of movement disorders*, and *II.2 Presentation of the results of quantitative assessment* (Fig. 3).

The presentation of the results of quantitative assessment includes determining the movement recovery effectiveness and outputting the results for current movement test.

In case of insufficient data in current test, the user proceeds to another testing object. Otherwise, for selected testing objects the integral assessments of disorders are calculated, and the paresis degrees are determined. Then there is crossing to *II.2 Presentation of the results of quantitative assessment*.

The presentation of the results of quantitative assessment includes determining the movement recovery effectiveness and outputting the results for current movement test.

In case of sufficient information for assessing the movement recovery effectiveness of selected testing objects, the integral assessments of movement disorders for these objects from the first test are loaded from relevant component of EMR. The effectiveness is determined by comparing the integral assessments for the current and first tests, and isn't determined in case of data absence of the first test for selected testing object.

The results for current test and movement rehabilitation effectiveness (in case of its presence) are stored in individual EMR and are displayed by program on the GUI.

The patient session ends if only a quantitative assessment of movement disorders is required, and the user returns to patients list. Otherwise, the user creates the personalized movement training plans.

In case "*III. Creation of personalized movement training plans*" (Fig. 4) there is a check of the permission / restriction / prohibition to perform the training based on prohibition / restriction factors for movement training. If there is a movement training prohibition, the patient session ends and the user is notified on prohibition.

Creating the personalized movement training plan continues in case of training permission. The recommended personalized movement training plan (distributed by priority the permitted movement, methods, programs and movement training duration) is output to the user. This plan is stored in the patient's EMR.

After reviewing the plan, the user corrects it: marks the specific movements, methods, programs. At the same time, user's choice is based on patient's information, which can be viewed optionally. The personalized user-corrected plan is also stored in the patient's EMR and is displayed to the user. If the user doesn't approve this plan, it is possible to correct it with rewriting in the patient's EMR. Finally the patient's personalized user-corrected movement training plan is that plan, according to which the movements are trained at this rehabilitation stage.

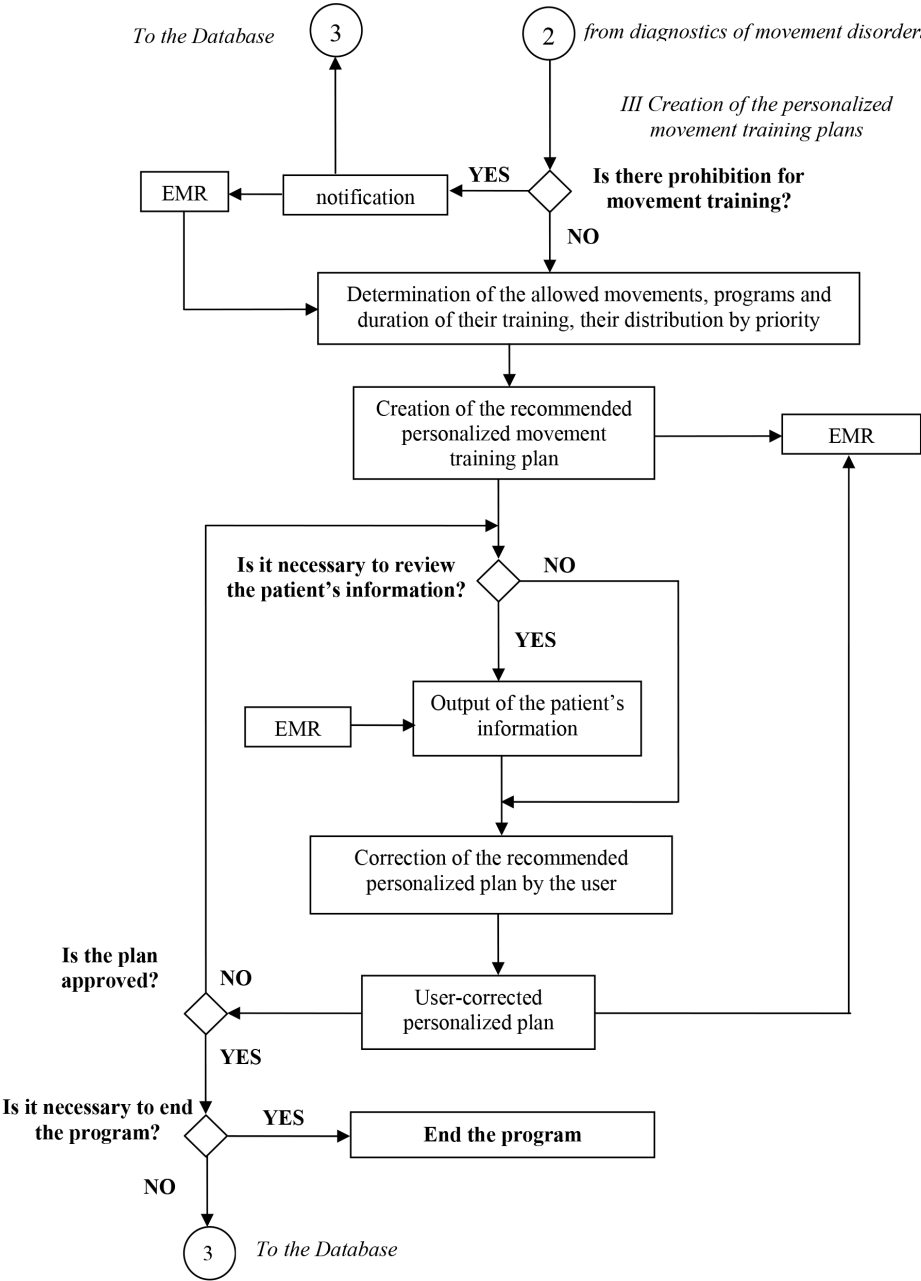


Fig. 4. Algorithm for creating a personalized movement training plans: recommended and user-corrected movement training plans

Then the user either ends the session with the current patient and returns to patients list (Database) or ends the program.

It should be noted that the created personalized movement training plan at a certain stage of rehabilitation course needs to be updated at the following stages.

The patient's rehabilitation course ends with assessment of rehabilitation effectiveness, i.e. comparing the quantitative assessment of movement disorders at the end and at the beginning of the rehabilitation course by the information unit of quantitative assessment of movement disorders "MovementTestStroke 1.1 (MD)".

The feature of the software module "MovementRehabStroke 1.0 (MD)" is that it can be used both to create a personalized movement training plan depending on the quantitative assessment of movement disorders, and only to diagnose the motor function disorders at different rehabilitation stages with the help of information unit "MovementTestStroke 1.1 (MD)".

CONCLUSION

The AI-technology for creating a personalized movement *training* plan for patients after a stroke has been developed. The technology is designed for Android mobile platforms. In order to increase the effectiveness of the rehabilitation process we utilized the the AI tool, the specialized software module "MovementRehabStroke 1.0 (MD)", which provides the information assistance to the user (physician) in creating the personalized training plan. The personalized plan is a multicriteria prioritization of the recommended movements and their training duration, as well as methods and programs of training with using TRENAR[®] devices. Movement training according to this plan provides the activation of the patient's reserves to recover movements, as well as speech motility based on training the fine motor skills of the hand, depending on severity of movement disorders, neurological status, psycho-emotional status, concomitant diseases and rehabilitation stage.

The theoretical basis of the synthesis of AI-technology is the phenomenon of neuroplasticity [22], and principle of personal activation of the patient's reserves to recover movements damaged by pathology (in particular a stroke) [21]. According to this principle, a structural and functional model of the user (physician) interaction with the software module for information assistance in creating the personalized movement training plan after a stroke for mobile platforms "MovementRehabStroke 1.0 (MD)" has been developed.

The module's structure consists of main information units: Database, where information about the patient is stored, the Unit for quantitative assessment of movement disorders by software module "MovementTestStroke 1.1 (MD)", the Unit for creating the personalized movement training plans, recommended and finally corrected by the user, and a GUI that allows the user to work in dialog mode with information units.

The practical basis of synthesis is an algorithm for creating the personalized movement training plans, recommended and finally corrected by the user.

The developed AItechnology enables:

- creation of the personalized movement training plans, recommended and finally corrected by user, and their review on the interface;
- determination of the rehabilitation effectiveness based on quantitative assessment of movement disorders before and after the movement training;
- storage of complete information about a patient (neurological status, concomitant diseases, psycho-emotional state, etc.), assessments of movement disorders before and after the movement training and rehabilitation effectiveness, and movement training plans in the individual EMR of the Database.

Advantages:

- reduction the physician error in diagnostic and treatment decisions;
- the ability to identify the specifics of movement disorders after a stroke;
- personalization of preventive and rehabilitation measures based on advanced functional capabilities for movement disorders diagnostics (distributed and integral quantitative assessment based on evidence criteria at the level of joints of proximal and distal parts of upper and lower extremities, fine motor skills of the hand and gait).

The results of the research enable the creation of new competitive tools of mobile digital medicine to solve urgent problems of quality care for patients after a stroke, the provision and monitoring of rehabilitation and health services not only in clinics but also at home, as well as and enable utilization of new information technologies with AI tools in educational programs.

REFERENCES

1. Gorelick P.B. The global burden of stroke: Persistent and disabling. *Lancet Neurol.* 2019. Vol. 18. № 5. pp. 417–418.
2. Delpont B., et.al. Pain after stroke: A review. *Revue neurologique.* 2018. Vol. 174. № 10. pp. 671–674.
3. Buono Lo, Corallo F., Bramanti P., Marino S. Coping strategies and health-related quality of life after stroke. 2017. *J. Health Psychol.* 2017. Vol. 22. № 1. pp. 16–28.
4. Jorgensen H.S., Nakayama H., Raaschou H.O., Olsen T.S. Recovery of walking function in stroke patients: the Copenhagen Stroke Study. *Archives of Physical Medicine and Rehabilitation.* 1995. Vol. 76(1). pp. 27–32.
5. Holland A., Fridriksson J. Aphasia management during the early phases of recovery following stroke. *American Journal of Speech-Language Pathology.* 2001. Vol. 10 (1). pp. 19–28.
6. Berthier M.L. Poststroke aphasia: epidemiology, pathophysiology and treatment. *Drugs Aging.* 2005. Vol. 22(2). pp. 163–182.
7. Hatem S.M., Saussez G., Faille M.D., Prist V. Rehabilitation of motor function after stroke: A multiple systematic review focused on techniques to stimulate upper extremity recovery. *Frontiers Hum. Neurosci.* 2016. Vol. 10. P. 442.
8. Upper Limb Rehabilitation System for Stroke Survivors Based on Multi-Modal Sensors and Machine Learning / Sheng Miao, et.al. *IEEE Access: Special section on AI and IoT convergence for smart health.* 2021. Vol. 9. pp. 30283–30291.
9. Hossain M.S. Cloud-supported cyber-physical localization framework for patients monitoring. *IEEE Syst. J.* 2015. Vol. 11. № 1. pp. 118–127.
10. Stinear C.M., Lang C.E., Zeiler S., Byblow W.D. Advances and challenges in stroke rehabilitation. *Lancet Neurol.* 2020. Vol. 19. № 4. pp. 348–360.
11. Vovk M.I., Galyan Ye.B. Restoring of motor component of speech based on muscle movement control. Theoretical grounding. *Cybernetics and Computer Engineering.* 2012. № 167. pp. 51–60. (in Russian).

12. Varun H Buch, Irfan Ahmed, Mahiben Maruthappu. Artificial intelligence in medicine: current trends and future possibilities. *Br J Gen Pract.* 2018. № 68(668). pp. 143–144.
13. The Oxford Dictionary of Current English. Oxford: Oxford University Press, 2001. 3rd edition. 1083 p.
14. Ahuja A.S. The impact of artificial intelligence in medicine on the future role of the physician. *PeerJ.* 2019. URL: <http://doi.org/10.7717/peerj.7702> (Last accessed: 01.09.2021)
15. Artificial intelligence in medicine: the main trends in the world. URL: https://medaboutme.ru/zdorove/publikacii/stati/soveti_vracha/iskusstvennyy_intell_ekt_v_meditsine_glavnye_trendy_v_mire/ (Last accessed: 1.04.2021) (in Russian).
16. Vovk M.I., Kutsiak O.A. AI-Technology of Motor Functions Diagnostics after a Stroke. *Cybernetics and Computer Engineering.* 2021. № 2 (204). pp. 84–100.
17. Vovk M.I., Kutsyak O.A. Software module for personal diagnostics of motor functions after stroke. *Cybernetics and Computer Engineering.* 2019. № 4 (198). pp. 62–77.
18. Belova A., Shchepetova O. Scales, tests and questionnaires in medical rehabilitation. Moscow: Antidor, 2002. 440 p. (in Russian)
19. Smychek V., Ponomareva E. Craniocerebral trauma (clinic, treatment, examination, rehabilitation). Minsk: Research Institute of ME and R, 2010. 430 p. (in Russian)
20. Vovk M.I., Kutsyak O.A. Information technology for forming a personal movement rehabilitation plan after a stroke. *Cybernetics and Computer Engineering.* 2020. № 3 (201). pp. 87–99.
21. Vovk M.I. Information technology of movement control. Evolution of synthesis and development prospects. *Cybernetics and Computer Engineering.* 2018. № 4 (194). pp. 79–97. (in Ukrainian).
22. Ugryumov M.V. Compensatory capabilities of the brain. URL: <http://www.den-zadnem.ru/page.php?article=576s> (Last accessed: 01.09.2021) (in Russian)

Received 15.09.2021

ЛІТЕРАТУРА

1. Gorelick P.B. The global burden of stroke: Persistent and disabling. *Lancet Neurol.* 2019. Vol. 18. № 5. pp. 417–418.
2. Pain after stroke: A review / B. Delpont, et.al. *Revue neurologique.* 2018. Vol. 174. № 10. pp. 671–674.
3. Buono Lo, Corallo F., Bramanti P., Marino S. Coping strategies and health-related quality of life after stroke. 2017. *J. Health Psychol.* 2017. Vol. 22. № 1. pp. 16–28.
4. Jorgensen H.S., Nakayama H., Raaschou H.O., Olsen T.S. Recovery of walking function in stroke patients: the Copenhagen Stroke Study. *Archives of Physical Medicine and Rehabilitation.* 1995. Vol. 76(1). pp. 27–32.
5. Holland A., Fridriksson J. Aphasia management during the early phases of recovery following stroke. *American Journal of Speech-Language Pathology.* 2001. Vol. 10 (1). pp. 19–28.
6. Berthier M.L. Poststroke aphasia: epidemiology, pathophysiology and treatment. *Drugs Aging.* 2005. Vol. 22(2). pp. 163–182.
7. Hatem S.M., Saussez G., Faille M.D., Prist V. Rehabilitation of motor function after stroke: A multiple systematic review focused on techniques to stimulate upper extremity recovery. *Frontiers Hum. Neurosci.* 2016. Vol. 10. P. 442.
8. Upper Limb Rehabilitation System for Stroke Survivors Based on Multi-Modal Sensors and Machine Learning / Sheng Miao, et.al. *IEEE Access: Special section on AI and IoT convergence for smart health.* 2021. Vol. 9. pp. 30283–30291.
9. Hossain M.S. Cloud-supported cyber-physical localization framework for patients monitoring. *IEEE Syst. J.* 2015. Vol. 11. № 1. pp. 118–127.
10. Stinear C.M., Lang C.E., Zeiler S., Byblow W.D. Advances and challenges in stroke rehabilitation. *Lancet Neurol.* 2020. Vol. 19. № 4. pp. 348–360.
11. Вовк М.І., Галян Е.Б. Восстановление моторного компонента речи на базе управления мышечными движениями. Теоретическое обоснование. *Кибернетика и числ. техника.* 2012. № 167. С. 51–60.

12. Varun H Buch, Irfan Ahmed, Mahiben Maruthappu. Artificial intelligence in medicine: current trends and future possibilities. *Br J Gen Pract.* 2018. № 68(668). pp.143–144.
13. The Oxford Dictionary of Current English. Oxford: Oxford University Press, 2001. 3rd edition. 1083 p.
14. Ahuja A.S. The impact of artificial intelligence in medicine on the future role of the physician. *PeerJ.* 2019. URL: <http://doi.org/10.7717/peerj.7702> (Дата звернення: 01.09.2021)
15. Искусственный интеллект в медицине: главные тренды в мире. URL: https://medaboutme.ru/zdorove/publikacii/stati/sovety_vracha/iskusstvennyy_intellekt_v_medsine_glavnye_trendy_v_mire/ (Дата звернення: 1.04.2021)
16. Vovk M.I., Kutsiak O.A. AI-Technology of Motor Functions Diagnostics after a Stroke. *Cybernetics and Computer Engineering.* 2021. № 2 (204). pp. 84–100.
17. Vovk M.I., Kutsyak O.A. Software module for personal diagnostics of motor functions after stroke. *Cybernetics and Computer Engineering.* 2019. № 4 (198). pp. 62–77.
18. Белова А., Щепетова О. Шкалы, тесты и опросники в медицинской реабилитации. М.: Антидор, 2002. 440 с.
19. Смычек В., Пономарева Е. Черепно-мозговая травма (клиника, лечение, экспертиза, реабилитация). Мн.: НИИ МЭ и Р, 2010. 430 с.
20. Vovk M.I., Kutsyak O.A. Information technology for forming a personal movement rehabilitation plan after a stroke. *Cybernetics and Computer Engineering.* 2020. № 3 (201). pp. 87–99.
21. Вовк М.І. Інформаційна технологія керування рухами. Еволюція синтезу і перспективи розвитку. *Кибернетика и вычислительная техника.* 2018. № 4 (194). С. 79–97.
22. Угрюмов М.В. Компенсаторные возможности мозга. URL: <http://www.den-zadnem.ru/page.php?article=576s> (Дата звернення: 01.09.2021)

Отримано 15.09.2021

Вовк М.І., канд. біол. наук, старш. наук. співроб.,
зав. відд. біоелектричного керування та медичної кібернетики
ORCID: 0000-0003-4584-9553

e-mail: vovk@irtc.org.ua; imvovk3940@gmail.com

Куцяк О.А., канд. техн. наук,
старш. наук. співроб., відд. біоелектричного керування та медичної кібернетики
ORCID: 0000-0003-2277-7411

e-mail: spirotech85@ukr.net

Міжнародний науково-навчальний центр

інформаційних технологій та систем

НАН України та МОН України,

пр. Акад. Глушкова 40, м. Київ, 03187, Україна

МОБІЛЬНА AI-ТЕХНОЛОГІЯ ФОРМУВАННЯ ПЕРСОНАЛІЗОВАНОГО ПЛАНУ РЕАБІЛІТАЦІЇ РУХІВ ПІСЛЯ ІНСУЛЬТУ

Вступ. Наслідки інсульту серйозно змінюють якість життя. Особливо страждає рухова активність. Вагомими є також мовленнєві порушення. Синтез ефективних технологій відновлення рухів, тонкої моторики кисті, яка відіграє значну роль у відновленні моторики мовлення, є актуальним науково-прикладним завданням.

Останнім часом у медицині увагу привертає застосування штучного інтелекту. Одночасно розвитку набувають мобільні технології. Вважають, що штучний інтелект у смартфоні зробить медицину майбутнього доступною для всіх.

Мета — розроблення технології відновлення рухів після інсульту, в якій для підвищення ефективності реабілітаційного процесу застосовано інструмент штучного інтелекту — встановлений у структурі мобільних платформ спеціалізований програм-

ний модуль інформаційної допомоги користувачу (лікарю) у формуванні персоналізованого плану на різних етапах реабілітації.

Результати. Розроблено AI-технологію формування персоналізованого плану тренувань рухів у пацієнтів після інсульту із застосуванням інструментів штучного інтелекту — встановленого у структурі мобільних платформ програмного модуля інформаційної допомоги у визначенні плану «MovementRehabStroke 1.0 (MD)», який за результатами кількісного оцінювання дефіциту рухів пацієнта програмним модулем «MovementTestStroke 1.1 (MD)» з урахуванням загального стану пацієнта надає користувачу рекомендований план та уможливорює його коригування. Надано структурно-функційну модель взаємодії користувача (лікаря) з програмним модулем «MovementRehabStroke 1.0 (MD)», а також алгоритм формування персоналізованого плану реабілітації рухів — рекомендованого та остаточно сформованого лікарем.

Висновки. Застосування інструментів штучного інтелекту сприятиме: зменшенню можливості помилки лікаря у прийнятті діагностично-реабілітаційних рішень, запобіганню розвитку ускладнень, зменшенню ризику набуття інвалідності, уможливить підвищення якості та масове використання реабілітаційних послуг пацієнтами після інсульту.

Ключові слова: інсульт, AI-технологія, персоналізований план, тренування рухів, реабілітація, діагностика, програмний модуль, структурно-функційна модель, алгоритм.

System Index of Articles Published in 2021

Informatics and Information Technologies

- SUROVTSEV I.V., GALIMOV S.K., GALIMOVA V.M., SARKISOVA M.V. Method of Chronoionometric Determination of Concentrations of Fluorine, Nitrate, Ammonium in Drinking Water 1(203)
- АНИСІМОВ А.В., БЕВЗА М.В., БОБИЛЬ Б.В. Прогнозування відгуків на візуально-текстовий контент з використанням нейронних мереж 1(203)
- ГРИЦЕНКО В.І., БАБАК О.В., СУРОВЦЕВ І.В. Особливості взаємозв'язку мереж 5G, 6G з великими даними, інтернетом речей та штучним інтелектом 2(204)
- CHABANIUK V.S., KOLIMASOV I.M., KRAKOVSKYI S.P. Critical Systemic Properties of Electronic Atlases New Generation. Part 1: Problem and Research Methods 2(204)
- GRITSENKO V.I., GLADUN A.Ya., KHALA K.O., RODRIGO MARTÍNEZ-BÉJAR Semantical Similarity Evaluation Method of Concepts for Comparison of Ontologies in Applied Problems of Artificial Intelligence 3(205)
- CHABANIUK V.S., KOLIMASOV I.M. Critical Systemic Properties of Electronic Atlases New Generation. Part 2: Research Results 3(205)
- MOROZ O.H., STEPASHKO V.S. Comparative Features of Multilayered Iterative Algorithm GMDH and Deep Feed-Forward Neural Networks 4(206)
- СУРОВЦЕВ І.В., ВЕЛИКИЙ П.Ю., ГРИЦАЧЕНКО М.О., ГАЛІМОВА В.М. Аналітична система для моніторингу та оцінки ризиків споживання питної води 4(206)

Intelligent Control and Systems

- MISHCHENKO M.D., GUBAREV V.F. Horizon Length Tuning for Model Predictive Control in Linear Multi Input Multi Variable Systems 1(203)
- ШЕПЕТУХА Ю.М., ВОЛКОВ О.Є., КОМАР М.М. Інтелектуалізація процесів прийняття рішень в автономних системах керування 2(204)
- ARALOVA N.I., KLYUCHKO O.M., MASHKIN V.I., MASHKINA I.V., RADZIEJOWSKI P.A., RADZIEJOWSKA M.P. Mathematical Model of Conflict Controlled Processes in Self-Organization of Respiratory System 3(205)
- VOLKOV O.Ye., TARANUKHA V.Yu., LINDER Ya.M., KOMAR M.M., VOLOSHENIUK D.O. Devising an Acoustic Method for Investigation of a Complex Form Object Parameters 4(206)

Medical and Biological Cybernetics

- ARALOVA N.I., KLYUCHKO O.M., MASHKIN V.I., MASHKINA I.V. Mathematical Model of Functional Respiratory System for the Investigation of Harmful Organic Compounds Influences in Industrial Regions 1(203)

KRYVOVA O.A., KOZAK L.M. Information Technology for Classification of Donosological and Pathological States Using the Ensemble of Data MiningMethods	1(203)
FAINZILBERG L.S., SOLOVEY S.R. Self-learning Information Technology for Detecting Respiratory Disorders in Home Conditions	2(204)
VOVK M.I., KUTSIK O.A. AI-Technology of Motor Functions Diagnostics After a Stroke	2(204)
DANILOVA V.V., SHLYKOV V.V., DUBKO A.A. Determination of Influence Parameters of High Frequency Current on Living Tissues	3(205)
СРМАКОВА І.Й., БОГАТЬОНКОВА А.І., НІКОЛАЄНКО А.Ю., ТАДЕЄВА Ю.П., ГРИЦАЮК О.В., СОЛЮПЧУК Ю.М. М-Health технологія для прогнозування стану людини в екстремальних умовах середовища	3(205)
KRYVOVA O.A., KOZAK L.M., KOVALENKO O.S. NENASHEVA L.V. Prediction of Surgery Control Parameters in Cardiology to Optimize the Emission Fraction Values with the Help of Neural Networks	4(206)
VOVK M.I., KUTSIK O.A. Mobile AI-technology for Forming the Personalized Movement Rehabilitation Plan After a Stroke	4(206)

У журналі надано результати досліджень у галузях теорії та практики інтелектуального керування, інформатики та інформаційних технологій, а також біологічної та медичної кібернетики.

Цільова аудиторія — науковці, інженери, аспіранти та студенти вищих навчальних закладів відповідного фаху.

Вимоги до рукописів статей

1. Рукопис надають на папері у двох примірниках (мова — англійська, українська, 17–22 с.) та електронну версію. До рукопису додають:

- анотації — українською та англійською мовами (прізвище, ініціали автора/ів, місце роботи, місто, країна, назва статті, текст 250–300 слів, з виділенням рубрик: вступ, мета, результати, висновки, ключові слова 5–8 слів);

- список літератури мовою оригіналу — у порядку згадування в тексті, за стандартом ДСТУ 8302:2015;

- список літератури — переклад джерел англійською мовою, прізвища та ініціали авторів — транслітерація;

- ліцензійний договір;

- відомості про автора/ів українською та англійською мовами повинні містити: ПІБ, вчений ступінь, наукове звання, посада, відділ, місце роботи, поштова адреса організації, телефон (для зв'язку редактора), авторські ідентифікатори ORCID або ResearcherID, E-mail.

2. Текст статті подають з обов'язковими рубриками: вступ, постановка завдання/проблеми, мета, результати, чітко сформульовані висновки.

Вимоги до текстового файлу

Формат файлу * .doc, * .rtf. Файл повинен бути підготовлений за допомоги текстового редактора Microsoft Word.

Використовувані стилі: шрифт Times New Roman, 12 пт, міжрядковий інтервал – 1,5. Формат паперу А4, всі береги — 2 см.

Формули набирають у редакторах формул Microsoft Equation Editor 3.0. та MathType 6.9b. Опції редактора формул — (10,5; 8,5; 7,5; 14; 10). **Ширина формул — до 12 см.**

Рисунки повинні бути якісними, створені вбудованим редактором рисунків Word Picture або іншими Windows-додатками (рисунки надають окремими файлами відповідних форматів). **Ширина рисунків — до 12 см.**

Таблиці виконують стандартним вбудованим у Word інструментарієм «Таблиця». **Ширина таблиці — до 12 см.**

Передплату на журнал (друкована версія) в Україні здійснюють:

- за «Каталогом видань України», індекс передплати друкованої версії — 86598;
- за допомоги передплатної агенції «Укрінформнаука» НАН України, ukrinformnauka@gmail.com, індекс журналу — 10029