

**СИСТЕМНЫЙ АНАЛИЗ
И ПРИКЛАДНАЯ
ИНФОРМАТИКА**

№ 2, 2025

**SYSTEM ANALYSIS
AND APPLIED
INFORMATION SCIENCE**

No 2, 2025



**Международный
научно-технический журнал**

Издается с декабря 2012 года

Учредитель

Белорусский национальный
технический университет

Главный редактор

Дробыш Алексей Анатольевич

Редакционная коллегия

Д. В. Капский (зам. главного редактора),
А. А. Большаков (РФ),
В. А. Вишняков, Л. С. Герасимович,
А. В. Гулай, Н. Н. Гурский,
О. О. Зарипов (Узбекистан),
А. А. Лобаты, С. А. Ляпин (РФ),
В. А. Малкин, А. В. Малолетов (РФ),
И. А. Сатиков (ответственный секретарь),
В. В. Старовойтов, В. А. Федоров (РФ),
С. В. Харитончик, Ю. Ф. Яцына,
Чень Дунъюэ (Китай), Янг Янг (Китай)

**International
Science and Technical Journal**

Published since December, 2012

Founder

Belarusian National
Technical University

Editor-in-chief

A. Drobysch

Editorial board

D. Kapski (deputy editor-in-chief),
A. Bolshakov (RF),
V. Vishnyakou, L. Gerasimovich,
A. Gulaj, N. Gursky,
O. Zaripov (Uzbekistan),
A. Lobaty, S. Lyapin (RF),
V. Malkin, A. Maloletov (RF),
I. Satikov (executive secretary),
V. Starovoitov, V. Fedorov (RF),
S. Haritonchik U. Yatsyna,
Chen Dongyue (Kitaj), Yang Yang (Kitaj)

Журнал включен в “Перечень научных изданий Республики Беларусь
для опубликования результатов диссертационных исследований”

Журнал включен в международные каталоги и базы данных:

- | | |
|--|---------------|
| ❖ Российский индекс научного цитирования (РИНЦ) | ❖ EBSCO |
| ❖ Научная электронная библиотека eLIBRARY.RU | ❖ BASE Search |
| ❖ Электронно-библиотечная система (ЭБС) издательства Лань | ❖ OpenAIRE |
| ❖ DOAJ https://doaj.org/toc/2414-0481 | ❖ WorldCat |
| ❖ Google Scholar | ❖ OpenDOAR |
| ❖ Киберленинка | ❖ ROAR |

Ведущий научный редактор

И. А. Сатиков

Технический редактор

О. Л. Чабарова

Адрес редакции

пр. Независимости, 65, Минск, 220013,
Республика Беларусь
Тел. +375 17 266-26-58
e-mail: ca_pi@bntu.by

Executive secretary of the editorial board

I. Satikov

Technical Editor

V. Chabarava

Editorial board address

Nezavisimosty Ave., 65, Minsk, 220013,
Republic of Belarus
Tel. +375 17 266-26-58
e-mail: ca_pi@bntu.by

Свидетельство о государственной регистрации средства массовой информации
№ 1540 от 08.06.2012, выданное Министерством информации Республики Беларусь

Подписано в печать 00.00.2025. Формат бумаги 60x84 1/8. Бумага мелованная.

Цифровая печать. Усл. печ. л. 8,84. Уч.-изд. л. 5,3. Тираж 50 экз. Заказ 0000.

Отпечатано в БНТУ. ЛП № 38200000006896 от 03.03.2014.

220013, г. Минск, пр. Независимости, 65.

СОДЕРЖАНИЕ

СИСТЕМНЫЙ АНАЛИЗ

Rulko E.V.

Applying attention U-Net with PyTorch architectural add-ons for extensive hyperparameter search with weights & biases for area of visibility prediction based on terrain.....4

Солонец А.В., Снарский А.С.

Применение искусственного интеллекта для прогнозирования риска травм у спортсменов: подход с использованием рекуррентных нейронных сетей.....11

УПРАВЛЕНИЕ ТЕХНИЧЕСКИМИ ОБЪЕКТАМИ

Гулай А.В., Зайцев В.М.

Оптимизация процесса обработки заданий в мульти-агентной интеллектуальной системе.....18

Сидоренко А.В., Солодухо Н.А.

Алгоритм обигания препятствий при перемещении мобильного робота с использованием Q-обучения и технологии блокчейн.....26

Лю Юйвэй, Саражинский Д.С., Капский Д.В.

Разработка варианта гибкого управления движением транспортных потоков для организации безостановочного движения маршрутного пассажирского транспорта в зоне регулируемого перекрестка.....32

ОБРАБОТКА ИНФОРМАЦИИ И ПРИНЯТИЕ РЕШЕНИЙ

Хайдаров Ш.И.

Оценка эффективности алгоритмов выявления рака с использованием синтетических данных на основе машинного обучения.....46

ЗАЩИТА ИНФОРМАЦИИ

Голиков В.Ф., Радюкевич М.Л., Шуляк Д.В.

Двухсторонняя атака на синхронизируемые искусственные нейронные сети, формирующие общий секрет.....55

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ В ОБРАЗОВАНИИ

Конопацкий Д.А., Лобаты А.А.

Система поддержки принятия решений при управлении образовательным процессом.....61

Никольшин Б.В., Кисель Т.В.

Оптимизация распределения зачисленных абитуриентов по учебным группам.....68

CONTENTS

SYSTEM ANALYSIS

Rulko E.V.

Applying attention U-Net with PyTorch architectural add-ons for extensive hyperparameter search with weights & biases for area of visibility prediction based on terrain.....4

Solonets A.V., Snarsky A.S.

Application of artificial intelligence for predicting injury risk in athletes: an approach using recurrent neural networks.....11

MANAGEMENT OF TECHNICAL OBJECTS

Gulaj A.V., Zajcev V.M.

Optimization of task processing in a multi-agent intelligent system.....18

Sidorenko A.V., Saladukha M.A.

Algorithm for obstacle avoidance in mobile robot navigation using Q-learning and blockchain technology.....26

Liu Yuwei, Sarazhinsky D.S., Kapski D.V.

Development of a flexible traffic flow management option for organizing non-stop traffic of public transport in the area of a controlled intersection32

DATA PROCESSING AND DECISION-MAKING

KHaydarov SH.I.

Assessing the efficiency of the cancer detection algorithms using synthetic data based on machine learning.....46

INFORMATION SECURITY

Holikau U.F., Radziukevich M.L., SHuliak D.V.

Two-way attack on synchronized artificial neural networks forming a common secret.....55

INFORMATION TECHNOLOGIES IN EDUCATION

Konopacki D.A., Lobaty A.A.

Decision support system in educational process management.....61

Nikulshin B.V., Kisel T.V.

Optimization of distribution of enrolled applicants in study groups.....68

**СИСТЕМНЫЙ
АНАЛИЗ**

SYSTEM ANALYSIS

RULKO E.V.

APPLYING ATTENTION U-Net WITH PyTorch ARCHITECTURAL ADD-ONS FOR EXTENSIVE HYPERPARAMETER SEARCH WITH Weights & Biases FOR AREA OF VISIBILITY PREDICTION BASED ON TERRAIN

Military Academy of the Republic of Belarus
Minsk, Republic of Belarus

Abstract. Current level of development in the sphere of deep learning allows replacing existing domain-specific algorithms for military simulation with approximating neural networks. Hyperparameter search allows finding network's architecture, appropriate for a task. This work describes that process for the task of predicting area of optical visibility, taking a fragment of a digital map as input and proposes ancillary architectural solutions for stitching building blocks together, assuring their conformation for performing search among their possible combinations within the architectural space. The final proposed result is a channel-wise attention U-Net with an encoder, based on ResNet50 backbone.

Keywords: : deep learning, U-Net, attention, segmentation, hyperparameter search, W&B, template method

Introduction

Calculation of an area of potential visibility, based on current terrain and the position of an observer, plays an important role in military simulation. For air defense simulators [1] it's essential to get radar coverage – Figure 1.

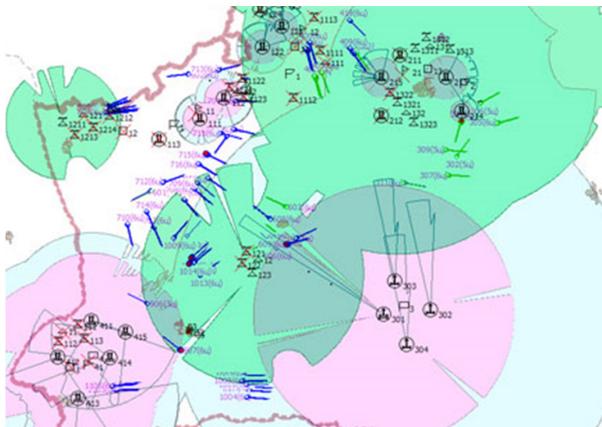


Figure 1. Radar coverage based on terrain

In ground forces simulators [2] every unit must be provided with an area of optical visibility – Figure 2. Building such areas in both cases require moving along azimuth direction with certain discretization and calculating angles of elevation. At the same time current development of deep learning allows tackling such tasks, including calculation of some military domain-specific areas on a map, like artillery shooting range area, area of sustainable communication with the influence of electronic warfare equipment, range of effective fire for specific arms depending on conditions and so on.

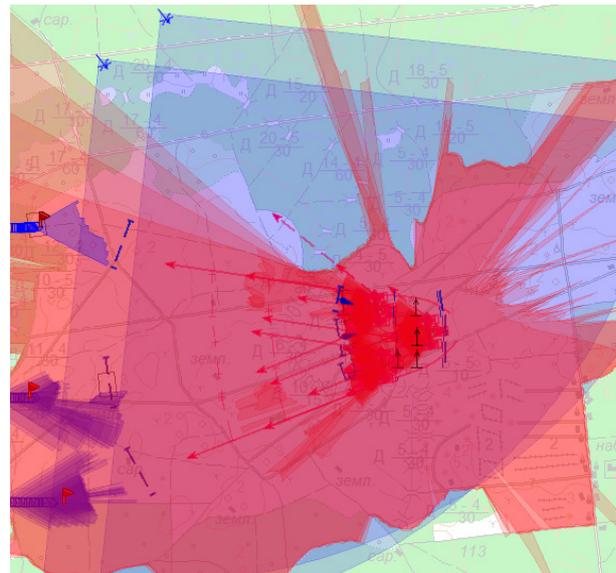


Figure 2. Areas of optical visibility

Transferring military simulation fully into the realm of deep learning, where neural networks are trained on “hardcoded” solutions, will allow building End-to-End systems for military operation planning and utilizing power of generative artificial intelligence for that.

Proposed approach

The area of optical visibility is calculated based on matrixes of height and surfaces for a correspondent patch of area. Usage of the existing military simulation system [2] provides limitless amount of training data. U-Net architecture [3] is widely used for the purpose of producing a mask within the boundaries of the original image,

for task like semantic segmentation. In our case it takes three channels: ideal area, height and surface matrices (U-Net is modified in order to take three input channels) and must produce an area of optical visibility within

circumscribed area around a hypothetical observer, situated at the center point. Then the output can be compared with the ground truth area of visibility given from a simulator – Figure 3.

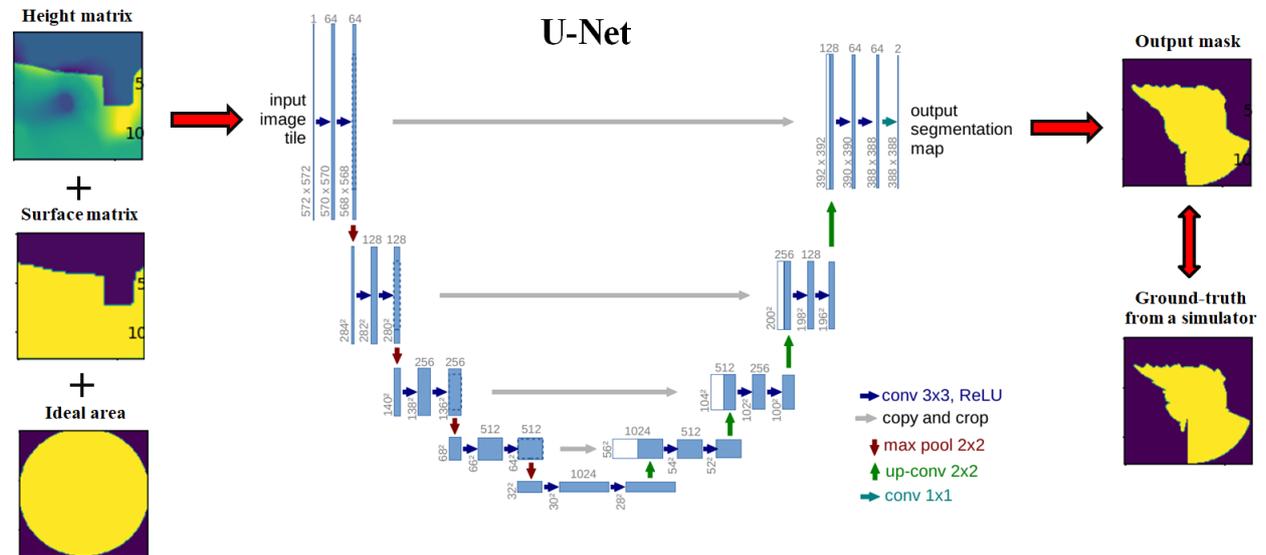


Figure 3. Area of visibility prediction as a mask

However, the usage of U-Net per se, hasn't proved to work well for this. During the research,

several approaches were considered, including attention U-Net [4] – Figure 4.

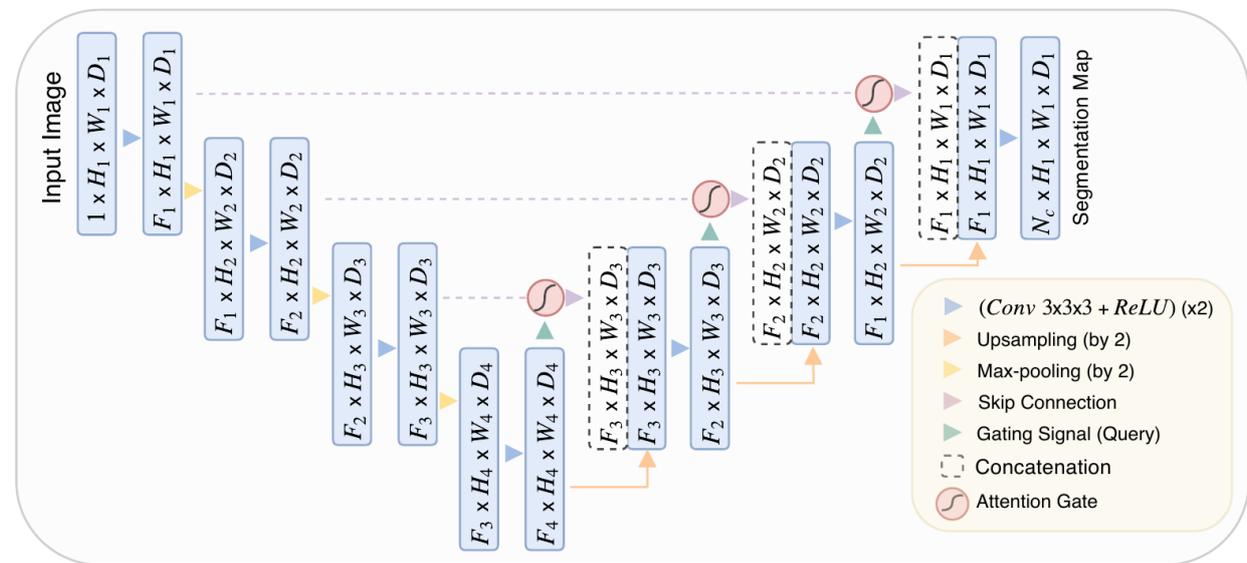


Figure 4. Attention U-Net model [4]

The key idea behind this model is usage of attention gates which learn to suppress irrelevant regions in an input image while highlighting salient features useful for a specific task.

Usage of *Weights & Biases* (W&B) developer platform [5] has proved to be effective for search of optimal hyperparameters such as: learning rate, batch size, dropout values and others. However, search must

also be conducted in the architectural space, because of a plethora of possible solutions for particular parts of attention U-Net, like usage of spatial, channel-wise or combined attention; usage of a model that is trained from scratch, like in [6] or usage of a pretrained backbone as an encoder; way of upsampling, like a 2D transposed convolution or a bilinear method; numbers of internal parameters in different attentions blocks and others.

Within W&B sweeps a tested model often must be rebuilt with different architectural parts, instead of just picking a model from list of preconfigured, because of the exorbitant amount of possible combinations. Chosen parts must match each other, like in a case when a

number of output channels of a convolutional layer is a tuned hyperparameter, and a consequent fully connected layer must conform that. The following architecture is proposed for assuring compatibility of separate building blocks – Figure 5.

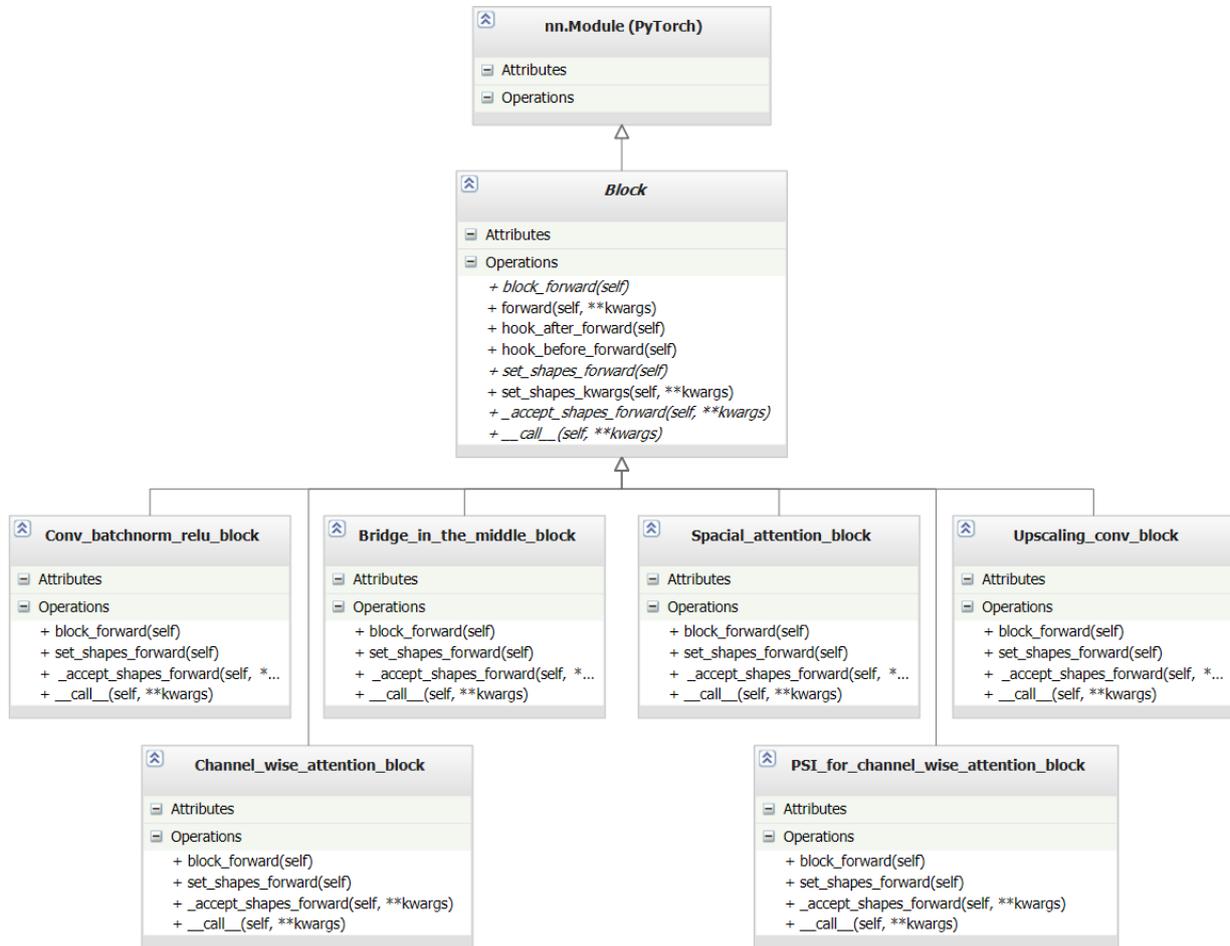


Figure 5. Hierarchy of blocks

An abstract class *Block* is inherited from PyTorch *nn.Module* and presents a set of abstract methods to be redefined in subclasses. A *forward* method represents a *Template method* pattern [7] which defines a set of consecutive steps (*hook_before_forward*, *block_forward* and *hook_after_forward*) implemented in subclasses. In the current model architecture some blocks contain others, representing a nested structure, like *Upscaling_conv_block* may contain *Channel_wise_attention_block* which contains *PSI_for_channel_wise_attention_block*. The parameters of nested blocks are set by a higher level block during the first call of *block_forward* through calling *set_shapes_forward* method on nested blocks. Each nested block may have a different signature of parameters to configure, so it in turn calls a not abstract method *set_shapes_kwargs* defined in a *Block* class which checks the matching of number and shapes of passing arguments (just **kwargs*) and calls a

method *accept_shapes_forward*, which is implemented by a nested block and has a specific set of parameters in a signature (not just **kwargs*) – Figure 6. Such a gimmick allows having self-descriptive signatures like *accept_shapes_forward (self, _gate_plus_x_num_ch: int, x_channels_number: int)* in *PSI_for_channel_wise_attention_block* class, instead of just passing a dictionary of keywords and parsing them uniquely, depending on a building block. It increases code readability and also allows checking and handling possible mismatch without generating an exception.

Abstract_element_builder class provides a set of methods for getting building blocks, based on current values from W&B during sweeps for hyperparameter search – Figure 7. Two concrete implementations of it (*WandB_elementbuilder* and *Solitary_elementBuilder*) allow switching between the modes of performing W&B sweeps and manual experiments.

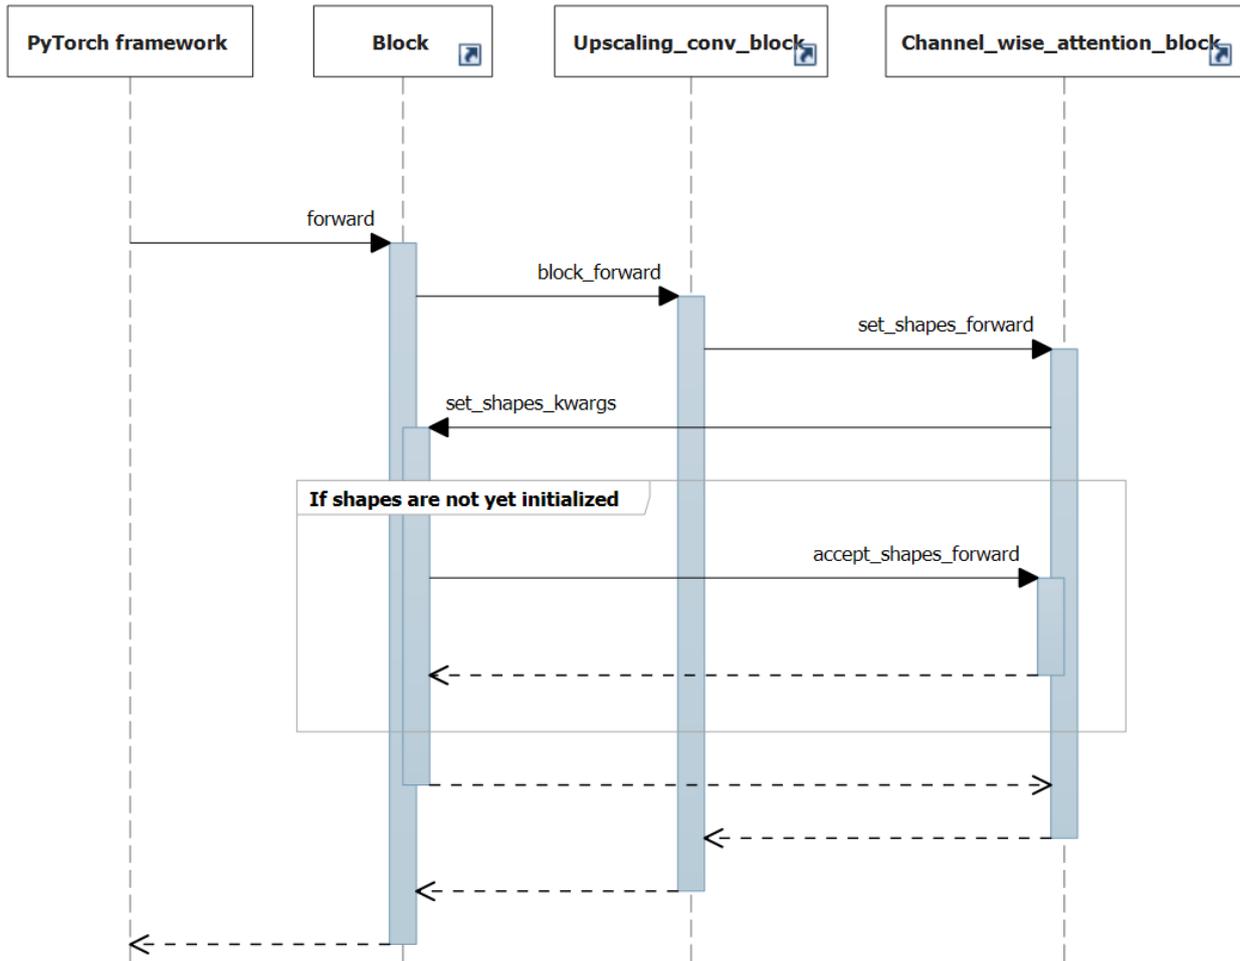


Figure 6. Steps of shape initialization during the *forward* method call

Abstract_train_mode class provides a set of abstract methods for getting parameters, necessary for the training process – Figure 8.

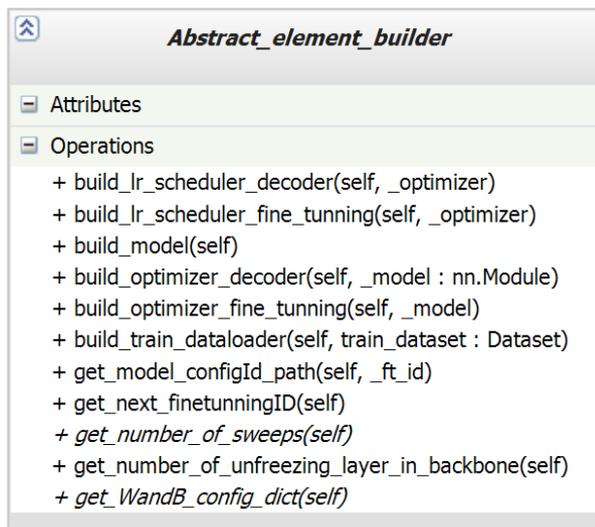


Figure 7. Abstract element builder class

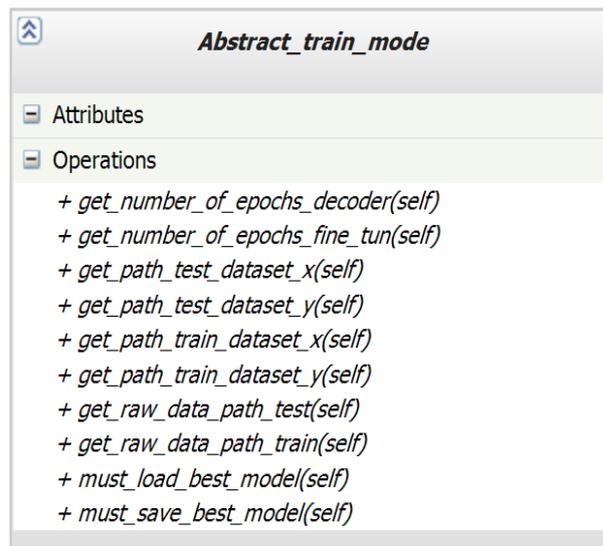


Figure 8. Abstract train mode class

Its main purpose is to support two cases. One of them – End-to-End testing that is provided by

Sanity_check_train_mode implementation, in order not to wait till the end of sweeps with all the training and testing data, like with a *Real_train_mode* implementation, – second case for real training. Another implementation is a *Preliminary_eval_train_mode* class, which is inherited from the *Real_train_mode*. It provides a way of cutting off obviously bad solutions with training on partial amount of data and number of epochs. It's a means of preliminary evaluation before other sweeps with the *Real_train_mode*, and is used as a first phase of parameter search.

During that *first* bout of search, it was found out, that a simple U-Net model and a simple attention U-Net model, both written from scratch, works worse than an attention U-Net model, based on a pretrained ResNet50 backbone. Usage of ResNet152 as a backbone improves precision a bit, but at the same time drastically hinders performance in terms of calculation time.

During the *second* search iteration, it was determined that channel-wise attention is generally better for the task than spatial attention, as well as that 2D transposed convolution is a better choice for upsampling than a bilinear method.

The *third* iteration gave preliminary values for number of internal channels in attention blocks, batch size for decoder training, best optimizer and learning rate. While reaching a descent performance on majority of possible terrains, further analysis of badly predicted cases revealed that a chosen configuration struggles to cope with the case when the observer is situated in the forest near a border with open space, when they can already through the forest – Figure 9 (colors on a surface mask correspond to different surfaces: open space, forest, shrubs).

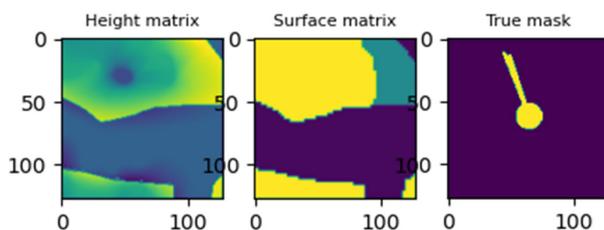


Figure 9. True mask while looking through the forest

Within the frame of research, in order to incentivize the network to understand that it deals with the forest, an auxiliary head with a fully connected layer was added. Its goal is to provide a binary classification: whether an observer is situated in the forest or not, with a contribution to the main binary cross entropy loss (*nn.BCELoss*), whereas Intersection

over Union (IoU) is the metric for parameter selection. Schematic representation of the resultant architecture (without attention gates and details) is presented on Figure 10.

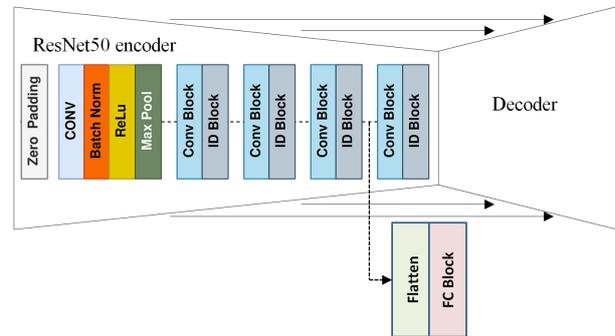


Figure 10. Auxiliary head for binary classification

As a result, such form of feature engineering wasn't successful. The situation when an observer can see through the forest towards open space is quite rare in the train dataset. So, as an aftermath of that, there is class imbalance. There are common solutions to cope with imbalanced datasets like usage of weighted random sampler [8], class weighting [9], synthetic minority oversampling technique (SMOTE) [10], or simple additional oversampling through augmentation of minority samples or some combinations. In our case additional data can be just generated from the simulator, with a stipulated rule, that we add a current case if both requirements are true: the observer is in the forest and there is an open space in the vicinity. After enriching the training dataset, the network started performing much better, which was evident even during preliminary evaluation.

The *forth* iteration of hyperparameter search involves usage of the real train mode with full datasets and number of epochs for every considered combination of hyperparameters. It eventually allowed picking a set best hyperparameters for decoder.

The *fifth* iteration involves unfreezing encoder and search of hyperparameters for fine-tuning. After that procedure, the network is evaluated on a test dataset, not a validation one used before, in order to check possible overfitting in hyperparameter search. It demonstrates an average IoU of 0.95 on a test set. Some examples of predicted masks (areas of visibility) are presented on Figure 11.

The network was trained on relatively low resolution of 128×128 in order to check the potential possibility of the approach, but in case of a higher resolution it will work the same way.

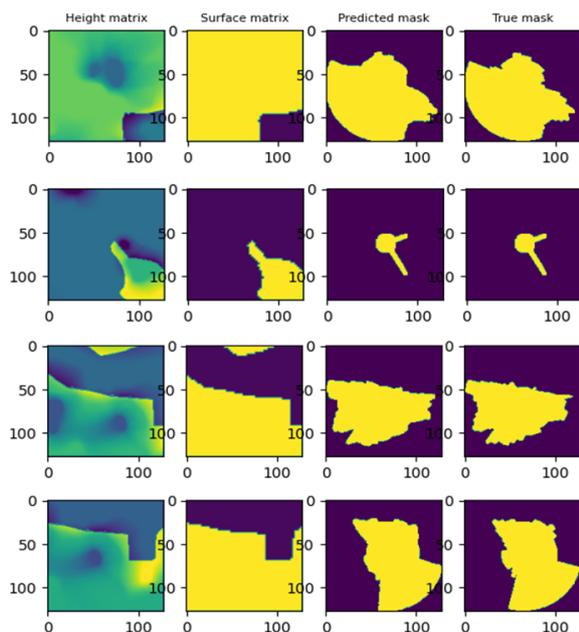


Figure 11. Examples of predictions

Conclusions

Current diversity of neural network architectures makes it possible to utilize them for solving different domain-specific tasks, including building an area of visibility, given data from a digital map. Usage of solutions for hyperparameter search allows evaluating a plethora of possible configurations. Ancillary architectural solutions provide a way for stitching building blocks together, assuring their conformation for performing search among their possible combinations within the architectural space. The final network in this work is based on combination of parts from different solutions, like the attention U-Net form the first source [6], different forms of attention from the second source [11] and finally – concrescence with a popular pretrained backbone in search of best performance. Such a strategy seems to be effective for solving real machine learning tasks for applied science.

REFERENCES

1. **Mathematical model complex for military grouping efficiency assessment:** [Electronic resource] // URL: <http://en.belfortex.com/page/show/9>. (Date of access: 15/11/2024).
2. **E. Rulko, et al.** Application of a simulation system for optimizing solutions based on elements of the theory of reflexive control. Collection of scientific articles of the Military academy of the Republic of Belarus. 2017. № 32. P. 153–162.
3. **Olaf Ronneberger, et al.** U-Net: Convolutional Networks for Biomedical Image Segmentation. 2015. arXiv: 1505.04597.
4. **Ozan Oktay et al.** Attention U-Net: Learning Where to Look for the Pancreas. 2018. arXiv: 1804.03999.
5. **Weights & Biases:** [Electronic resource] // URL: <https://wandb.ai/site>. (Date of access: 15/11/2024).
6. PyTorch implementation of U-Net, R2U-Net, attention U-Net, attention R2U-Net. https://github.com/LeeJunHyun/Image_Segmentation. 2018.
7. **E. Gamma, et al.** “Design Patterns Elements of Reusable Object-Oriented Software,” Addison-Wesley, Massachusetts, 1995.
8. **PyTorch documentation. Weighted random sampler:** [Electronic resource] // URL: <https://pytorch.org/docs/stable/data.html#torch.utils.data.WeightedRandomSampler>. (Date of access: 15/11/2024).
9. **How to Improve Class Imbalance using Class Weights in Machine Learning?:** [Electronic resource] // URL: <https://www.analyticsvidhya.com/blog/2020/10/improve-class-imbalance-class-weights/>. (Date of access: 15/11/2024).
10. **N. V. Chawla, et al.** SMOTE: Synthetic Minority Over-sampling Technique. 2011. arXiv: 1106.1813.
11. **Long Chen, et al.** SCA-CNN: Spatial and Channel-wise Attention in Convolutional Networks for Image Captioning. 2016. arXiv: 1611.05594.

РУЛЬКО Е.В.

**ИСПОЛЬЗОВАНИЕ U-Net СЕТИ С МЕХАНИЗМОМ ВНИМАНИЯ СОВМЕСТНО
С АРХИТЕКТУРНЫМИ НАДСТРОЙКАМИ ДЛЯ ФРЕЙМВОРКА PyTorch В РАМКАХ ПОИСКА
ГИПЕРПАРАМЕТРОВ ПОСРЕДСТВОМ БИБЛИОТЕКИ Weights & Biases
ДЛЯ ПРЕДСКАЗЫВАНИЯ ОБЛАСТИ ВИДИМОСТИ ПО КАРТЕ МЕСТНОСТИ**

*Военная академия Республики Беларусь
г. Минск, Республика Беларусь*

Аннотация. Текущий уровень развития глубокого обучения позволяет заменить нейронными сетями существующие специфические для моделирования военных действий алгоритмы. Поиск гиперпараметров даёт возможность определить структуры сетей, подходящие для решения соответствующих задач. Данная работа описывает процесс поиска структуры сети для предсказания зоны оптической видимости на основе фрагмента цифровой карты местности и предлагает архитектурные решения для комбинирования возможных составных частей сети, обеспечивая их совместимость в рамках поиска наилучшего решения. В качестве финального варианта предлагается использование U-Net архитектуры с поканальным механизмом внимания и энкодером на основе сети ResNet50.

Ключевые слова: глубокое обучение, U-Net, механизм внимания, сегментация, поиск гиперпараметров, W&B, шаблонный метод



Рулько Евгений Викторович, кандидат технических наук, доцент. Начальник научно-исследовательской лаборатории моделирования военных действий учреждения образования «Военная академия Республики Беларусь». Сфера научных интересов: глубокое обучение, машинное зрение, обучение с подкреплением, нейронауки, активный вывод, принцип свободной энергии, рефлексивное управление.

Eugene Rulko, PhD, associate professor in computer science. The head of the research laboratory of military operation simulation of the educational institution «Military academy of the Republic of Belarus». Research interests: deep learning, computer vision, reinforcement learning, neuroscience, active inference, free energy principle, reflexive control.

E-mail: eugeni1533@gmail.com

СОЛОНЕЦ А.В., СНАРСКИЙ А.С.

ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ПРОГНОЗИРОВАНИЯ РИСКА ТРАВМ У СПОРТСМЕНОВ: ПОДХОД С ИСПОЛЬЗОВАНИЕМ РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЕЙ

Белорусский национальный технический университет
г. Минск, Республика Беларусь

Аннотация. Целью работы является разработка и апробация модели прогнозирования риска травм у спортсменов, использующей методы машинного обучения для анализа временных рядов физиологических данных. В исследовании анализируются данные бегунов с квалификацией КМС, включая показатели частоты сердечных сокращений (ЧСС), вариабельности сердечного ритма (ВСР) и тренировочной нагрузки, что позволяет оценить состояние организма спортсмена в динамике и выявить возможные риски для здоровья. Разработанная модель прогнозирования, построенная на основе рекуррентной нейронной сети Long Short-Term Memory (LSTM), позволяет выявлять периоды повышенного риска травм у спортсменов и, основываясь на полученных результатах, корректировать тренировочный процесс для предотвращения этих рисков. В ходе экспериментов на реальных данных был достигнут высокий уровень точности прогноза – 85 %, что подтверждает эффективность предложенного подхода для предсказания вероятности травм. Несмотря на успешность модели, для обеспечения более точной валидации разработанного подхода авторы признают необходимость проведения дополнительных долгосрочных исследований с расширенным набором данных.

Ключевые слова: спортивные травмы, прогнозирование, машинное обучение, рекуррентные нейронные сети, искусственный интеллект, вариабельность сердечного ритма, частота сердечных сокращений, тренировочная нагрузка

Введение

Современный спорт предъявляет высокие требования к подготовке и мониторингу состояния спортсменов, поскольку даже кратковременные нарушения в восстановительных процессах могут привести к травмам. Полученная травма не только вызывает вынужденный перерыв в тренировках и «откат» в спортивной форме, но в ряде случаев может поставить крест на дальнейшей спортивной карьере. Особенно это касается профессиональных спортсменов, для которых период восстановления после травмы может совпасть с ключевыми этапами спортивного цикла: основные соревнования и непосредственная подготовка к ним или отбор в сборную команду.

В связи с этим профилактика травм и контроль текущего состояния спортсмена становятся приоритетными направлениями спортивной науки и медицины. На протяжении многих лет главными методами диагностики состояния спортсмена оставались медицинские осмотры, субъективные опросы и отдельные физиологические тесты. Однако они часто недостаточно чувствительны к изменению состояния организма, что затрудняет своевременное выявление признаков перенапряжения или первых симптомов перетренированности.

В последние годы с развитием цифровых технологий значительно расширились возможности ана-

лиза физиологических данных. Одним из перспективных направлений стало применение искусственного интеллекта (ИИ) и, в частности, методов машинного обучения (МО) в спортивной аналитике [1–3]. Эти методы позволяют работать с большими объемами данных в реальном времени, выявляя скрытые закономерности, недоступные для традиционных методов анализа. Важным практическим направлением применения ИИ и МО является разработка моделей прогнозирования риска травм на основе физиологических и других показателей спортсменов.

Проблема прогнозирования и предотвращения спортивных травм привлекает внимание многих исследователей, особенно в последние десятилетия, когда возрос интерес к использованию цифровых технологий и методов МО в спорте. По данным ряда исследований, основными факторами, повышающими риск травм у спортсменов, являются чрезмерная тренировочная нагрузка, недостаточное восстановление, а также отсутствие объективного контроля состояния организма [4; 5].

Традиционные методы оценки тренировочного процесса и состояния спортсмена основаны на субъективных отчетах и периодических медицинских обследованиях [6]. Однако субъективные показатели часто подвержены искажениям, а редкие обследования не позволяют в полной мере оценить динамические изменения физиологического

состояния спортсмена. В связи с этим в спортивной науке активно развивается использование объективных данных, таких как частота сердечных сокращений (ЧСС) и вариабельность сердечного ритма (ВСР), которые позволяют более точно оценивать уровень нагрузки и степень восстановления [7].

При этом ЧСС является одним из ключевых показателей состояния сердечно-сосудистой системы. Его повышение во время покоя или замедленное восстановление после физической нагрузки может свидетельствовать о накопленной усталости или начальных признаках перенапряжения [8]. ВСР, в свою очередь, широко используется для оценки состояния вегетативной нервной системы и степени восстановления организма. Снижение ВСР может указывать на дисбаланс между симпатической и парасимпатической активностью, что связано с повышенным риском травм и снижением работоспособности [9; 10].

Методы МО в последние годы стали активно применяться для анализа временных рядов физиологических данных с целью прогнозирования состояния спортсмена. Наиболее перспективными из них являются рекуррентные нейронные сети, а также их модификации, такие как Long Short-Term Memory (LSTM), которые позволяют учитывать временные зависимости и предсказывать будущие состояния на основе последовательных данных [11]. По данным исследований, модели на основе LSTM демонстрируют высокую точность в прогнозировании физиологических состояний и позволяют своевременно выявлять признаки перенапряжения [12].

В то же время большинство существующих моделей сосредоточены на одном виде спорта или ограниченном наборе физиологических параметров. Кроме того, многие исследования проводятся на относительно небольших выборках, что ограничивает возможность обобщения результатов и применения моделей в условиях реальной спортивной практики. В связи с этим актуальной задачей представляется разработка и тестирование модели, способной прогнозировать риск травм у спортсменов на основе объективных физиологических данных в условиях симулированного тренировочного процесса.

Таким образом, целью проводимых исследований является разработка и оценка модели прогнозирования риска травм у спортсменов (в рассматриваемом случае – бегунов) на основе временных рядов физиологических данных с использованием методов МО. Предполагается, что полученные результаты позволят не только выявить ключевые предикторы повышенного риска, но и сформировать основы для дальнейшего внедрения таких моделей в спортивную практику.

Основные задачи исследований:

1. Сбор и предварительная обработка данных о ЧСС, ВСР и тренировочной нагрузке.

2. Разработка и обучение модели на основе рекуррентной нейронной сети LSTM.

3. Оценка эффективности модели и анализ полученных результатов для выявления ключевых факторов риска травм у спортсменов (на примере бегунов).

Материалы и методы исследования

Объектом исследования выступали цифровые двойники двух бегунов, имеющих квалификацию КМС: спортсмен X – стайер (25 лет), соревновательная специализация – дистанции 10 000 м и 5 000 м; спортсмен В – спринтер (22 года), соревновательная специализация – дистанции 100 и 200 м. В качестве примера для разработки и тестирования модели были выбраны именно бегуны, поскольку их тренировочная нагрузка характеризуется циклическими ударными воздействиями на опорно-двигательный аппарат, что повышает риск травм нижних конечностей. При этом подготовка спринтеров отличается выраженной силовой направленностью по сравнению со стайерской, где, например, достаточно редко применяются большие и предельные отягощения. Основной особенностью модели является прогнозирование периода повышенного риска, что позволило бы корректировать тренировочную нагрузку и снижать вероятность травм.

Для построения цифровых двойников использованы данные физиологического мониторинга, биомеханического анализа и психофизиологического тестирования, которые собирались в течение 14 дней тренировочного процесса специально-подготовительного этапа подготовительного периода подготовки вышеуказанных спортсменов. Исследование проводилось с целью прогнозирования состояния спортсменов и определения риска травм на основе методов МО.

Для каждого спортсмена были собраны и проанализированы нижеприведенные группы данных.

1. Физиологические данные, которые включали показатели ЧСС, ВСР, уровень лактата в крови и тренировочную нагрузку. Измерения проводились с использованием пульсометров Garmin Forerunner 945 (для регистрации ЧСС и ВСР) и портативного анализатора лактата Lactate Scout 4. Тренировочная нагрузка учитывалась по параметрам интенсивности и объема каждой тренировки.

2. Биомеханические данные, которые оценивались по видео бегуна во время выполнения интервальных отрезков при помощи Kinovea (программное обеспечение для анализа спортивных движений).

3. Психофизиологические данные, включающие тестирование реакции на световые стимулы (оценка когнитивной функции) с использованием «НС-Психотест» (компьютерный комплекс для

проведения психофизиологических и психологических тестов с регистрацией вегетативных и эмоциональных реакций).

Для анализа временных рядов были выбраны ключевые физиологические параметры, регистрируемые ежедневно: ЧСС покоя и средняя ЧСС во время тренировки; ВСР; тренировочная нагрузка (интегральный показатель интенсивности и продолжительности). Помимо того, что ЧСС и ВСР – одни из наиболее информативных показателей состояния спортсмена, в дополнение они

легко собираются при помощи носимых устройств (пульсометров, кардиомониторов) и могут быть непрерывно зафиксированы на протяжении тренировочного процесса или при необходимости круглосуточно. Анализ временных рядов этих данных позволяет выявить динамические изменения в состоянии организма, которые могут предшествовать травмам, связанным с перенапряжением или недостаточным восстановлением. Примерные данные за одну тренировку для спортсменов приведены в таблице.

Таблица. Параметры тренировочной нагрузки и физиологического состояния спортсменов в рамках одной тренировки

Параметр	Спортсмен X (стайер)	Спортсмен В (спринтер)
Длительность тренировки («беговой» части)*	1 ч 20 мин	40 мин
Средняя ЧСС	165 уд./мин	175 уд./мин
Максимальная ЧСС	182 уд./мин	190 уд./мин
Уровень лактата	3,5 ммоль/л	6,0 ммоль/л
ВСР	45 мс	35 мс

* Примечание: тренировка у бегунов обычно состоит из разминки (выполняемой на месте и в движении), основной части (при этом зачастую в эту часть тренировки входят как общеразвивающие упражнения, так и специальные с различным отягощением или сопротивлением, особенно у спринтеров) и заключительной части тренировочного занятия.

Для построения модели прогнозирования риска травмы и мониторинга состояния спортсменов использовались методы МО. Основным инструментом анализа стал рекуррентный нейронный алгоритм LSTM, позволяющий эффективно обрабатывать временные ряды физиологических данных и выявлять скрытые закономерности. Входными параметрами были ЧСС, ВСР и тренировочная нагрузка, которые подавались на вход модели в виде временных последовательностей длиной 7 дней.

Для построения модели использовался язык программирования Python и библиотеки TensorFlow и Keras. Модель обучалась на собранных данных и тестировалась на новых последовательностях. Алгоритм включал следующие этапы.

1. Сбор и предварительная обработка данных. Данные нормализовались с использованием метода Min-Max Scaling в диапазон [0, 1]. Последовательности длиной 7 дней использовались в качестве входных данных модели.

2. Создание рекуррентной нейронной сети. Архитектура модели включала два слоя LSTM по 50 нейронов каждый и слой Dropout для предотвращения переобучения.

3. Обучение модели. Использовалась функция потерь binary_crossentropy, а в качестве оптимизатора применялся Adam. Ранняя остановка позволила

сохранить лучшие веса модели на основе минимального значения функции потерь на валидационных данных.

Результаты исследования

Кривая обучения модели (рисунок 1) показала, что функция потерь на обучающих и валидационных данных стабилизировалась после 20-й эпохи, что свидетельствует о хорошей сходимости модели. При этом точность возрастает по мере обучения и достигает уровня около 85 %, что указывает на успешное обучение модели. Таким образом, это подтверждает способность выбранной нами модели выявлять закономерности в последовательных данных и делать надежные прогнозы.

На рисунке 2 представлена динамика прогнозируемой вероятности риска травмы у бегунов на основании данных за последние 7 дней тренировок. Как видно из графика, вероятность постепенно возрастает от 15 % на первый день до 82 % на седьмой у стайера и 88 % у спринтера, что может свидетельствовать о накоплении усталости и потенциальной перегрузке спортсменов.

На рисунке 3 показаны изменения ЧСС у спортсменов X и В в течение 14-дневного тренировочного цикла.

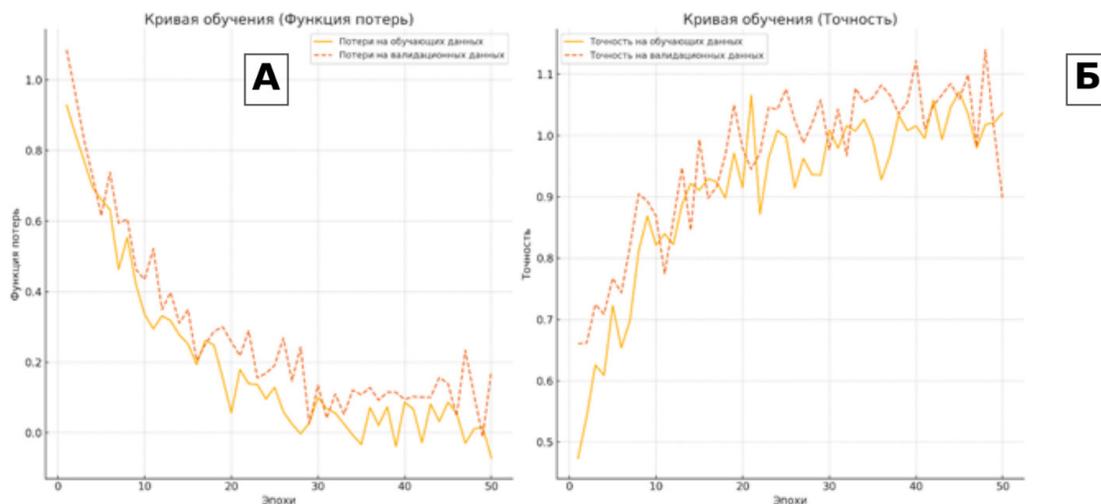


Рисунок 1. Кривые обучения модели.

А – Зависимость функции потерь от количества эпох, Б – Зависимость точности модели от количества эпох для обучающих и валидационных данных

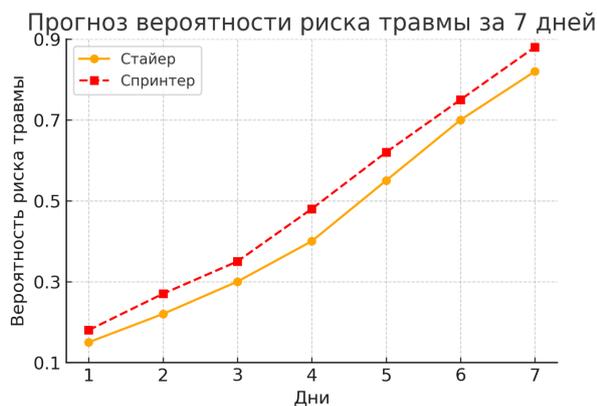


Рисунок 2. Динамика прогнозирования вероятности травмы

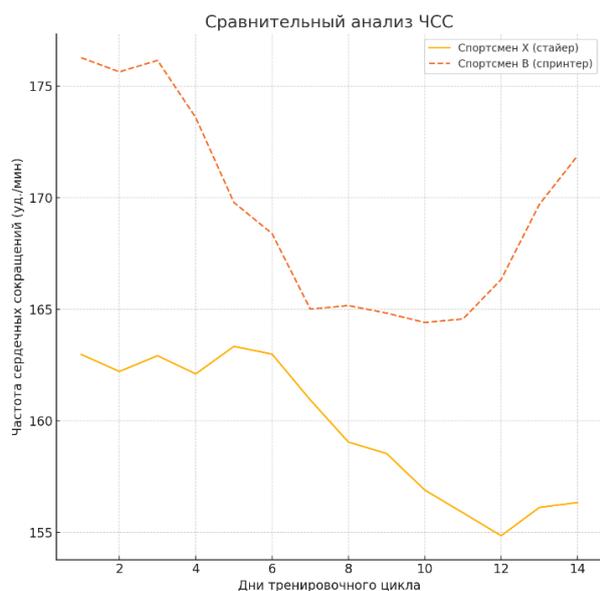


Рисунок 3. Сравнительный анализ ЧСС спортсменов

Анализ выявил следующие особенности:

- у спортсмена X ЧСС оставался относительно стабильным, что свидетельствует о хорошей адаптации к тренировочным нагрузкам;

- у спортсмена В ЧСС демонстрировал более выраженные колебания и в среднем был выше, что может быть связано с большей интенсивностью нагрузок и меньшим уровнем восстановления.

Заключение

Проведенное исследование продемонстрировало, что применение ИИ и методов МО, в частности рекуррентных нейронных сетей, позволяет выявлять периоды повышенного риска травм у спортсменов на основе анализа временных рядов физиологических данных (а именно: ЧСС и ВСР) и тренировочной нагрузки. Созданная модель продемонстрировала высокую эффективность, обеспечивая точность прогнозирования на уровне 85%. Это свидетельствует о значительном потенциале разработанного подхода для практического использования в спортивной аналитике и для мониторинга состояния спортсменов.

Однако, несмотря на обнадеживающие результаты, следует учитывать, что человеческий организм представляет собой сложную биологическую систему, реагирующую на внешние и внутренние стимулы множеством взаимосвязанных физиологических и психофизиологических процессов. Обилие таких взаимосвязей значительно усложняет задачу точного прогнозирования риска травм, особенно в условиях высокой изменчивости тренировочного процесса и индивидуальных особенностей каждого спортсмена. В связи с этим для окончательной валидации модели необходимы лонгитюдные исследования с участием спортсменов различных специализаций, в ходе ко-

торых будут регистрироваться как физиологические данные, так и фактические травмы. Это позволит провести ретроспективный анализ прогнозов модели и оценить ее способность предсказывать реальные события.

Таким образом, предложенная модель является важным шагом на пути к созданию цифровых ин-

струментов для персонализированного мониторинга состояния спортсменов и профилактики травм. Однако для обеспечения высокой надежности и клинической значимости требуется дальнейшая работа по расширению набора данных, улучшению алгоритмов и интеграции модели в практику спортивной медицины.

REFERENCES

1. **Rossi, A.** Effective injury forecasting in soccer with GPS training data and machine learning / A. Rossi, L. Pappalardo, P. Cintia, F.M. Iaia, J. Fernández, D. Medina // *PLoS ONE*. – 2018. – Vol. 13, Iss. 7. – P. 1–15. – DOI: 10.1371/journal.pone.0201264
2. **Carey, D.L.** Predictive modelling of training loads and injury in Australian football / D.L. Carey, K.L. Ong, R. Whiteley, K.M. Crossley, J. Crow, M.E. Morris // *International Journal of Computer Science in Sport*. – 2018. – Vol. 17, Iss. 1. – P. 1–18. – DOI: 10.2478/ijcss-2018-0002
3. **Eetvelde, H.V.** Machine learning methods in sport injury prediction and prevention: a systematic review / H.V. Eetvelde, L.D. Mendonça, C. Ley, R. Seil, T. Tischer // *Journal of Experimental Orthopaedics*. – 2021. – Vol. 8, Iss. 27. – P. 1–15. – DOI: 10.1186/s40634-021-00346-x
4. **Bahr, R.** Understanding injury mechanisms: A key component of preventing injuries in sport / R. Bahr, T. Krosshaug // *British Journal of Sports Medicine*. – 2005. – Vol. 39, Iss. 6. – P. 324–329. – DOI: 10.1136/bjsm.2005.018341
5. **Gabbett, T.J.** The training-injury prevention paradox: Should athletes be training smarter and harder? / T.J. Gabbett // *British Journal of Sports Medicine*. – 2016. – Vol. 50, Iss. 5. – P. 273–280. – DOI: 10.1136/bjsports-2015-095788
6. **Meeusen, R.** Prevention, diagnosis, and treatment of the overtraining syndrome: Joint consensus statement of the European College of Sport Science and the American College of Sports Medicine / R. Meeusen, M. Duclos, C. Foster, A. Fry, M. Gleeson, D. Nieman, J. Raglin, G. Rietjens, J. Steinacker, A. Urhausen // *European Journal of Sport Science*. – 2013. – Vol. 45, Iss. 1. – P. 186–205. – DOI: 10.1080/17461391.2012.730061
7. **Plews, D.J.** Heart rate variability in elite triathletes, is variation in variability the key to effective training? A case comparison / D.J. Plews, P.B. Laursen, A.E. Kilding, M. Buchheit // *European journal of applied physiology*. – 2012. – Vol. 112. – P. 3729–3741. – DOI: 10.1007/s00421-012-2354-4
8. **Achten, J.** Heart rate monitoring: Applications and limitations / J. Achten, A.E. Jeukendrup // *Sports Medicine*. – 2003. – Vol. 33. – C. 517–538. – DOI: 10.2165/00007256-200333070-00004
9. **Malik, M.** Heart rate variability: Standards of measurement, physiological interpretation, and clinical use / M. Malik, J.T. Bigger, A.J. Camm, R.E. Kleiger, A. Malliani, A.J. Moss, P.J. Schwartz // *European Heart Journal*. – 1996. – Vol. 17, Iss. 3. – P. 354–381. – DOI: 10.1093/oxfordjournals.eurheartj.a014868
10. **Kiviniemi, A.M.** Endurance training guided by daily heart rate variability measurements / A.M. Kiviniemi, A.J. Hautala, H. Kinnunen, M.P. Tulppo // *European Journal of Applied Physiology*. – 2007. – Vol. 101. – C. 743–751. – DOI: 10.1007/s00421-007-0552-2
11. **Hochreiter, S.** Long short-term memory / S. Hochreiter, J. Schmidhuber // *Neural Computation*. – 1997. – Vol. 9 (8). – P. 1735–1780. – DOI: 10.1162/neco.1997.9.8.1735
12. **Hou, J.** Application of recurrent neural network in predicting athletes' sports achievement / J. Hou, Z. Tian // *The Journal of Supercomputing*. – 2022. – Vol. 78. – P. 5507–5525. – DOI: 10.1007/s11227-021-04082-y

SOLONETS A.V., SNARSKY A.S.

APPLICATION OF ARTIFICIAL INTELLIGENCE FOR PREDICTING INJURY RISK IN ATHLETES: AN APPROACH USING RECURRENT NEURAL NETWORKS

Belarusian National Technical University
Minsk, Republic of Belarus

Abstract. The aim of this study is to develop and validate a model for predicting injury risk in athletes using machine learning methods to analyze time-series physiological data. The research focuses on data from runners with the high qualification, including heart rate (HR), heart rate variability (HRV), and training load, allowing for the assessment of an athlete's physiological state over time and the identification of potential health risks.

The proposed prediction model, based on a Long Short-Term Memory (LSTM) recurrent neural network, enables the identification of periods of increased injury risk in athletes and allows for adjustments to the training process to prevent injuries. Experimental results on real-world data demonstrated a high prediction accuracy of 85%, confirming the effectiveness of the proposed approach in forecasting injury probability. Despite the model's success, the authors recognize the need for further longitudinal studies with an expanded dataset to ensure a more precise validation of the proposed method.

Keywords: sports injuries, prediction, machine learning, recurrent neural networks, artificial intelligence, heart rate variability, heart rate, training load



Солонец Антон Владимирович, кандидат педагогических наук, доцент. Заведующий кафедрой «Спортивная инженерия» Белорусского национального технического университета. Проводит исследования в области применения искусственного интеллекта в спорте, включая анализ биомеханических данных с использованием машинного обучения, прогнозирование спортивных результатов и рисков травм на основе временных рядов физиологических показателей.

A.V. Solonets, PhD of Pedagogic Sciences, Associate Professor. Head of the Department of Sports Engineering at the Belarusian National Technical University. Conducts research in the application of artificial intelligence in sports, including the analysis of biomechanical data using machine learning, as well as the prediction of sports performance and injury risks based on time-series physiological data.

E-mail: solonets@bntu.by, botanic_@mail.ru



Снарский Андрей Станиславович, кандидат технических наук, доцент. Декан факультета промышленной и радиационной безопасности филиала БНТУ «Межотраслевой институт повышения квалификации и переподготовки кадров по менеджменту и развитию персонала». Проводит исследования по разработке инженерных решений для спортивной аналитики, а также по проблемам интеграции современных цифровых технологий в подготовку специалистов в области инженерии.

A.S. Snarsky, PhD in Engineering, Associate Professor. Dean of the Faculty of Industrial and Radiation Safety at the BNTU branch "Interindustry Institute for Advanced Training and Retraining of Personnel in Management and Personnel Development." Conducts research on the development of engineering solutions for sports analytics, as well as on the integration of modern digital technologies into the training of engineering specialists.

**УПРАВЛЕНИЕ
ТЕХНИЧЕСКИМИ
ОБЪЕКТАМИ**

**MANAGEMENT
OF TECHNICAL
OBJECTS**

ГУЛАЙ А.В., ЗАЙЦЕВ В.М.

ОПТИМИЗАЦИЯ ПРОЦЕССА ОБРАБОТКИ ЗАДАНИЙ В МУЛЬТИАГЕНТНОЙ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЕ

Белорусский национальный технический университет
г. Минск, Республика Беларусь

Аннотация. Функциональные компоненты мультиагентной интеллектуальной системы имеют различную физическую или логическую конструкцию и обеспечивают обработку потоков заданий с разной интенсивностью. С точки зрения эффективности выполнения поставленных задач, получения консолидированного результата и достижения общей цели агентами указанная система рассматривается как единый объект, целостное образование. При этом суммарная эффективность функционирования ее компонентов оценивается общим параметром, по которому она может сравниваться с другими вариантами архитектурного построения мультиагентных систем. В связи с этим предложено оценивать эффективность функционирования мультиагентной системы условным экстремумом — суммарным количеством заданий в очередях всех агентов системы при условии сохранения способности обеспечивать необходимый запас по коэффициенту загрузки каждого агента, ограничивающему зону его стабильного функционирования. Показано, что для оптимизации процесса обработки заданий может быть использован алгоритм случайного поиска, заключающийся в том, что случайным образом выбираются точки в пространстве возможных решений, оценивается их качество с помощью целевой функции и сохраняется лучшее из найденных решений. Рассматриваемая задача минимизации целевой функции — суммарного количества заданий в очередях всех агентов системы интерпретируется как выполнение приближенной нелинейной оптимизации с использованием метода множителей Лагранжа. В качестве примера реализации предлагаемого способа оптимизации процесса обработки заданий мультиагентной системы приведены результаты компьютерного эксперимента по определению минимального значения целевой функции. На основе указанного решения задачи оптимизации предложен технологический алгоритм функционирования распределителя заданий в мультиагентной интеллектуальной системе.

Ключевые слова: мультиагентная интеллектуальная система; распределение потока заданий; коэффициент загрузки агента; целевая функция оптимизации; метод множителей Лагранжа

Введение

В последние десятилетия в среде специалистов по разработке аппаратно-программных средств сложилась и получила развитие совокупность специальных научных терминов, представлений и положений об организации построения систем технического назначения на основе коллективного искусственного интеллекта. Указанная парадигма построения информационно-управляющих интеллектуальных систем базируется на применении мультиагентных технологий — рассмотрении данных систем как эргатических логико-технических конструкций с развитой пространственно-распределенной структурой [1–6]. В таких системах создаются условия для решения заданного множества системных задач путем концентрации усилий автономных функциональных агентов на основе единого замысла по достижению цели.

Мультиагентная интеллектуальная система включает в свой состав определенное количество как реальных, так и виртуальных функциональных агентов. В общем случае системные агенты — это сущности той или иной природы, целенаправленно действующие в определенной среде

функционирования интеллектуальной системы в соответствии с установленными правилами переработки вещества, энергии, информации и методами системной взаимосвязи. Каждый агент в системе имеет как общие, так и индивидуальные свойства, но все агенты ведут себя совместно для достижения общего системного результата. В инженерных системах агентами могут быть компьютеры, контроллеры, датчики, электронные приборы, производственное оборудование, а также компьютерные программы. Можно утверждать, что любая часть интеллектуальной технической системы, в принципе, может быть представлена и функционально оформлена как ее системный агент.

Особенность мультиагентной интеллектуальной системы заключается в том, что ей присущи такие свойства как ситуативность, гибкость и социализация. Ситуативность — это свойство системы воспринимать с помощью сенсоров текущие состояния окружения (среды, оборудования и персонала) и в соответствии с результатами анализа обстановки вырабатывать необходимые действия. Гибкость мультиагентной системы предполагает, что она не только

реагирует на текущие состояния и вариации окружения, но и заранее готовится к ним, прогнозирует возможные изменения, а также структурно и функционально адаптируется к ситуациям и выбирает рациональные альтернативы. Свойство социализации обеспечивает консолидацию усилий агентов системы для решения общих задач и достижения единой цели.

Для явного или латентного управления процессом функционирования мультиагентных интеллектуальных систем в их состав вводятся специальные объекты–лидеры. Агенты системы могут также обходиться без системного лидера, предназначенного для обеспечения их синхронизированного взаимодействия. В таком случае предусматривается наличие протоколов социализации, которые позволяют с помощью программных средств и сеансов обмена информацией в режиме реального времени синхронизировать процессы функционирования агентов и организовать адекватное использование системных ресурсов и данных.

Опубликованные в научно-технических источниках результаты большинства исследований различных аспектов создания мультиагентных интеллектуальных систем представляют собой, например, изложение общих проблем, стоящих перед системными аналитиками и инженерами-разработчиками в процессе проектирования указанных систем [7–10]. Некоторые научные публикации, напротив, ориентированы на изложение конкретных вопросов разработки и обеспечения процессов функционирования отдельных системных компонентов [11, 12]. В указанных публикациях обсуждаются, в частности, методы автоматического управления функциональными агентами, группирование агентов системы в определенные пространственные построения, сохранение порядка следования объектов в группах, назначение лидеров и распределение задач между агентами.

Однако процессы поддержки нормального функционирования мультиагентной системы нуждаются в решении ряда оптимизационных задач, обусловленных наличием системных компонентов с существенно различающимися характеристиками. Как правило, все функциональные агенты интеллектуальной системы имеют разные параметры и, соответственно, разную производительность процесса выполнения заданий. При распределении заданий между агентами без учета данного обстоятельства их загруженность оказывается неоптимальной, что приводит к снижению эффективности функционирования многоагентной системы в целом. В частности, оптимизация распределения заданий на обработку между агентами позволяет существенно уменьшить их суммарное количество в очередях у всех агентов системы.

С учетом вышеизложенного задачей настоящей работы является выбор и обоснование параме-

тра мультиагентной системы, который характеризует процесс ее функционирования, а также разработка способа оптимизации указанного процесса. В работе определены значения коэффициентов распределения общего потока заданий между агентами интеллектуальной системы, при которых минимизируется целевая функция – суммарное количество заданий в очередях всех агентов. В качестве условия оптимизации принята способность обеспечения необходимого запаса по коэффициенту загрузки, который ограничивает зону стабильного функционирования каждого агента. Предложен алгоритм функционирования распределителя потоков заданий в направлении агентов системы, заключающийся в случайном выборе точки в пространстве возможных решений и оценке их качества с помощью целевой функции.

Постановка задачи оптимизации процесса обработки заданий агентами

Виртуальный агент как модель мультиагентной интеллектуальной системы. С точки зрения выполнения поставленных задач, получения консолидированного результата и достижения общей цели мультиагентная система может рассматриваться как единый объект, целостное образование. При этом суммарная эффективность функционирования ее компонентов оценивается общим параметром, по которому она может сравниваться с другими вариантами мультиагентных систем и результатами их действий. В связи с этим появляется необходимость в выделении одного интегративного параметра, которым можно характеризовать работу системы в целом, с учетом неодинаковых параметров отдельных агентов, разной эффективности их действий. Фактически мультиагентная система (целостный набор, совокупность отдельных агентов) представляется в виде единого виртуального агента, который обладает интегральной характеристикой, учитывающей определенные параметры всех агентов, входящих в систему. Особенность предлагаемого подхода к оценке мультиагентных систем заключается также в том, что по данному параметру можно не только оценивать эффективность действий системы, но и проводить оптимизацию процесса ее функционирования.

Допустим, что система включает в свой состав группу из n агентов, которые ориентированы на обработку определенного типа заданий с одинаковой производительностью μ заданий в единицу времени. В этом случае независимо от физического и логического построения отдельных агентов при проведении системного анализа мультиагентную систему правомерно заменить одним эквивалентным виртуальным объектом (агентом) с производительностью $\mu_{\text{экв}} = n\mu$ заданий в единицу времени t . Случайный поток актов обработки заданий виртуальным агентом (как эквивалентом мультиагентной системы)

может быть представлен экспоненциальной моделью с функцией распределения $f(t) = 1 - \exp(-\mu t)$.

Задача оценки и оптимизации процесса распределения потока заданий значительно усложняется в практическом случае, когда все агенты системы имеют разную производительность. Создается ситуация, когда агенту с относительно низкой производительностью направляется поток заданий, значительно превышающий возможности агента по обработке данного потока. Накопление заданий в очереди на обработку такими агентами приводит к увеличению суммарного количества заданий в очередях всей системы и, соответственно, к снижению эффективности функционирования многоагентной системы.

Выбор параметра, по которому производится оптимизация функционирования мультиагентной интеллектуальной системы, базируется на следующих подходах. Анализ особенностей архитектурного, функционального и алгоритмического построения многоагентных интеллектуальных систем показывает, что они могут интерпретироваться как гетерогенные системы массового обслуживания [2, 3, 13]. При таком подходе к анализу указанных систем весьма продуктивным может быть рассмотрение характерной для них зависимости процесса обработки заданий не только от общего коэффициента загрузки системы, но и от распределения общего потока заданий между отдельными агентами. Эффективность указанного разделения общего потока заданий на части будет определяться индивидуальными свойствами агентов, к которым направляются соответствующие фрагменты потока.

С учетом этого целесообразно оценивать эффективность функционирования мультиагентной системы условным экстремумом – минимальным суммарным количеством заданий в очередях всех агентов системы при сохранении способности обеспечивать необходимый запас по коэффициенту загрузки каждого агента, ограничивающему зону стабильного его функционирования. Возникающая задача может быть интерпретирована следующим образом: необходимо определить значения коэффициентов, характеризующих процесс разделения общего потока заданий в мультиагентной системе на отдельные потоки в направлении каждого агента, при которых минимизируется целевая функция – суммарное количество заданий в очередях всех агентов системы. Коэффициент загрузки агентов задается экспертами в диапазоне 0,2–0,3 в процессе построения интеллектуальной системы.

Распределение потока заданий в мультиагентной интеллектуальной системе. Обобщенная схема распределения потока заданий в мультиагентной интеллектуальной системе представлена на рис. 1. Исходный поток однотипных заданий формируется объектом управления мультиагентной системы и поступает извне и распределяется между реальными

и виртуальными агентами системы для последующей обработки. Поток заданий – пуассоновский с интенсивностью Λ :

$$\Lambda = \sum_{i=1}^n \lambda_i, \quad \lambda_i = \alpha_i \Lambda,$$

где $i = 1, 2, \dots, n$; λ_i – интенсивность потока заданий в направлении агента i ; α_i – коэффициент распределения общего потока Λ заданий между агентами.



Рис. 1. Общая схема распределения потока заданий в мультиагентной интеллектуальной системе

Интегральная оценка эффективности функционирования мультиагентной системы. Системные агенты могут иметь различную физическую или логическую конструкцию, они обрабатывают задания и обеспечивают потоки обработки с интенсивностью μ_i . Распределение времени обработки заданий в i -тых агентах – экспоненциальное, процесс обработки характеризуется следующими параметрами:

- среднее время обработки задания i -тым агентом:

$$T_i = \mu_i^{-1};$$

- второй начальный момент времени обработки задания i -тым агентом:

$$T_i = \mu_i^{-1};$$

- среднее время ожидания заданием начала обработки в очереди i -того агента:

$$\omega_i = 0,5\alpha_i\Lambda T_i^{(2)} / (1 - \alpha_i\Lambda T_i);$$

- средняя длина очереди ожидания заданиями начала обработки i -тым агентом:

$$\Omega_i = \lambda_i \omega_i = 0,5\alpha_i^2 \Lambda^2 T_i^{(2)} / (1 - \alpha_i\Lambda T_i).$$

Эффективность функционирования мультиагентной системы целесообразно оценивать условным экстремумом – суммарным количеством заданий Ω в очередях всех агентов системы и способностью обеспечивать необходимый запас по коэффициенту загрузки каждого агента Δp , ограничивающему зону

его стабильного функционирования. Указанный коэффициент зависит от особенностей функционирования агента, его эксплуатационных характеристик, а также от внешних условий и окружающей среды. Он задается экспертным путем на стадии проектирования мультиагентной системы, при этом для системы в целом наиболее рациональным является выбор ненормирующего значения:

$$\Delta\rho = \min\{\Delta\rho_i\}.$$

Требуется определить значения коэффициентов разделения общего потока Λ на отдельные потоки в направлении каждого агента $\{\alpha_i\}$, при которых минимизируется целевая функция – суммарное количество заданий в очередях всех агентов системы:

$$\Omega = \sum_{i=1}^n \Omega_i \rightarrow \min.$$

Ограничения в решении задачи оптимизации процесса обработки заданий. При решении задачи определения целевой функции оптимизации соблюдаются следующие ограничения:

$$A = \{\alpha_i \geq 0\} \sum_{i=1}^n \alpha_i = 1.$$

Ограничение, касающееся суммы α_i , является приближенным и применяется для упрощения выполнения аналитических выводов.

Поскольку на рассматриваемые переменные налагаются дополнительные условия, которые ограничивают область допустимых значений при поиске экстремума целевой функции оптимизации, в работе используется понятие «условный экстремум».

Способ оптимизации процесса обработки заданий системными агентами

Для оптимизации процесса обработки заданий может быть использован алгоритм случайного поиска, основанный на случайной генерации возможных решений внутри заданного пространства поиска и последующей их оценке. Данный алгоритм относится к стохастическим методам, поскольку в своей основе использует случайные величины для построения стратегии поиска. Пространство поиска представляет собой множество всех допустимых комбинаций параметров задачи оптимизации. Указанная задача состоит в поиске такого значения параметра, которое минимизирует целевую функцию, выступающую в роли критерия оценки каждого из возможных решений. Таким образом, принцип работы алгоритма оптимизации заключается в том, что случайным образом выбираются точки в пространстве возможных решений, оценивается их качество с помощью целевой функции и сохраняется лучшее из найденных решений.

Рассматриваемая задача минимизации целевой функции – суммарного количества заданий в очередях всех агентов системы может быть интерпретирована как выполнение нелинейной оптимизации с ограничениями в виде определенных равенств и неравенств. В данном случае применим метод множителей Лагранжа [14].

Для решения задачи оптимизации рассматриваемого процесса задается функция Лагранжа, которая для случая обработки заданий в мультиагентной интеллектуальной системе имеет следующий вид:

$$\begin{aligned} L(\alpha_1, \alpha_2, \dots, \alpha_n, \beta_0, \beta_1, \gamma_1, \dots, \gamma_{n-1}, \gamma_n, \delta_1, \delta_2, \dots, \delta_n) = \\ = \beta_0 \sum_{i=1}^n 0,5\alpha_i^2 \Lambda^2 T_i^{(2)} [1 - \alpha_i \Lambda T_i]^{-1} + \\ + \beta_1 \left(\sum_{i=1}^n \alpha_i - 1 \right) + \sum_{i=1}^n \gamma_i \{ \alpha_i - (1 - \Delta\rho) \Lambda^{-1} T_i^{-1} \} - \\ - \delta_1 \alpha_1 - \delta_2 \alpha_2 - \dots - \delta_n \alpha_n, \end{aligned}$$

где $\beta_0, \beta_1, \gamma_1, \dots, \gamma_{n-1}, \gamma_n, \delta_1, \delta_2, \dots, \delta_n$ – неопределенные множители Лагранжа.

Далее выстраивается совокупность уравнений относительно множителей Лагранжа из частных производных целевой функции по переменным $\alpha_1, \alpha_2, \dots, \alpha_n$, которые приравниваются к нулю (условия стационарности):

$$\begin{aligned} \{ \partial L / \partial \pm \alpha_i = \{ \beta_0 \{ \alpha_i \Lambda T_i^{(2)} [1 - \alpha_i \Lambda T_i] + \\ + \Lambda T_i 0,5\alpha_i^2 \Lambda^2 T_i^{(2)} \} [1 - \alpha_i \Lambda T_i]^{-2} + \beta_i + \gamma_i - \delta_i = 0 \}. \end{aligned}$$

К этой совокупности присоединяются уравнения дополняющей нежесткости и согласования знаков:

$$\begin{aligned} \beta_1 \left(\sum_{i=1}^n \alpha_i - 1 \right) = 0; \\ \sum_{i=1}^n \gamma_i \{ \alpha_i - (1 - \Delta\rho) \Lambda^{-1} T_i^{-1} \} = 0; \\ \delta_1 \alpha_1 + \delta_2 \alpha_2 + \dots + \delta_n \alpha_n = 0. \end{aligned}$$

Решение системы уравнений относительно множителей Лагранжа находим при следующих условиях:

$$\beta_1 \neq 0, \text{ так как приближенно принимается } \sum_{i=1}^n \alpha_i = 1.$$

Таким образом, получаем субоптимальную точку в пространстве коэффициентов α_i :

$$\{ \alpha_i = (1 - \Delta\rho) \Lambda^{-1} T_i^{-1} \}.$$

Строгое решение рассматриваемой системы уравнений приводит к отклонению точки оптимума от точки субоптимума, при котором

$$\sum_{i=1}^n \alpha_i = (1 - \Delta\rho) \Lambda^{-1} \sum_{i=1}^n \mu_i \neq 1.$$

Однако это отклонение практически не влияет на процессы управления потоками заданий в мультиагентной системе.

Если точка $A = \{\alpha_i \geq 0\}$ является решением исходной задачи, то найдется такой вектор $\beta_0, \beta_1, \gamma_1, \dots, \gamma_{n-1}, \gamma_n, \delta_1, \delta_2, \dots, \delta_n$, который удовлетворяет системе уравнений. Значит, все экстремальные точки задачи находятся среди решений системы, у которых не все компоненты указанного вектора не равны нулю.

Приближенное определение координат точки экстремума выполняется следующим образом. Пусть A – координаты точки экстремума, а $f(A)$ – соответствующее значение целевой функции. Берется точка A_1 , близкая к точке A , и вычисляется значение целевой функции $f(A_1)$. Если $f(A) \geq f(A_1)$, то в точке A наблюдается максимум указанной функции; если $f(A) \leq f(A_1)$, то в точке A данная функция имеет минимум.

В качестве примера реализации предлагаемого способа оптимизации процесса обработки заданий мультиагентной системы приведем результаты компьютерного эксперимента по определению минимального значения суммарного количества заданий в очередях всех агентов. Рассматриваемая мультиагентная система состоит из объекта управления и трех агентов, для которых характерны разные значения времени обработки заданий T_i . Для

данной системы при разной величине коэффициентов распределения общего потока заданий между агентами α_i рассчитываются значения средней производительности агентов μ_i , суммарная производительность системы $\Sigma \mu_i$, вторые центральные моменты $T_i^{(2)}$. Кроме этого, устанавливается необходимый запас по коэффициенту загрузки каждого агента, ограничивающему зону его стабильного функционирования $\Delta\rho$, а также определяется предельный поток задания Λ и целевая функция оптимизации Ω .

В таблице 1 представлены основные результаты вычислений, из анализа которых следует, что при неизменной величине суммарного потока заданий явно выделяется минимум средних суммарных очередей агентов системы в случае $\alpha_1 = 0,53$; $\alpha_2 = 0,26$; $\alpha_3 = 0,21$. В ряду полученных значений функции оптимизации при разных величинах коэффициентов распределения потоков минимальное значение Ω составляет 4,79. Таким образом, величины α_i , соответствующие минимальному значению функции Ω , можно считать оптимальными для рассматриваемой в качестве примера мультиагентной системы. Следует отметить, что в расчетах и при выполнении анализа принято экспертное значение ненаритарного системного запаса по коэффициенту загрузки агентов на уровне 0,3.

Таблица 1. Результаты определения целевой функции оптимизации

Коэффициент распределения			Время обработки			Ограничение загрузки	Поток заданий	Функция оптимизации
α_1	α_2	α_3	T_1	T_2	T_3	$\Delta\rho$	Λ	Ω
0,70	0,30	0	0,2	0,4	0,5	0,3	6,65	15,54
0,45	0,30	0,25						8,10
0,53	0,26	0,21						4,79
0,51	0,34	0,15						12,10
0,45	0,27	0,28						15,08

Технологический алгоритм функционирования распределителя заданий в мультиагентной интеллектуальной системе реализуется следующим образом. Данный алгоритм предполагает предварительную разметку таблицы распределения $\{\alpha_j\}$ и

размещение элементов α_j в порядке возрастания (таблица 2; множество значений коэффициента распределения α_j принадлежит множеству α_j):

$$\{0 \leq \alpha_j \leq \alpha_j + 1 \leq 1, 0\}, \quad j = 1, 2, \dots, n-1.$$

Таблица 2. Коэффициенты распределения заданий между агентами

Номер интервала	1	2	3	...	n
Интервальное значение	$(0; \alpha_1)$	$(\alpha_1; \alpha_1 + \alpha_2)$	$(\alpha_1 + \alpha_2; \alpha_1 + \alpha_2 + \alpha_3)$...	$(\sum_{j=1}^{n-1} \alpha_j; 1, 0)$

В процессе функционирования мультиагентной системы проводится выработка случайного числа ξ_k датчиком случайных чисел с равномерным распределением в интервале (0; 1) и определяется номер интервала принадлежности m [15]:

$$\xi_k \in \left(\sum_{j=1}^m \alpha_j, \sum_{j=1}^{m+1} \alpha_j \right).$$

В компьютерном эксперименте значения α_i в порядке возрастания располагаются следующим образом: $\alpha_3, \alpha_2, \alpha_1$, а интервальные значения приобретают вид (0; 0,21) (0,21; 0,47) (0,47; 1,0). Генерируется ряд случайных чисел ξ_k , например: 0,81; 0,04; 0,75; 0,20; 0,80; 0,27; 0,14; 0,69; 0,35; 0,70; 0,98; 0,15; 0,71; 0,23; 0,45; 0,24; 0,61; 0,77; 0,91; 0,29. При таких условиях потоки заданий в направлении агентов с коэффициентами распределения $\alpha_3, \alpha_2, \alpha_1$ будут содержать следующее количество заданий: 4; 7; 9. При указанном распределении потоков заданий между агентами достигается решение задачи минимизации целевой функции – суммарного количества заданий в очередях всех агентов системы.

Заключение

Выполнено обоснование выбора параметра мультиагентной системы, который характеризует эффективность процесса ее функционирования, а также разработан способ оптимизации указанного процесса. Определены значения коэффициентов распределения общего потока заданий между агентами интеллектуальной системы, при которых минимизируется целевая функция – суммарное количество заданий в очередях всех агентов. В качестве условия оптимизации принята способность обеспечения необходимого запаса по коэффициенту загрузки, который ограничивает зону стабильного функционирования каждого агента. Предложен алгоритм функционирования распределителя потоков заданий в направлении агентов системы, заключающийся в случайном выборе точки в пространстве возможных решений и оценке качества решений с помощью целевой функции.

ЛИТЕРАТУРА

1. **Городецкий, В. И.** Многоагентные системы (обзор) / В. И. Городецкий, М. С. Грушинский, А. В. Хабалов // *Новости искусственного интеллекта*. 1998. – № 2. – С. 64–116.
2. **Карпов, В. Э.** Модели социального поведения в групповой робототехнике / В. Э. Карпов // *Управление большими системами*. – 2016. – Вып. 59. – С. 165–232.
3. **Гулай, А. В.** Архитектура интеллектуальных систем / А. В. Гулай, В. М. Зайцев. – Минск : ИВЦ Минфина, 2018. – 367 с.
4. **Гулай, А. В.** Интеллектуальные мехатронные системы с дистанционной организацией транзакций: особенности построения / А. В. Гулай, В. М. Зайцев // *Доклады БГУИР*. – 2015. – № 7(93). – С. 92–98.
5. **Гулай, А. В.** Интеллектуальные мехатронные системы с дистанционным взаимодействием компонентов: структура и функции / А. В. Гулай, В. М. Зайцев // *Наука и техника*. – 2015. – № 4. – С. 12–18.
6. **Гулай, А. В.** Конвергенция интеллектуальных систем / А. В. Гулай, В. М. Зайцев. – Минск : ИВЦ Минфина, 2020. – 384 с.
7. **Тарасов, В. Б.** От многоагентных систем к интеллектуальным организациям: философия, психология, информатика / В. Б. Тарасов. – М. : Эдиториал УРСС, 2002. – 348 с.
8. **Guessoum, Z.** Towards reliable multi-agent system: An adaptive replication mechanism / Z. Guessoum, J.-P. Briot, N. Faci, O. Martin // *Multiagent and Grid Systems*. – 2010. – Vol. 6, Iss. 1 – P. 1–24. – DOI: 10.3233/MGS-2010-0139.
9. **Hübner, J. F.** A normative programming language for multi-agent organizations / J. F. Hübner, O. Boissier, R. H. Bordini // *Annals of Mathematics and Artificial Intelligence*. – Vol. 62. – P. 27–53. – DOI: 10.1007/s10472-011-9251-0
10. **Boissier, O.** Dimensions in programming multi-agent systems / O. Boissier, R. H. Bordini, J. F. Hübner, A. Ricci // *The Knowledge Engineering Review*. – 2019. – Vol. 34, № 2. – P. 1–28. – DOI: 10.1017/S026988891800005X
11. **Ерофеева, В. А.** Управление роем динамических объектов на базе мультиагентного подхода / В. А. Ерофеева, Ю. В. Иванский, В. И. Княев // *Компьютерные инструменты в образовании*. – 2015. – № 6. – С. 34–42.
12. **Воробьев, В. В.** Алгоритмы выбора лидера и кластеризации в статическом рое роботов / В. В. Воробьев // *Мехатроника, автоматизация, управление*. – 2017. – Т. 18, № 3. – С. 166–173. – DOI: 10.17587/mau.18.166-173
13. **Бронштейн, О. И.** Модели приоритетного обслуживания в информационно-вычислительных системах / О. И. Бронштейн, И. М. Духовный. – М. : Наука, 1976. – 220 с.
14. **Реклейтис, Г.** Оптимизация в технике: в 2 кн. / Г. Реклейтис, А. Рейвиндран, К. Рэгсдел. – М. : Мир, 1986. – 2 кн.
15. **Поляк, Ю. Г.** Вероятностное моделирование на электронных вычислительных машинах / Ю. Г. Поляк. – М.: Советское радио, 1971. – 400 с.

REFERENCES

1. **Gorodetsky, V. I.** Multi-agent systems (review) / V. I. Gorodetsky, M. S. Grushinsky, A. V. Khabalov // *Novosti iscusstvennogo intellecta*. – 1998. – № 2. – P. 64–116.
2. **Karpov, V. E.** (2016) Models of social behavior in group robotics / V. E. Karpov // *Large-Scale Systems Control*. – 2016. – № 59. – P. 165–232.

3. Gulay, A. V. Architecture of intelligent systems / A. V. Gulay, V. M. Zaitsev. – Minsk : IVC Minfina, 2018. – 367 p.
4. Gulay, A. V. Intelligent mechatronic systems with remote organization of transactions: design features / A. V. Gulay, V. M. Zaitsev // Doklady BGUIR. – 2015. – № 7(93). – P. 92–98.
5. Gulay, A. V. Intelligent mechatronic systems with remote component interaction: structure and functions / A. V. Gulay, V. M. Zaitsev // Science & Technique. – 2015. – № 4. – P. 12–18.
6. Gulay, A. V. Convergence of intelligent systems / A. V. Gulay, V. M. Zaitsev. – Minsk : IVC Minfina, 2020. – 384 p.
7. Tarasov, V. B. From multi-agent systems to intellectual organizations / V. B. Tarasov. – M. : Editorial URSS, 2002. – 348 p.
8. Guessoum, Z. Towards reliable multi-agent system: An adaptive replication mechanism / Z. Guessoum, J.-P. Briot, N. Faci, O. Martin // Multiagent and Grid Systems. – 2010. – Vol. 6, Iss. 1 – P. 1–24. – DOI: 10.3233/MGS-2010-0139
9. Hübner, J. F. A normative programming language for multi-agent organizations / J. F. Hübner, O. Boissier, R. H. Bordini // Annals of Mathematics and Artificial Intelligence. – Vol. 62. – P. 27–53. – DOI: 10.1007/s10472-011-9251-0
10. Boissier, O. Dimensions in programming multi-agent systems / O. Boissier, R. H. Bordini, J. F. Hübner, A. Ricci // The Knowledge Engineering Review. – 2019. – Vol. 34, № 2. – P. 1–28. – DOI: 10.1017/S026988891800005X
11. Erofeeva, V. A. Swarm control of dynamic objects based on multi-agent technologies / V. A. Erofeeva, U. V. Ivanskiy, V. I. Kiyayev // Computer Tools in Education journal. – 2015. – № 6. – P. 34–42.
12. Vorobyev, V. V. Leader selection and clusterization algorithms in a static robot swarm // Mekhatronika, Avtomatizatsiya, Upravlenie. – 2017. – Vol. 18, № 3. – P. 166–173. – DOI: 10.17587/mau.18.166-173
13. Bronshtejn, O. I. Priority service models in information and computing systems / O. I. Bronshtejn, I. M. Duhovnyj. – M. : Nauka, 1976. – 220 p.
14. Reklejtis, G. Optimization in engineering : in 2 vol. / G. Reklejtis, A. Rejvindran, K. Rejksdel. – M. : Mir, 1986. – 2 vol.
15. Pollyak, Yu. G. Probabilistic modeling on electronic computers / Yu. G. Pollyak. – M. : Sovetskoe radio, 1971. – 400 p.

GULAJ A.V., ZAJCEV V.M.

OPTIMIZATION OF TASK PROCESSING IN A MULTI-AGENT INTELLIGENT SYSTEM

*Belarusian National Technical University
Minsk, Republic of Belarus*

Abstract. *The functional components of a multi-agent intelligent system have different physical or logical structures and provide processing of task flows with different intensities. From the point of view of the effectiveness of the tasks set, obtaining a consolidated result and achieving a common goal by the agents, this system is considered as a single object, an integrated entity. At the same time, the overall efficiency of its components is assessed by a common parameter by which it can be compared with other architectural variants of multi-agent systems. In this regard, it is proposed to evaluate the effectiveness of the multi-agent system by a conditional extremum – the total number of tasks in the queues of all agents of the system, provided that the ability to provide the necessary margin for the load factor of each agent limits the zone of its stable functioning. It is shown that a random search algorithm can be used to optimize the task processing process, which consists in randomly selecting points in the space of possible solutions, evaluating their quality using an objective function, and preserving the best of the solutions found. The considered task of minimizing the objective function – the total number of tasks in the queues of all agents of the system is interpreted as performing approximate nonlinear optimization using the Lagrange multiplier method. As an example of the implementation of the proposed method for optimizing the task processing process of a multi-agent system, the results of a computer experiment to determine the minimum value of the objective function are given. Based on the specified solution to the optimization problem, a technological algorithm for the functioning of a task distributor in a multi-agent intelligent system is proposed.*

Keywords: *multi-agent intelligent system; task flow distribution; agent load factor; objective function of optimization; Lagrange multipliers method*



Гулай Анатолий Владимирович, Белорусский национальный технический университет, Минск, Республика Беларусь. Кандидат технических наук, заведующий кафедрой «Интеллектуальные и мехатронные системы». Окончил Минский радиотехнический институт (1971), защитил диссертацию на соискание ученой степени кандидата технических наук (1982), лауреат Государственной премии в области науки и техники. Область научных интересов: методологические проблемы интеллектуальных технологий; интеллектуальные системы формирования знаний; построение интеллектуальных технических систем.

A.V. Gulaj, Belarusian National Technical University, Minsk, Republic of Belarus. PhD in Engineering, Head of the Department of Intelligent and Mechatronic Systems. Graduated from the Minsk Radio Engineering Institute (1971), defended his dissertation for the degree of candidate of technical sciences (1982), laureate of the State Prize in the field of science and technology. Research interests: methodological problems of intellectual technologies; intelligent education systems; construction of intellectual technical systems.

E-mail: is@bntu.by



Зайцев Владимир Михайлович, Белорусский национальный технический университет, Минск, Республика Беларусь. Кандидат технических наук, доцент кафедры «Интеллектуальные и мехатронные системы». Окончил Минский радиотехнический институт (1971), защитил диссертацию на соискание ученой степени кандидата технических наук (1974). Область научных интересов: цифровая обработка сигналов; проектирование интеллектуальных систем технического назначения.

V.M. Zajcev, Belarusian National Technical University, Minsk, Republic of Belarus. PhD in Engineering, Associate Professor of the Department of Intelligent and Mechatronic Systems. Graduated from the Minsk Radio Engineering Institute (1971), defended his dissertation for the degree of candidate of technical sciences (1974). Research interests: digital signal processing; design of intellectual systems for technical purposes.

E-mail: is@bntu.by

СИДОРЕНКО А.В., СОЛОДУХО Н.А.

АЛГОРИТМ ОГИБАНИЯ ПРЕПЯТСТВИЙ ПРИ ПЕРЕМЕЩЕНИИ МОБИЛЬНОГО РОБОТА С ИСПОЛЬЗОВАНИЕМ Q-ОБУЧЕНИЯ И ТЕХНОЛОГИИ БЛОКЧЕЙН

Белорусский государственный университет
г. Минск, Республика Беларусь

Аннотация. Предложен алгоритм моделирования движения робота с огибанием препятствий при использовании метода машинного Q-обучения. Применение Q-обучения позволяет сохранять полученные при моделировании вознаграждения, выполняя оптимальные действия в каждом конкретном состоянии, при этом в Q-таблице содержится информация о состоянии и действии робота. Сохранение Q-таблицы в блокчейне с использованием технологии IPFS (InterPlanetary File System) позволяет надежно и децентрализованно хранить данные о состояниях и действиях робота. Контент адресации в IPFS отделяет данные от их местоположения и извлекает файлы из нескольких источников в пириновом режиме. Для предложенного алгоритма проведен вычислительный эксперимент с применением среды моделирования движения робота. В пакете визуализации Gazebo 11 показано, что с использованием нового алгоритма препятствия огибаются быстрее (на 59,8 %), чем при использовании предыдущей версии алгоритма.

Ключевые слова: робот, блокчейн, IPFS, Q-обучение, перемещение, препятствия, ROS 2, Gazebo 11

Введение

Интенсивное развитие информационных методов искусственного интеллекта, технологии блокчейн, а также использование для обеспечения связи с наземными объектами структур InterPlanetary File System (IPFS) выдвигают новые задачи в области моделирования и разработки алгоритмов огибания препятствий при перемещении роботизированных систем.

В представленных нами работах [1, 2] были предложены алгоритмы огибания препятствий при перемещении робота, в которых решение задачи проводилось следующим образом:

1) когда робот встречает препятствие, он начинает огибать его, двигаясь вдоль препятствия, постоянно держась одной и той же стороной к препятствию (алгоритм I, он же bug-алгоритм);

2) использование модифицированного алгоритма (далее – алгоритм II), сочетающего алгоритм I и алгоритм vfn, что позволило не только находить оптимальные маршруты, но и эффективно справляться с длинными и сложными препятствиями, встречающимися на его пути.

Данная статья является продолжением работы, представленной в статье [2], и определяет параметры системы управления роботом, позволяющим реализовать возможности использования машинного обучения, технологии блокчейн и сохранения информационных данных в IPFS (далее – алгоритм III).

Вначале остановимся на особенностях машинного Q-обучения и системы IPFS.

Алгоритм Q-обучения

Используя данный алгоритм и полученное от среды вознаграждение, агент (далее – робот) создаёт функцию полезности Q. Это позволяет ему случайным образом выбирать стратегию поведения, учитывая при этом опыт предыдущих взаимодействий со средой.

Алгоритм Q-обучения анализирует пару "состояние-действие". Это позволяет вычислить ценность действия в конкретном состоянии. В любом процессе принятия решений с использованием Q-обучения определяется оптимальное значение Q.

Алгоритм Q-обучения позволяет агенту получать вознаграждение, выполняя наиболее оптимальные действия в каждом конкретном состоянии. Исходя из таблицы вознаграждений, алгоритм позволяет выбрать следующее действие на основе его полезности и дает возможность агенту обновлять Q-значение. Q-значения инициализируются случайными значениями и затем обновляются согласно выражению:

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha[r_t + 1 + \gamma \max_a Q] \quad (1)$$

где a_t и s_t – действие и состояние агента в момент времени t , α и γ – скорость обучения и дисконтирующий множитель, параметры которых находятся в диапазоне $[0, 1]$, r – значение вознаграждения [3].

Таким образом, создается новая таблица, называемая Q-таблицей, которая содержит информацию о состояниях и действиях агента. При значительном увеличении числа состояний и действий хранение информации в Q-таблице может стать проблематичным и привести к сбоям.

IPFS (Межпланетная файловая система)

Межпланетная файловая система (InterPlanetary File System, IPFS), представляет собой децентрализованную сеть для хранения и обмена данными с использованием технологии блокчейн. IPFS работает по принципу пиринговой сети, позволяя пользователям обмениваться и сохранять данные без центрального сервера. Когда файл загружается в IPFS, он разбивается на малые части, каждая из которых получает свой уникальный идентификатор (так называемый CID, полученный на основе хеша). Эти части хранятся по всей сети, и, когда кто-то хочет получить доступ к этому файлу, он собирается снова из этих частей с использованием хешей. Блокчейн добавляет неизменяемый журнал транзакций в IPFS. Любое изменение данных фиксируется в блокчейне, что обеспечивает прозрачность и проверяемость.

В отличие от HTTP, который загружает файлы с одного сервера за раз, контент-адресация в IPFS отделяет данные от их местоположения. IPFS извлекает файлы из нескольких источников одновременно в пиринговом режиме, что позволяет решать следующие задачи.

1. *Делать цифровой отпечаток данных.* Идентификаторы контента (CID) дают каждому элементу контента, данным или файлу постоянный хеш-адрес, который можно закрепить (pin), чтобы сохранить. Для закрепления можно использовать как сайт <https://ipfs.tech/>, так и другие специально предназначенные для этого сайты, например: <https://pinata.cloud/>, <https://www.infura.io/>, <https://www.4everland.org/>, <https://fleek.co/>.

2. *Свободно хранить и распространять данные.* Пиринговая сеть IPFS объединяет тысячи узлов. Таким образом, можно найти все узлы с необходимыми данными и помочь другим обнаружить контент, который есть у вас.

3. *Оптимизировать доставку данных.* IPFS кеширует и хранит данные на локальных серверах, экономя пропускную способность благодаря более эффективному распределению и доставке. *Если одни и те же данные расположены в разных местах сети, и какому-то узлу необходимо получить доступ к этим данным, в качестве источника информации будет использован тот узел, который расположен ближе к данному узлу.*

Проведение вычислительного эксперимента

Программно реализованные алгоритмы обучения, примененные к разработанной нами модели управления системой мобильных роботов, позволили провести вычислительный эксперимент с использованием разработанной компьютерной программы. При работе с симуляцией движения робота исполь-

зовался визуализатор Gazebo 11 и ROS 2 Humble Hawksbill. Для управления роботом использовались команды командной оболочки UNIX bash в ОС Linux Ubuntu 22.04 Jammy Jellyfish. Исходный код представлен в ветке “with-blockchain-json” [4]. Для работы алгоритма необходимо запустить скрипт `bash lines.sh`. Для задания конечной точки движения необходимо задать координаты X (переменная “targetX”) и Y (переменная “targetY”) в строках 3-16 файла `lines.sh`.

При проведении вычислительного эксперимента в качестве среды использовалась поверхность 20 на 20 клеток с препятствием в виде длинной стены (стартовая точка в координатах (-3;5), конечная точка в координатах (3;3)). В эксперименте использовались следующие параметры, необходимые для корректной работы Q-обучения: максимальная награда, при которой прекращается обучение, равнялась 100; максимальное количество шагов в эпизоде, по достижению которых эпизод обучения начинался заново, – 50. В координатах цели награда r за любое движение для достижения цели составляла 60. Мгновенная награда за достижение цели r составляла 100. Мгновенная награда r без достижения цели составляла -10. Значение α равнялось 0,1. Значение γ равнялось 0,9.

Структурная схема предложенного алгоритма представлена на рисунке 1.

Образец Q-таблицы в формате json в используемой программе приведен на рисунке 2.

Симуляционное пространство в пакете визуализации Gazebo 11 приведено на рисунке 3.

Предложенный алгоритм для огибания препятствий роботизированной системой состоит в следующем. В работе использовано Q-обучения с вариантами движения робота (действиями): 1) движение по алгоритму VFH* на расстояние предела видимости до начала движения; 2) движение по bug-алгоритму до тех пор, пока впереди не встретится препятствие. Состояние робота задавалось целыми значениями координатной сетки. Q-таблица представляет собой json-файл, в котором прописана награда за выбранное действие в выбранной ячейке координатной сетки. Начальные значения Q-таблицы задавались следующим образом: движение по алгоритму vfh: 1.1; движение по алгоритму bug левой стороной: 1.00001; движение по алгоритму bug правой стороной: случайное число от 0 до 1. Данные значения выбраны для ускорения обучения. Q-таблица хранилась в виде json-файла и после обновления автоматически сохранялась в блокчейн с использованием IPFS [5]. В качестве сайта для закрепления данных по технологии IPFS мы использовали <https://www.4everland.org/>. Блок-схема предложенного алгоритма представлена на рисунке 1. Образец элемента Q-таблицы представлен на рисунке 2.

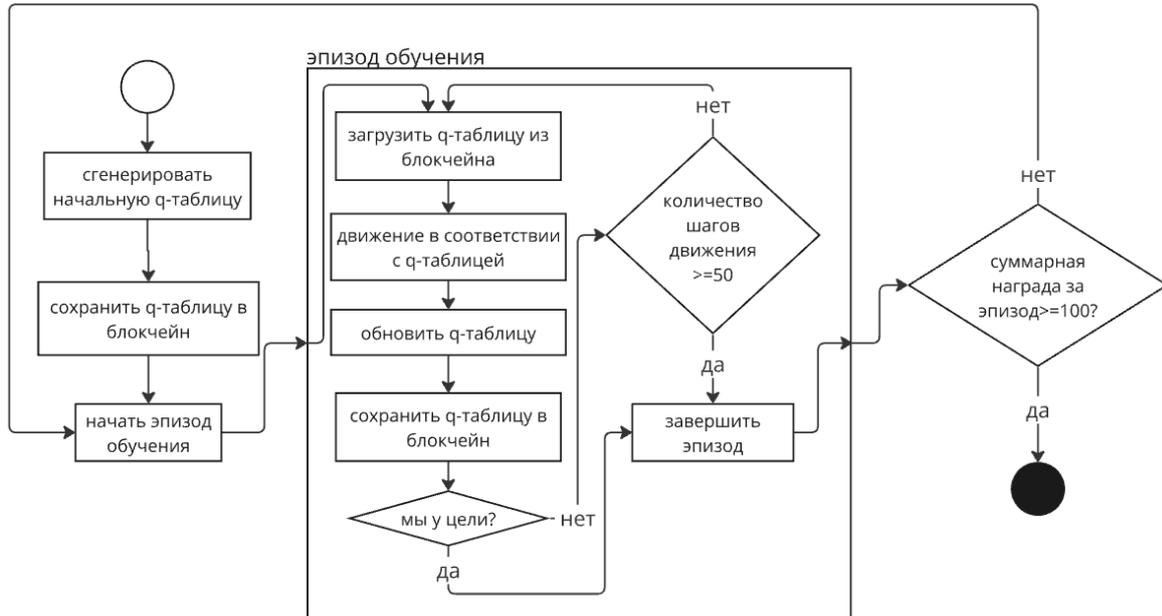


Рисунок 1. Структурная схема предложенного алгоритма

JSON	Необработанные данные	Заголовки
Сохранить	Копировать	Свернуть все
		Развернуть в
▼ [-10.0, -9.0]:		
▼ [-10.0, -9.0]:		
vfh:	1.1	
bug_left:	1.00001	
bug_right:	0.09728686372827333	
▶ [-9.0, -8.0]:	{..}	
▶ [-8.0, -7.0]:	{..}	
▶ [-7.0, -6.0]:	{..}	
▶ [-6.0, -5.0]:	{..}	
▶ [-5.0, -4.0]:	{..}	
▶ [-4.0, -3.0]:	{..}	
▶ [-3.0, -2.0]:	{..}	
▶ [-2.0, -1.0]:	{..}	
▶ [-1.0, 0.0]:	{..}	
▶ [0.0, 1.0]:	{..}	
▶ [1.0, 2.0]:	{..}	
▶ [2.0, 3.0]:	{..}	
▶ [3.0, 4.0]:	{..}	
▶ [4.0, 5.0]:	{..}	
▶ [5.0, 6.0]:	{..}	
▶ [6.0, 7.0]:	{..}	
▶ [7.0, 8.0]:	{..}	
▶ [8.0, 9.0]:	{..}	
▶ [9.0, 10.0]:	{..}	
▼ [-9.0, -8.0]:		
▼ [-10.0, -9.0]:		
vfh:	1.1	
bug_left:	1.00001	
bug_right:	0.22310654314829692	
▼ [-9.0, -8.0]:		
vfh:	1.1	
bug_left:	1.00001	
bug_right:	0.7321155557545258	
▼ [-8.0, -7.0]:		
vfh:	1.1	
bug_left:	1.00001	
bug_right:	0.3424112180046296	
▼ [-7.0, -6.0]:		
vfh:	1.1	
bug_left:	1.00001	
bug_right:	0.34414906006681645	
▼ [-6.0, -5.0]:		
vfh:	1.1	

Рисунок 2. Образец Q-таблицы в формате json в используемой программе

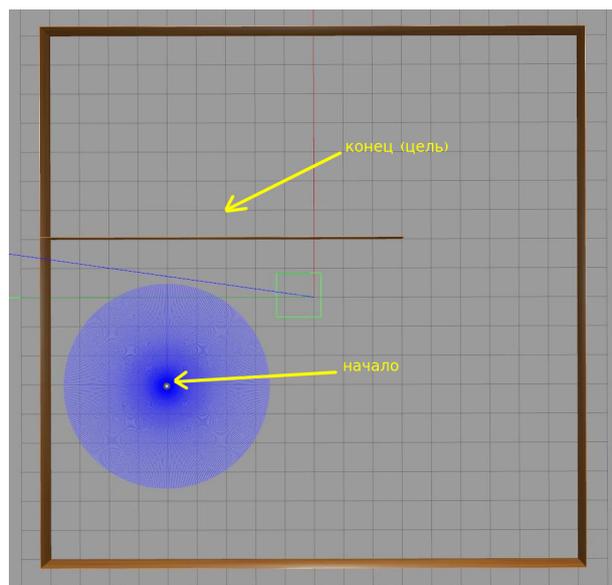


Рисунок 3. Симуляционное пространство в пакете визуализации Gazebo 11

Мы предварительно обучаем нашу систему до тех пор, пока награда за эпизод не станет равной или выше 100. Как показал эксперимент, после этого робот уверенно находит цель, оптимально огибая препятствия.

Анализ результатов вычислительного эксперимента

Результаты проведенного вычислительного эксперимента позволили представить кривую изменения суммарной награды за эпизод в течение обучения (рисунок 4) в процессе вычислительного эксперимента. Необходимо отметить, что несмотря на все прилагаемые усилия по программированию робота, иногда он все же сталкивался с препятствием, т.к. окружение Gazebo 11 моделирует реальное окружение, а в реальном окружении есть задержка прослушивания информации, получаемой от сенсоров, – роботу нужно время, чтобы получить и обработать информацию, среагировав на изменения в окружении в процессе движения. В случае соударения робота с препятствием мы просто перезапускаем окружение и начинаем эпизод обучения заново. Этим обуславливаются некоторые внезапные резкие снижения суммарной награды – робот просто столкнулся с препятствием. После обучения, для оценки времени достижения цели с огибанием препятствий мы запускаем очередной эпизод обучения и регистрируем время, которое понадобилось роботу для достижения цели.

Временные параметры движения роботизированной системы при применении различных разработанных нами алгоритмов (алгоритм I из работы [1], алгоритм II из работы [2], алгоритм III – предлагаемый алгоритм) показаны на рисунке 5.

Суммарная награда за эпизод обучения

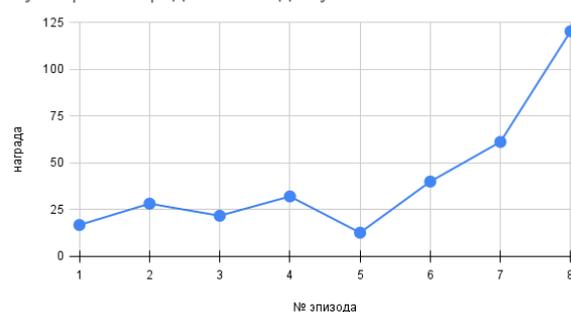


Рисунок 4. Суммарное значение вознаграждения относительно номера эпизода

При проведении эксперимента проводилось 10 измерений, погрешность рассчитывалась с использованием коэффициентов Стьюдента для доверительной вероятности $p = 0,95$. Время достижения цели с использованием алгоритма II составило 54,3 % относительно времени достижения цели алгоритма I, а алгоритма III – 40,2 % относительно времени достижения цели алгоритма I.

Время огибания препятствий

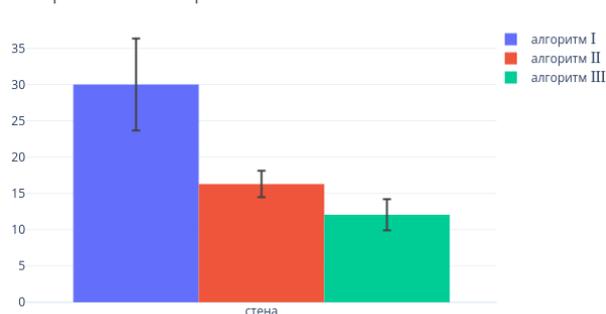


Рисунок 5. Временные параметры огибания препятствия роботом при использовании различных алгоритмов (в минутах)

Примеры движения робота по различным алгоритмам представлены в видео на платформе YouTube [6]. Как видно, предложенный алгоритм обладает наилучшими временными характеристиками.

Заключение

В данной работе мы предложили алгоритм огибания препятствий роботизированной системой с использованием машинного Q -обучения. Проведен вычислительный эксперимент по огибанию препятствия в виде длинной стены (рисунок 3). Оценено время движения до цели с огибанием препятствий (рисунок 5) в пространстве визуализации Gazebo 11 (рисунок 3) с использованием всех разработанных нами алгоритмов огибания препятствий. Выявлено, что с использованием предложенного

алгоритма III движение до цели без столкновения с препятствием происходит быстрее, чем при использовании алгоритмов, предложенных в работах [1] и [2]; время достижения цели для алгоритмов II и III составляет 54,3 % и 40,2 % относительно времени при использовании алгоритма I. Для каждого применяемого алгоритма записано видео с примером движения робота, которое затем было размещено на сайте YouTube.

В результате проведенной работы установлено, что верификация предложенного нами алгоритма продемонстрировала его преимущества перед ранее предложенными алгоритмами [1] и [2] в плане более высокой скорости достижения препятствия, а также его большую универсальность – данный алгоритм потенциально можно использовать для абсолютно любых типов препятствий, если правильно настроить необходимую плотность Q -таблицы для координатной сетки.

ЛИТЕРАТУРА

1. Сидоренко, А. В. Огибание препятствий при перемещении мобильного робота / А. В. Сидоренко, Н. А. Солодухо // Системный анализ и прикладная информатика. – 2023. – № 1. – С. 4-9. – DOI: 10.21122/2309-4923-2023-1-4-9
2. Сидоренко, А. В. Алгоритм огибания препятствий при перемещении мобильного робота / А. В. Сидоренко, Н. А. Солодухо // Системный анализ и прикладная информатика. – 2024. – № 4. – С. 29-33. – DOI: 10.21122/2309-4923-2024-4-29-33
3. Altuntas, N. Reinforcement learning-based mobile robot navigation / Nihal Altuntaş, Erkan Imal, Nahit Emanet, Ceyda Nur Ozturk // Turkish Journal of Electrical Engineering & Computer Sciences. – 2016. – Vol. 24, № 3. – P. 1747-1767. – DOI: org/10.3906/elk-1311-129
4. GitHub : [site]. – [San Francisco, California], 2008. – URL: <https://github.com/MikitaSaladukha/ROSproject/tree/with-blockchain-json> (date of access: 20.01.2025).
5. IPFS : [site]. – URL: <https://ipfs.tech/> (date of access: 20.01.2025).
6. YouTube : [site]. – URL: https://www.youtube.com/playlist?list=PLU4iF0_W9xOlrE8brTv5WYbpmQgZQ0OHk (date of access: 20.01.2025).

REFERENCES

1. Sidorenko, A.V. Bending obstacles when moving a mobile robot / A.V. Sidorenko, N.A. Saladukha // System analysis and applied information science. – 2023. – № 1. – P. 4-9. – DOI: 10.21122/2309-4923-2023-1-4-9
2. Sidorenko A.V. Obstacle avoidance algorithm in mobile robot motion / A.V. Sidorenko, N.A. Saladukha // System analysis and applied information science. 2024. – № 4. – P. 29-33. – DOI: 10.21122/2309-4923-2024-4-29-33
3. Altuntas, N. Reinforcement learning-based mobile robot navigation / Nihal Altuntaş, Erkan Imal, Nahit Emanet, Ceyda Nur Ozturk // Turkish Journal of Electrical Engineering & Computer Sciences. – 2016. – Vol. 24, № 3. – P. 1747-1767. – DOI: org/10.3906/elk-1311-129.
4. GitHub : [site]. – [San Francisco, California], 2008. – URL: <https://github.com/MikitaSaladukha/ROSproject/tree/with-blockchain-json> (date of access: 20.01.2025).
5. IPFS : [site]. – URL: <https://ipfs.tech/> (date of access: 20.01.2025).
6. YouTube : [site]. – URL: https://www.youtube.com/playlist?list=PLU4iF0_W9xOlrE8brTv5WYbpmQgZQ0OHk (date of access: 20.01.2025).

SIDORENKO A.V., SALADUKHA M.A.

ALGORITHM FOR OBSTACLE AVOIDANCE IN MOBILE ROBOT NAVIGATION USING Q-LEARNING AND BLOCKCHAIN TECHNOLOGY

Belarusian State University
Minsk, Republic of Belarus

Abstract. A robot movement modeling algorithm with obstacle avoidance using the Q-learning machine learning method is proposed. Q-learning allows for preserving the rewards obtained during modeling by performing optimal actions in each specific state. The Q-table contains information about the state and actions of the robot. Storing the Q-table in the blockchain using IPFS (InterPlanetary File System) technology ensures reliable and decentralized storage of data about the robot's states and actions. Content addressing in IPFS separates the data from its location and retrieves files from multiple sources in a peer-to-peer mode. A computational experiment for the proposed algorithm was conducted using a robot movement simulation environment. In the Gazebo II visualization package, it was shown that using the new algorithm, obstacles are avoided faster (by 59.8 %) compared to the previous version of the algorithm.

Keywords: robot, blockchain, IPFS, Q-learning, movement, obstacles, ROS 2, Gazebo II



Сидоренко Алевтина Васильевна, Белорусский государственный университет, Минск, Республика Беларусь. Доктор технических наук, профессор факультета радиофизики и компьютерных технологий.

A. V. Sidorenko, Belarusian State University, Minsk, Republic of Belarus, D.Sc., Professor at the Department of radiophysics and computer technologies faculty.

E-mail: sidorenkoa@yandex.by



Солодухо Никита Александрович, Белорусский государственный университет, Минск, Республика Беларусь. Магистр физико-математических наук, старший преподаватель факультета радиофизики и компьютерных технологий.

Mikita A. Saladukha, Belarusian State University, Minsk, Republic of Belarus. Master of Science. Senior Lecturer at the Department of radiophysics and computer technologies faculty.

ЛЮ ЮЙВЭЙ, САРАЖИНСКИЙ Д.С., КАПСКИЙ Д.В.

РАЗРАБОТКА ВАРИАНТА ГИБКОГО АЛГОРИТМА УПРАВЛЕНИЯ ДЛЯ ОРГАНИЗАЦИИ БЕЗОСТАНОВОЧНОГО ДВИЖЕНИЯ МАРШРУТНОГО ПАССАЖИРСКОГО ТРАНСПОРТА ЧЕРЕЗ РЕГУЛИРУЕМЫЙ ПЕРЕКРЕСТОК

Белорусский национальный технический университет
г. Минск, Республика Беларусь

Аннотация. Приведен анализ существующих методов уменьшения вероятности возникновения блокировки движения маршрутных пассажирских транспортных средств на регулируемых перекрестках. На участке улично-дорожной сети в районе пересечения проспекта Независимости – проспекта Машерова – улицы Козлова разработаны алгоритмы гибкого управления для уменьшения блокировок движения маршрутных пассажирских транспортных средств другими транспортными средствами на базе интеллектуальных транспортных систем, а также предложены решения по применению современных средств управления светофорным регулированием. С помощью имитационного микромоделирования выполнена оценка результативности предложенных решений и их эффективности.

Ключевые слова: транспортный поток, регулируемый перекресток, маршрутное транспортное средство, гибкое регулирование, алгоритм управления

Введение

Маршрутный пассажирский транспорт играет важную роль в обеспечении мобильности жителей города и снижении нагрузки на дорожную сеть [1, 2]. Для повышения эффективности его работы в настоящее время повсеместно начинают применять выделение специальных полос движения, предназначенных для маршрутного пассажирского транспорта [3, 4]. Однако движение по специально выделенным полосам осложняется в зоне регулируемых перекрестков из-за блокировки данной полосы движения правоповоротными автомобилями. В результате маршрутные транспортные средства не могут своевременно проехать перекресток, накапливаются очереди, нарушается расписание движения, а пассажиры теряют время. Главной целью всех существующих подходов и методов организации движения маршрутного пассажирского транспорта является обеспечение эксплуатационной скорости, а также стабильности его работы, то есть точное выполнение установленного расписания движения [3, 4]. Среди самых распространенных можно выделить следующие [2, 5-7]. Применение выделенных полос для движения маршрутных транспортных средств (МТС) (рис. 1).

В большинстве случаев выделенная полоса для движения маршрутных транспортных средств уменьшает задержки, но в периоды пиковой загруженности дорог ситуация заметно осложняется. При интенсивном движении

правоповоротные автомобили могут создавать очереди, которые распространяются на полосу, предназначенную для маршрутного транспорта. В результате МТС вынуждены снижать скорость или полностью останавливаться, теряя то преимущество, которое должно обеспечивать наличие выделенной полосы. Особенно остро эта проблема проявляется в случаях, когда перекресток не оборудован специальными светофорными секциями для правоповоротных автомобилей или отсутствуют карманы (уширения) для маневрирования. (рис. 2).



Рисунок 1. Выделенная полоса для маршрутного пассажирского транспорта

Метод смещения выделенной полосы для маршрутного пассажирского транспорта, при котором выделенная полоса переносится с первой полосы движения на вторую (рис. 3).



Рисунок 2. Протяженная очередь правоповоротных автомобилей на выделенной полосе (проспект Независимости)



Рисунок 3. Смещение выделенной полосы с организацией кармана для правоповоротных транспортных средств

Суть и причины применения метода смещения выделенной полосы заключаются в следующем: выделенная полоса для маршрутных транспортных средств (МТС) располагается на первой полосе, чаще всего крайней правой. При интенсивном движении и плотном пешеходном трафике на перекрестках это приводит к частым блокировкам правоповоротными транспортными средствами. Правоповоротные автомобили, занимая первую полосу для поворота направо, вынуждены ожидать завершения движения пешеходов, что приводит к заторам и задержкам МТС на выделенной полосе.

Перемещение выделенной полосы на вторую полосу позволяет разгрузить первую полосу, выделив её для поворачивающего транспорта, и тем самым уменьшить время ожидания МТС на перекрестках. Это способствует повышению эксплуатационной скорости маршрутного пассажирского транспорта и снижению общего времени поездки.

К основным преимуществам данного метода относится снижение конфликтов с правоповоротным транспортом непосредственно перед перекрестком. Перемещение выделенной полосы на вторую полосу позволяет значительно уменьшить задержки на перекрестках и блокировки маршрутного пассажирского транспорта.

Стоит отметить, что метод смещения выделенной полосы требует дополнительной

организации дорожного движения и наличия площадей.

Нужно отметить, что в ряде случаев для эффективной работы выделенной полосы необходим контроль за соблюдением правил, чтобы предотвратить незаконный въезд личного транспорта, что требует дополнительных ресурсов.

Также одним из эффективных методов уменьшения задержек МТС в мире является система приоритета маршрутного транспорта на светофорах (*Traffic Signal Priority*).

Суть этого метода заключается в предоставлении приоритетного проезда маршрутных пассажирских транспортных средств через регулируемые перекрестки, что позволяет уменьшить время в пути, повысить регулярность движения и сделать маршрутный пассажирский транспорт более привлекательным для пассажиров [2, 5-6].

Также развиваются системы скоростного пассажирского транспорта, которые обеспечивают высокую скорость, надёжность и большую провозную способность по сравнению с обычными маршрутами из-за выделения отдельных путей следования и специального обустройства подходов и ожидания пассажиров прибытия МТС [2, 7].

Предпосылки для моделирования

Выбран объект исследования, который находится на одной из самых загруженных магистралей улично-дорожной сети крупнейшего города нашей страны – Минска. По проспекту Независимости проходит значительное количество маршрутов пассажирского транспорта, что подчёркивает его важность для пассажирских перевозок. В связи с этим эффективность движения маршрутного пассажирского транспорта на данном проспекте напрямую влияет на качество транспортного обслуживания жителей города.

В частности, особенно остро проблема блокировки движения МТС наблюдается на участке улично-дорожной сети в районе пересечения проспекта Независимости, проспекта Машерова и улицы Козлова (рис. 4). Здесь большое количество транспортных средств вынуждено временно занимать выделенную полосу для маршрутного транспорта при подготовке к повороту направо со стороны проспекта Независимости в сторону проспекта Машерова. При этом, даже имея разрешающий сигнал светофора, они часто вынуждены ожидать завершения движения пешеходов, пересекающих их траекторию. Кроме того, такие автомобили имеют право перестраиваться на выделенную полосу, если она отделена прерывистой линией, что создаёт дополнительные сложности и приводит к регулярным задержкам маршрутного транспорта.

В часы пик особенно снижается эффективность работы выделенных полос, ухудшая общую регулярность движения общественного транспорта. Кроме того, эффективность функционирования этих полос значительно снижается из-за недостаточного контроля за соблюдением правил.

Часто выделенная полоса оказывается занята не только маршрутным транспортом, но и легковыми автомобилями, в том числе такси, которые не относятся к маршрутным транспортным средствам и не имеют права пользоваться выделенной полосой, что дополнительно усугубляет ситуацию.

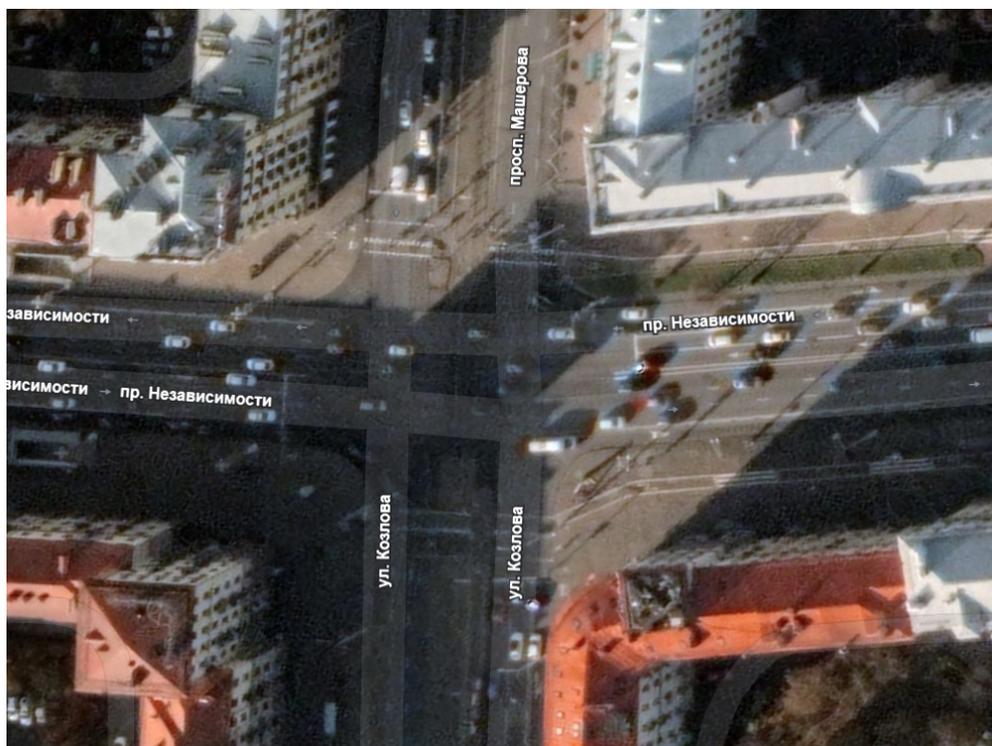


Рисунок 4. Схема исследуемого поворота транспортных средств с проспекта Независимости в сторону проспекта Машерова

Вследствие этих факторов маршрутные транспортные средства, которые должны иметь преимущество на выделенной полосе, вынуждены снижать скорость, простаивать в заторах или перестраиваться в соседние полосы, чтобы продолжить движение. Это в свою очередь нивелирует основное преимущество выделенной полосы — сокращение времени в пути и повышение надежности расписания маршрутного пассажирского транспорта. Кроме того, подобные ситуации создают дополнительный стресс для пассажиров, ухудшают общую транспортную ситуацию на перекрестке и снижают уровень комфорта при использовании маршрутных пассажирских транспортных средств.

Таким образом, рассматриваемый участок улично-дорожной сети является ярким примером сложной транспортной проблемы, характерной для многих крупных городов, где даже при наличии современной инфраструктуры и выделенных полос для маршрутного пассажирского транспорта

возникают значительные трудности с обеспечением беспрепятственного движения.

Выполнены исследования режимов светофорного регулирования, геометрических параметров и дорожных условий, а также замеры интенсивности транспортных и пешеходных потоков на исследуемом объекте. Полученные значения обработаны с помощью программного обеспечения New Traffic Intensity [8] и представлены в виде картограммы интенсивности движения (рис. 5).

Исследования проводились по методике БНТУ [9]. Также была получена информация о расписании движения маршрутного пассажирского транспорта. Согласно ей, частота прибытия МТС на объект исследования составляет 5 минут. Помимо того, были дополнительно проведены замеры среднепутевой скорости движения транспортных средств на участке: регулируемый пешеходный переход около домов № 46 и № 47 пр-та Независимости — пересечение пр-та Независимости, пр-та Машерова, улицы Козлова (рис. 6).

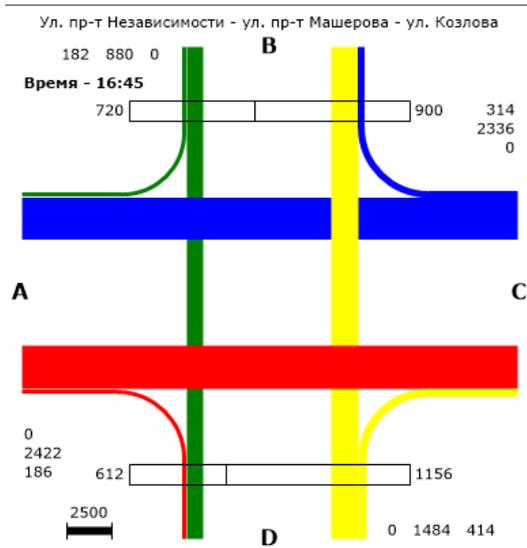


Рисунок 5. Картограмма интенсивности движения на пересечении исследуемого объекта, ед/ч и пеш/ч

Необходимо отметить, что для измерений скоростей на данном исследуемом объекте учитывались только транспортные средства, которые начинали движение после полной остановки на стоп-линии регулируемого пешеходного перехода около домов № 46 и № 47 проспекта Независимости.

Среднепутевая скорость потока из МТС и остальных ТС по направлению к перекрёстку измерялась в целевой период времени (вторник) (фрагмент – рис. 7).

По результатам измерений было получено значение коэффициента безостановочного проезда, который оказался равным 0,36. Это означает, что лишь небольшая часть всех транспортных средств движется без остановок, тогда как остальная их часть сталкивается с необходимостью замедления или полной остановки в связи с включением красного сигнала светофора на исследуемом перекрёстке.

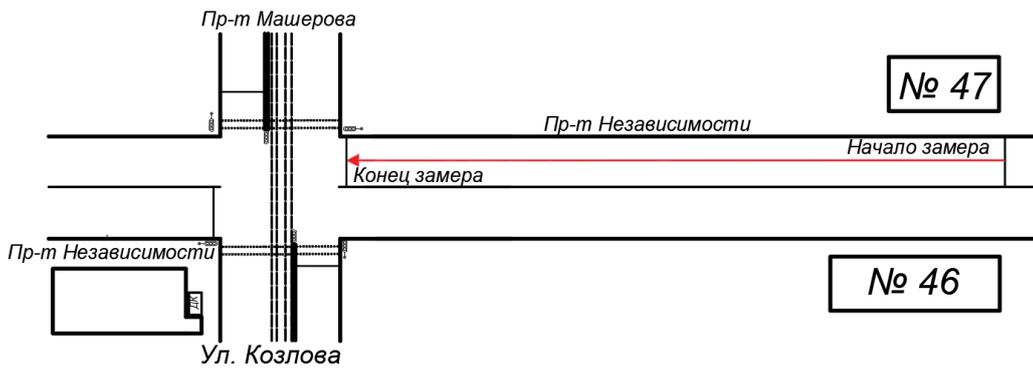


Рисунок 6. Схема участка для проведения замера среднепутевых скоростей

$\eta = \{50.86, 37.5\}$

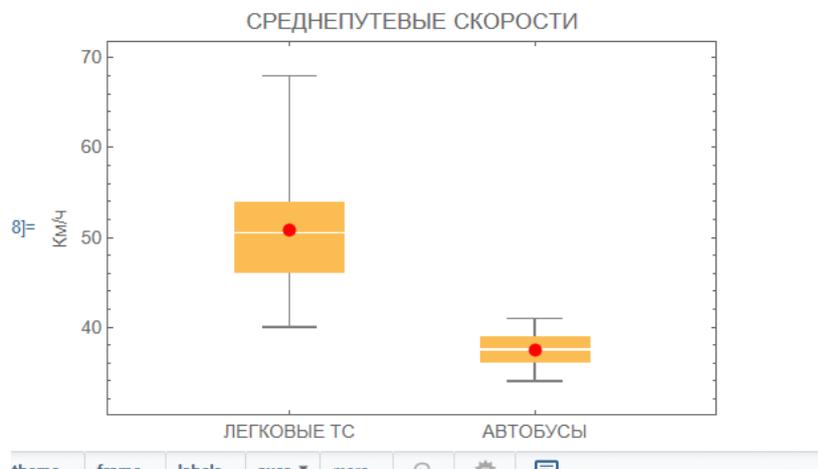


Рисунок 7. Бокс-диаграмма среднепутевых скоростей

Разработка вариантов гибкого управления на перекрестке

Общий принцип модели базируется на том, что водитель маршрутного транспортного средства, заметив перед собой очередь транспортных средств, выполняющих правый поворот, может подать запрос на обслуживание дорожному контроллеру, что в свою очередь активирует диаграмму светофорного регулирования, обеспечивающую остановку транзитного потока по второй полосе и беспрепятственный пропуск маршрутного пассажирского транспортного средства. В простейшем (первом варианте) это выглядит, как указано на рисунках 8 и 9.

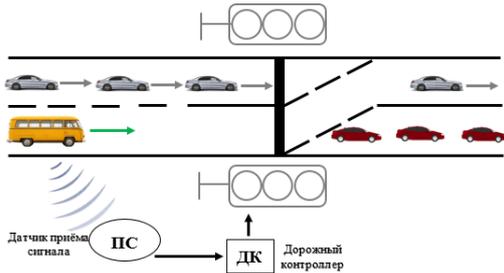


Рисунок 8. Запрос на обслуживание из салона маршрутного пассажирского транспортного средства

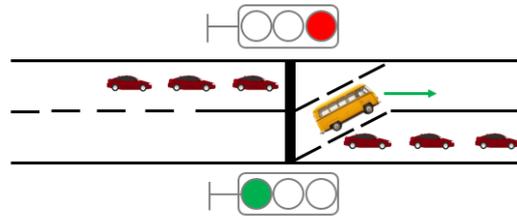


Рисунок 9. Проезд маршрутного пассажирского транспортного средства после активации цикла диаграммы светофорного регулирования

После того как МТС завершают проезд через регулируемую зону, по окончании одного активного цикла регулирования, светофоры возвращаются к выключенному состоянию. Алгоритм работы можно представить в следующем виде (рис. 10).

Соответствующая диаграмма одного активного цикла представлена на рисунке 11.

Данный алгоритм может быть реализован на дорожных контроллерах типа «СИДК», которые поддерживают жёлтый мигающий сигнал в программах и обеспечивают организацию гибкого регулирования движения. Для этого достаточно организации тактов и переходов между ними согласно рисункам 12 и 13.

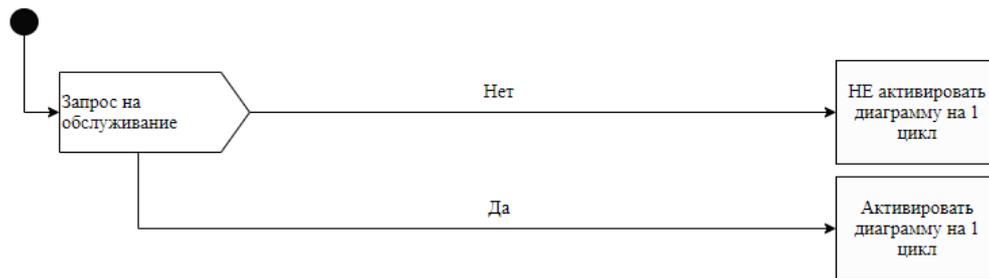


Рисунок 10. Алгоритм работы первого варианта реализации

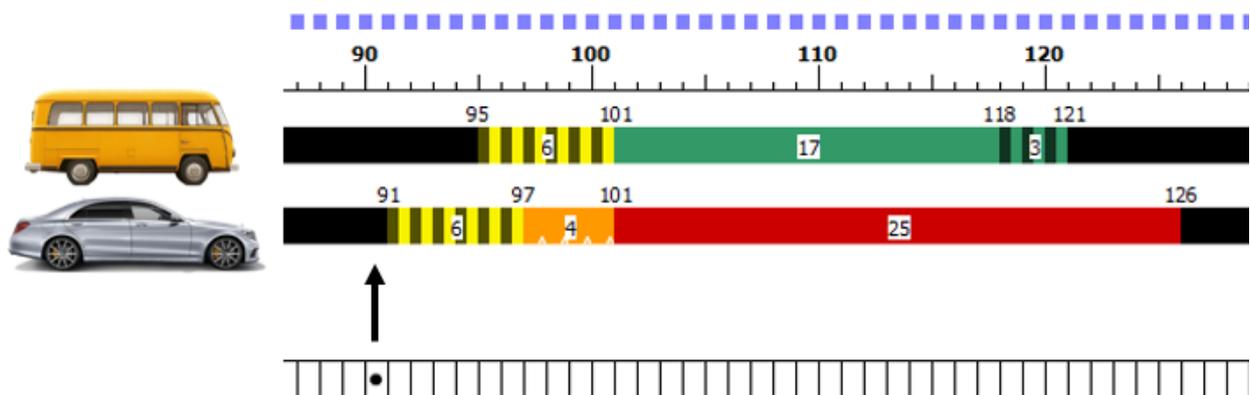


Рисунок 11. Диаграмма светофорного регулирования (границы активного цикла выделены синим цветом)

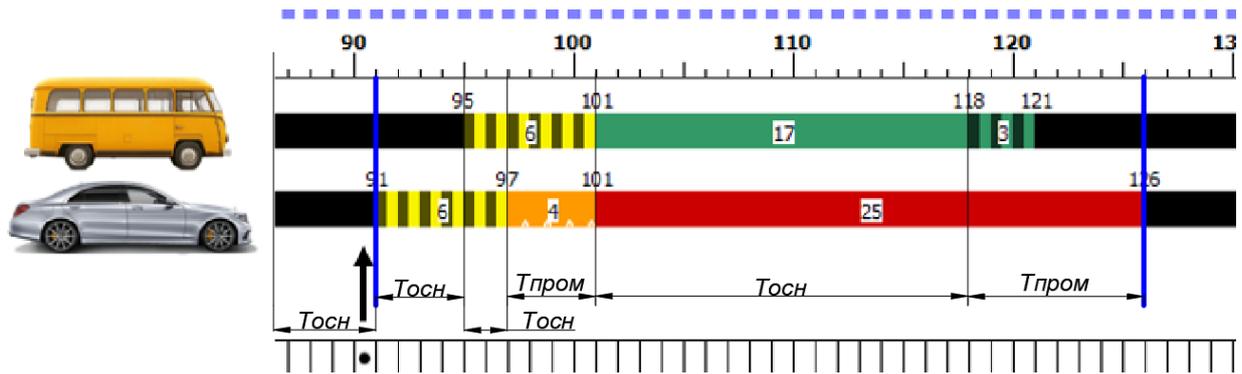


Рисунок 12. Потактовое представление диаграммы светофорного регулирования на один цикл

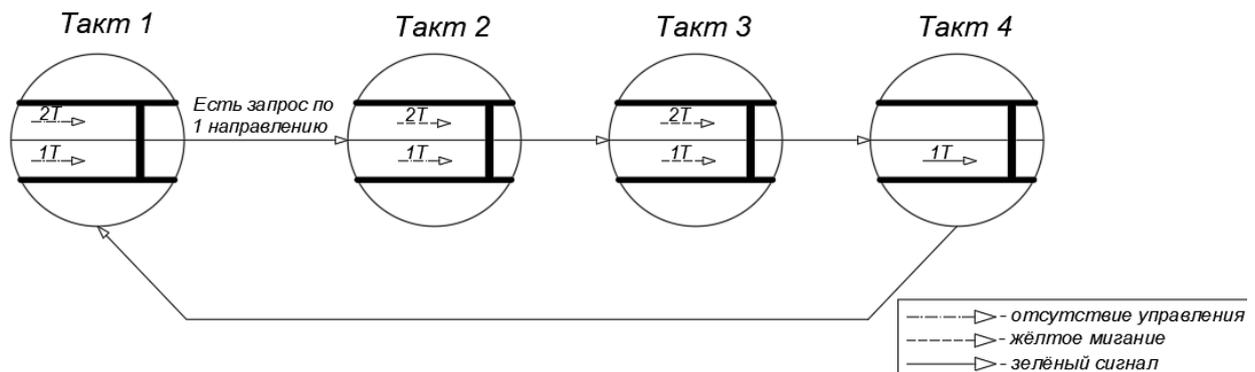


Рисунок 13. Потактовое переключение

Однако в рассмотренном варианте есть следующий недостаток: проблема с выбором длительности зелёного сигнала. Например, бывает так, что после включения светофора на зелёный сигнал проезжает всего одна подвижная единица МТС, а время зелёного сигнала ещё не закончилось, поскольку предусматривало проезд двух – то есть присутствует неиспользуемое время, которое можно сократить.

Поэтому предложен второй вариант реализации решения.

Реализация второго варианта отличается следующим: если, после того как был получен первый запрос на обслуживание, например, от первого МТС, в течение определённого времени не поступает никаких новых запросов, скажем, от второго или третьего МТС, то в контроллер поступает информация о наличии разрыва в потоке¹. В ответ дорожный контроллер автоматически сокращает длительность зелёного сигнала до минимума (рис. 14).

Для реализации такого решения в проекте предполагается использование (помимо датчика запроса на обслуживание) дополнительного

¹Разрыв в потоке – это ситуация, когда после проезда первого автомобиля следующее транспортное средство появляется с временным зазором (Gap), превышающим установленный порог, заданный для данного датчика.

логического датчика² (датчик разрыва в потоке), в варианте, который фиксирует мгновенное состояние разрыва (то есть, не запоминает единожды уже обнаруженный разрыв). В качестве порогового значения для обнаружения разрыва в потоке предлагается установить 5 сек, поскольку этого времени достаточно, чтобы МТС успело доехать от расположенного поблизости остановочного пункта до регулируемой зоны.

Таким образом, алгоритм работы можно представить в следующем виде (рис. 15).

Условие «Зелёный горит ≥ 5 секунд» используется, чтобы предоставить второму МТС возможность подать запрос на продолжение зелёного сигнала, когда первый МТС ещё не завершило проезд.

Соответствующая диаграмма одного цикла представлена на рисунке 16.

Данный алгоритм, также, как и в первом случае, может быть реализован на дорожных контроллерах типа «СИДК», которые поддерживают жёлтый мигающий сигнал в программах и обеспечивают организацию гибкого регулирования движения. Для этого достаточно организации тактов и переходов между ними в соответствии с рисунками 17 и 18.

² Логический датчик — абстрактный датчик, обрабатывающий данные с физического детектора

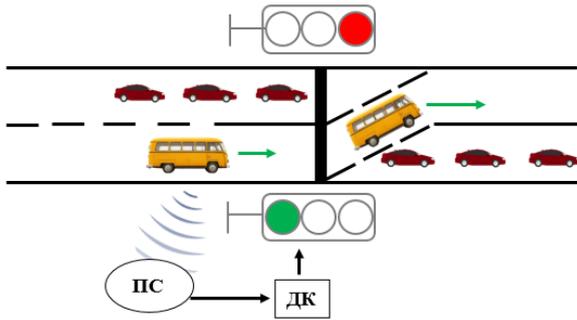


Рисунок 14. Управление в ситуации, когда есть 2 запроса на обслуживание (без сокращения времени)

Разработана схема размещения светофоров и основных элементов дорожной инфраструк-

туры, которая отражает планируемую организацию движения на рассматриваемом участке (рис. 19).

Для обеспечения эффективного и безопасного регулирования движения на рассматриваемом перекрёстке необходимо правильно спроектировать расположение светофорных объектов и сопутствующих элементов приёма и передачи запроса от водителя к дорожному контроллеру. Ниже приведено подробное описание размещения основных компонентов системы, включая установку стоп-линии, светофорных опор и дополнительных устройств, обеспечивающих максимальную видимость и информативность сигналов для водителей.

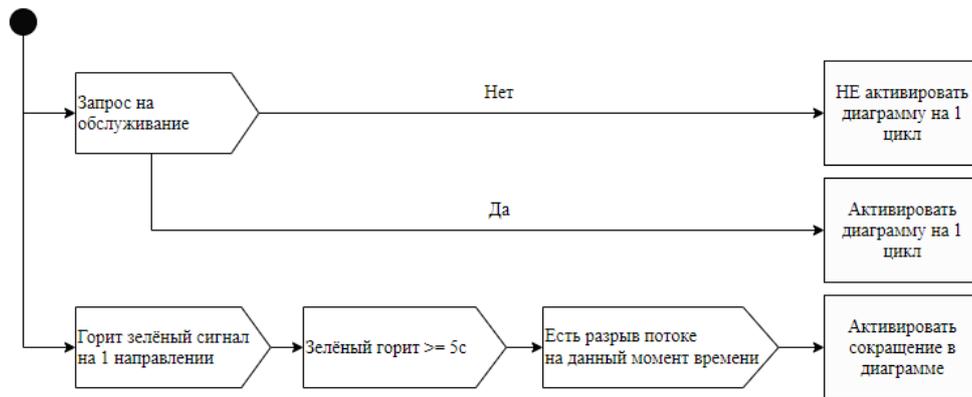


Рисунок 15. Алгоритм работы второго варианта реализации

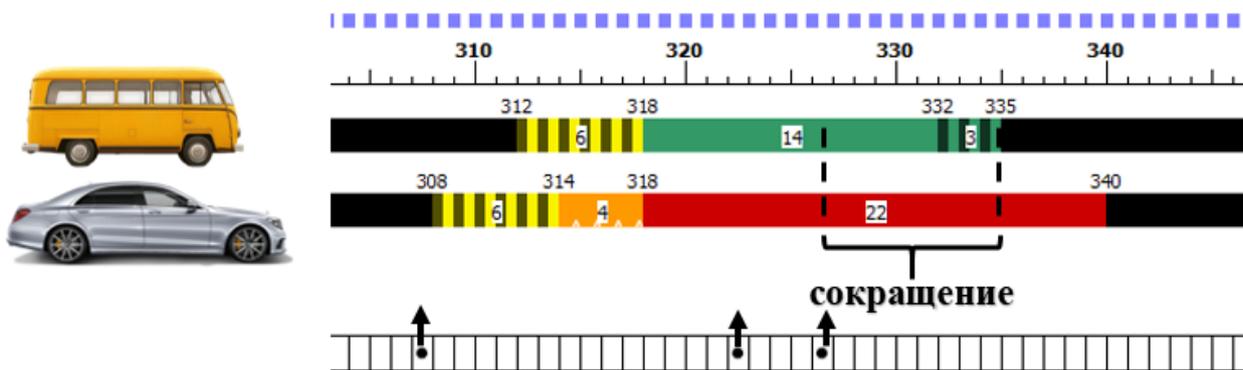


Рисунок 16. Диаграмма светофорного регулирования при нескольких запросах на обслуживание

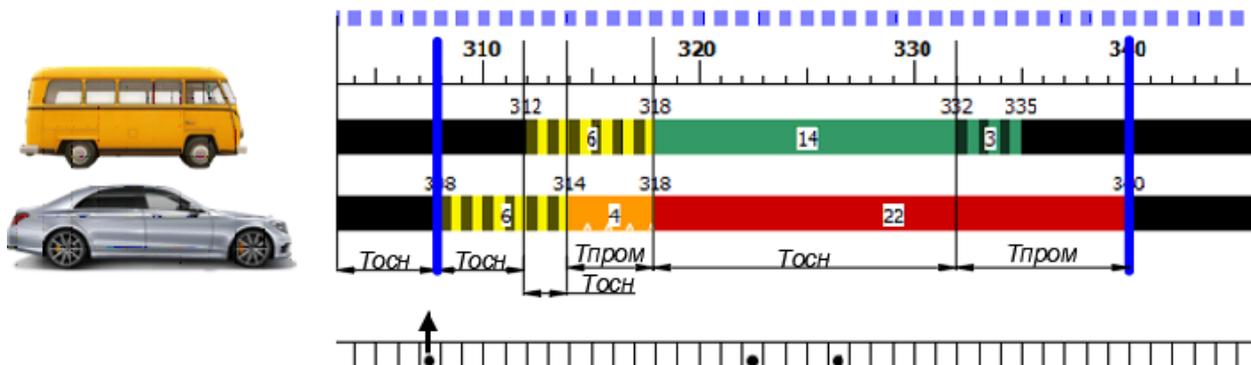


Рисунок 17. Потактовое представление диаграммы светофорного регулирования на один цикл

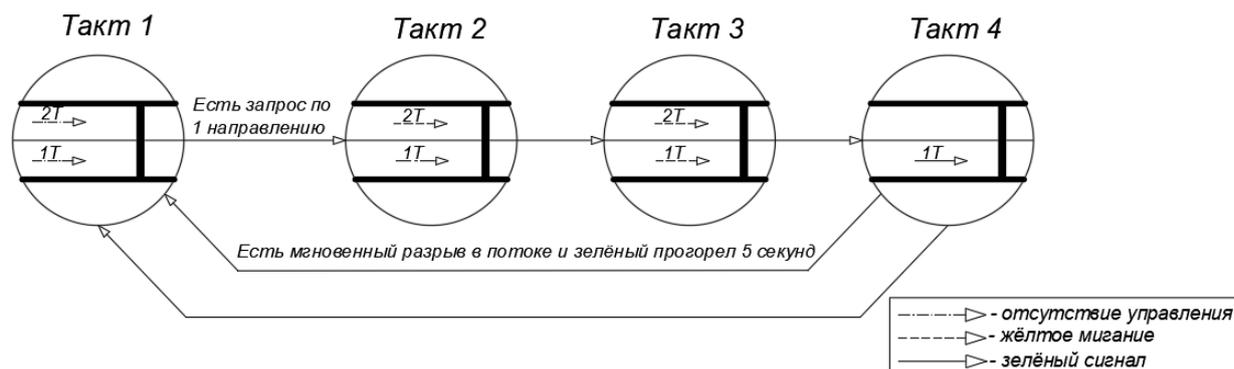


Рисунок 18. Потактовое переключение

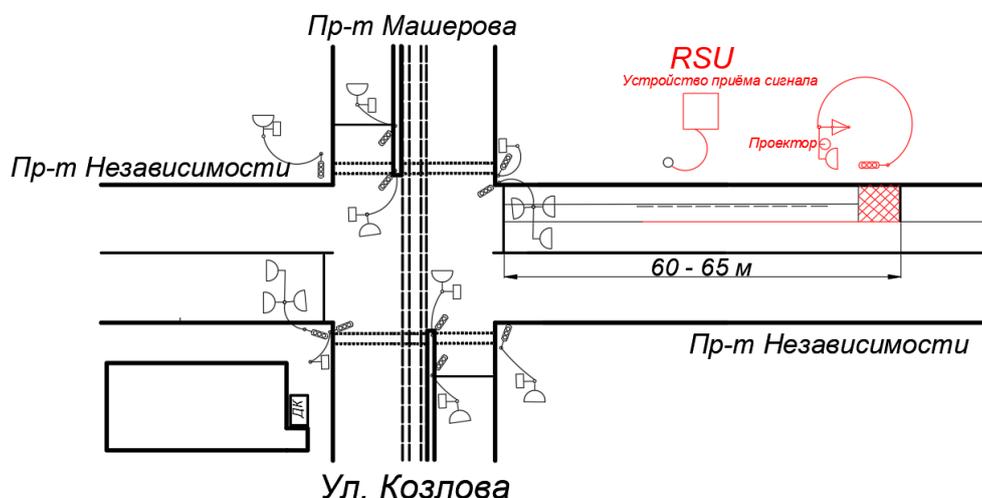


Рисунок 19. Схема предполагаемого размещения светофоров и основных элементов дорожной инфраструктуры

Имеет смысл нанести стоп-линию за 60–65 метров до перекрёстка (по результатам замеров максимальной очереди). Справа, на тротуаре или газоне, на расстоянии 10 метров от стоп-линии устанавливается гранёная светофорная опора. На этой опоре справа размещается светофор для выделенной полосы Т.8. Для второй полосы сверху на опоре устанавливается светофор Т.1. Вместе со светофором Т.1 монтируется экран с чёрным фоном и белой каймой, а под ним размещается знак 7.14, указывающий, что действие сигнала распространяется только на полосу, находящуюся под знаком.

Кроме того, на светофорной опоре устанавливается проектор, дублирующий сигналы обоих светофоров, чтобы водители других транспортных средств с большей вероятностью могли их заметить. Для светофора Т.8 используются маски в виде стрелки «Движение разрешено» и символа МТС.

Перед стоп-линией наносится разметка 1.37 и устанавливается экран со светоотражающей краской для проецирования сигналов с проектора (рис. 20).

Также в 20 метрах от самого перекрёстка на опоре освещения будет установлен коммуникационный модуль TEDIX системы LTE-V2X для передачи запроса от водителя к дорожному контроллеру.



Рисунок 20. Визуальное представление решения на исследуемом перекрёстке

Для организации передачи запроса от водителя маршрутного пассажирского транспортного средства к дорожному контроллеру наиболее перспективным представляется использование технологии LTE V2X.

В качестве технической реализации технологии LTE-V2X можно использовать оборудование, в частности компании Fort Telecom, выпускаемое под брендом TEDIX.

Архитектура этой системы строится на следующих ключевых компонентах [10-11]:

1. Бортовой модуль LTE-V2X (OBU – On Board Unit (TEDIX)) — устройство, устанавливаемое в салоне МТС, служит связующим звеном между водителем и дорожной инфраструктурой. Оно оснащено цифровыми входами для подключения кнопки ручного управления. Также есть подключение к TEDIX-Connect — мобильное приложение на базе операционной системы Android для приёма информации от придорожного коммуникационного модуля (рис. 21 и 22);

2. Придорожный коммуникационный модуль (RSU – Road Site Unit (TEDIX)) – придорожный терминал, принимающий запросы от OBU и передающий их на светофорный контроллер, например, СИДК. (рис. 23);

3. Сервер управления ИТС – централизованная платформа, обрабатывающая данные со всех перекрёстков и координирующая их работу для оптимизации движения на масштабах города. Однако стоит отметить, что технология обеспечивает прямую и надёжную связь между маршрутным транспортным средством и дорожной инфраструктурой без необходимости постоянного подключения к центральному серверу.



Рисунок 21. Бортовой модуль LTE-V2X (TEDIX)



Рисунок 22. Мобильное приложение на базе операционной системы Android



Рисунок 23. Придорожный коммуникационный модуль RSU

В данном разделе были рассмотрены основные компоненты проектного решения, включая варианты его реализации и алгоритмы функционирования. Представленные технические решения и алгоритмы направлены на повышение безопасности и оптимизацию движения маршрутного пассажирского транспорта за счёт минимизации блокировок.

Для оценки результативности и эффективности разработанных алгоритмов использовался программный комплекс SUMO (Simulation of Urban MObility). Этот инструмент позволяет проводить моделирование и симуляцию городских транспортных потоков, что является важным для анализа и оптимизации дорожного движения.

Далее была выполнена калибровка модели, основанная на реальных данных о движении потока транспортных средств. Калибровка включала настройку параметров модели для обеспечения максимального соответствия симуляции реальным условиям дорожного движения. SUMO по умолчанию использует Крауссову модель для симуляции движения транспортных средств. Для достижения реалистичного поведения автомобилей в симуляции, параметры этой модели были изменены и адаптированы.

Процесс калибровки включал итеративные изменения параметров и последующее тестирование модели, чтобы достичь оптимального соответствия между симулированными и реальными данными. Для этого использовались данные о дорожном движении, собранные на исследуемом объекте, что позволило создать высоко реалистичную модель дорожного потока.

После завершения калибровки и настройки параметров модели, были проведены симуляции, которые включали два ключевых этапа: проведение имитационного эксперимента с существующими

настройками светофорного объекта и эксперимента с предлагаемыми мерами уменьшения блокировок движения маршрутных транспортных средств.

Симуляции, по которым производилась оценка эффективности, моделировали полтора часа для каждого рассматриваемого варианта. Симуляции были проведены в 21 прогон.

В качестве показателя результативности используются показатели общих задержек транспортных средств на исследуемом перекрёстке [12], которые были рассчитаны с помощью SUMO. Система рассчитала задержки для всех

транспортных средств: для МТС, для транспортных средств, которые движутся в прямом направлении и для правоповоротных транспортных средств.

Также было проведено тестирование гипотез для пересекающихся бокс-диаграмм задержек, которое показало, что при предлагаемых вариантах 1 и 2 задержки легковых автомобилей статистически не отличаются от исходного варианта, в то время как для маршрутных пассажирских транспортных средств варианты 1 и 2 статистически-значимо отличны от исходных.

Результаты расчётов представлены в таблице 1.

Таблица 1. Общие задержки транспортных средств (за полтора часа)

Общие задержки, авт*ч	Существующие	Предлагаемые Вариант-1	Предлагаемые Вариант-2
МТС (автобусы)	0,63	0,47	0,49
Прямо движущиеся ТС	26,79	25,69	25,42
Правоповоротные ТС	12,99	11,75	11,8

Сравнительные бокс-диаграммы задержек ТС при различных вариантах представлены на рисунках 24-26.

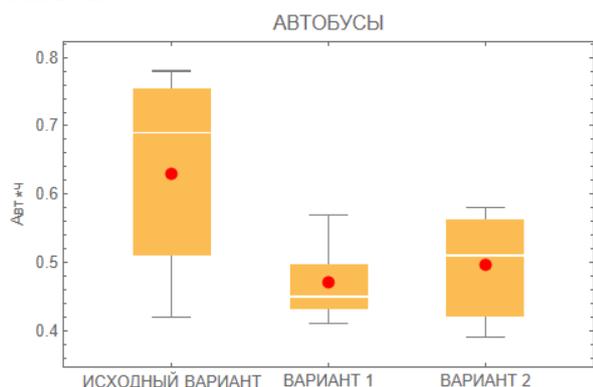


Рисунок 24. Сравнительная бокс-диаграмма общих задержек МТС

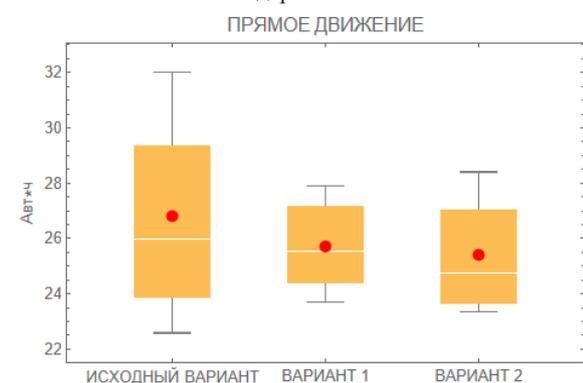


Рисунок 25. Сравнительная бокс-диаграмма общих задержек транспортных средств, движущихся в прямом направлении

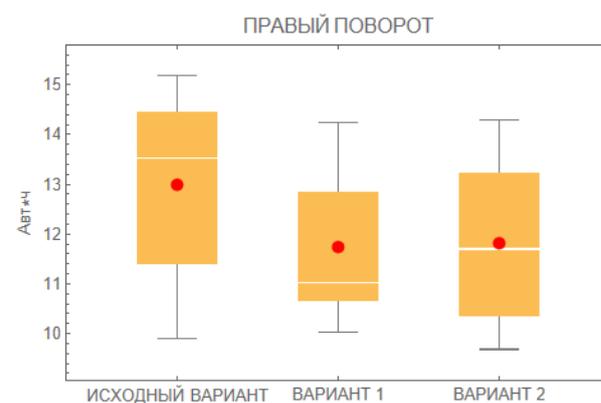


Рисунок 26. Сравнительная бокс-диаграмма общих задержек транспортных средств, движущихся направо

Таким образом, на основании приведённых данных анализа бокс-диаграмм можно сделать вывод, что введение первого варианта проектного решения является достаточно результативным, и его использование приведёт к снижению задержек для маршрутных транспортных средств на 25,4 %.

Введение второго варианта проектного решения приведёт к снижению задержек для маршрутных транспортных средств на 21,3 %. Для прямо движущихся и правоповоротных транспортных средств ситуация не изменилась. По методике БНТУ определены годовые потери от задержек (представлены в таблице 2).

Таблица 2. Годовые потери от задержек транспортных средств

Потери от общих задержек, у.е./год	Существующие	Предлагаемые Вариант-1	Предлагаемые Вариант-2
МТС (автобусы)	81497	60799	63386
Прямо движущиеся ТС	247540	237376	234881
Правоповоротные ТС	120028	108570	109032

Заключение

В результате исследований были разработаны алгоритмы адаптивного управления транспортными потоками в двух вариантах: для активации диаграммы светофорного регулирования, где неиспользуемое время не сокращается (вариант 1), и для активации диаграммы светофорного регулирования на один цикл, где неиспользуемое время сокращается до минимума в случае отсутствия дополнительных МТС (вариант 2).

С помощью имитационного моделирования в SUMO выполнена оценка показателей эффективности, в результате которой установлено:

– общие часовые задержки для маршрутных транспортных средств при введении первого варианта проектного решения сократились на 25,4 %, а введение второго варианта проектного решения способствовало снижению задержек на 21,3 %;

– потери от задержек МТС снижаются на 20698 у.е./год;

– срок окупаемости капиталовложений – 80 дней;

– годовой экономический эффект составит 19167 у.е./год;

– при этом на 1 у.е. капитальных вложений потери от задержек снижаются на 4,46 у.е./год.

ЛИТЕРАТУРА

1. **Капский, Д. В.** Бионическое развитие транспортных систем городов / Д. В. Капский, С. В. Богданович // Транспорт и транспортные системы: конструирование, эксплуатация, технологии : сборник научных статей. – Минск, 2022. – Вып. 4. – С. 91–97.
2. Устойчивая городская мобильность: теория и практика развития / А. О. Лобашов, Е. Н. Кот, Д. В. Капский [и др.]. – Вологда : Инфра-Инженерия, 2023. – 236 с.
3. **Капский, Д. В.** Методология повышения качества дорожного движения / Д. В. Капский / Минск : БНТУ, 2018. – 372 с.
4. **Капский, Д. В.** Повышение эффективности применения информации при организации перевозок пассажиров в городах / Д. В. Капский, С. С. Семченков, О. Н. Ларин // Наука и техника. – 2022. – № 4. – С. 323-330. – DOI: 10.21122/2227-1031-2022-21-4-323-330
5. **Transit signal priority** // TSMO at WSDOT. – URL: <https://tsmowa.org/category/intelligent-transportation-systems/transit-signal-priority> (дата обращения: 04.06.2025).
6. **Signal Priority** // Federal Transit Administration. – URL: <https://www.transit.dot.gov/research-innovation/signal-priority> (дата обращения: 04.06.2025).
7. **Bus rapid transit. Planning guide.** – New York, 2007. – 825 p.
8. RTF-Road traffic flows : свидетельство о регистрации компьютерной программы № 222 / Д. В. Капский, Д.В. Мозалевский, М.К. Мирошник, А.В. Коржова, В.Н. Кузьменко, А.С. Полховская, Е.Н. Костюкович. – № С20100112 ; заявл. 07.09.2010 ; опубл. 17.09.2010 / Нац. центр интеллектуальной собственности.
9. Технические средства организации дорожного движения / Е. Н. Кот, Д. В. Капский, А. В. Коржова. – Минск : БНТУ, 2016. – 239 с.
10. TEDIX – оборудование для V2X // Fort Telecom. – URL: <https://tedix.fort-telecom.ru/> (дата обращения: 04.06.2025).
11. Vehicle-to-Everything (V2X) 5G в эволюции автомобилей // TAdviser. – URL: <https://www.tadviser.ru/index.php> Статья: Vehicle-to-Everything (V2X) 5G в эволюции автомобилей (дата обращения: 04.06.2025).
12. **Врубель, Ю. А.** Определение потерь в дорожном движении / Ю. А. Врубель, Д. В. Капский, Е. Н. Кот. – Минск : БНТУ, 2006. – 239 с.

REFERENCES

1. **Kapski, D. V.** Bionic development of urban transport systems / D. V. Kapski, S. V. Bogdanovich // Transport and transport systems: design, operation, technologies : collection of scientific articles. – Minsk, 2022. – Vol. 4. – P. 28–34 (in Russian).

2. Sustainable urban mobility : theory and practice of development / A. O. Lobashov, E. N. Kot, D. V. Kapski [et al.]. – Vologda : Infra-Inzhenerija, 2023. – 236 p. (in Russian).
3. **Kapski, D. V.** Methodology for improving the quality of road traffic / D. V. Kapski / Minsk : BNTU, 2018. – 372 p. (in Russian).
4. **Kapski, D. V.** Improving the Efficiency of Information Application in the Organization of Passenger Transportation in Cities. / D. V. Kapski, S. S. Semchenkov, O. N. Larin // Science & Technique. – 2022. – Vol. 21, № 4. – P. 323-330. – DOI: 10.21122/2227-1031-2022-21-4-323-330 (in Russian).
5. Transit signal priority // TSMO at WSDOT. – URL: <https://tsmowa.org/category/intelligent-transportation-systems/transit-signal-priority> (date of access: 04.06.2025).
6. Signal Priority // Federal Transit Administration. – URL: <https://www.transit.dot.gov/research-innovation/signal-priority> (date of access: 04.06.2025).
7. Bus rapid transit. Planning guide. – New York, 2007. – 825 p.
8. RTF-Road traffic flows : svidetel'stvo o registracii komp'juternoj programmy № 222 / D.V. Kapski, D.V. Mozalevskij, M.K. Miroshnik, A.V. Korzhova, V.N. Kuz'menko, A.S. Polhovskaja, E.N. Kostjukovich. – № S20100112 ; zajavl. 07.09.2010 ; opubl. 17.09.2010 / Nac. centr intelektual'noj sobstvennosti. (in Russian).
9. **Kot, E. N.** Technical means of road traffic organisation / E. N. Kot, D. V. Kapski, A. V. Korzhova. – Minsk : BNTU, 2016. – 239 p. (in Russian).
10. TEDIX – equipment for V2X // Fort Telecom. – URL: <https://tedix.fort-telecom.ru/> (date of access: 04.06.2025).
11. Vehicle-to-Everything (V2X) 5G in the evolution of automobiles // TAdviser. – URL: [https://www.tadviser.ru/index.php/Статья:Vehicle-to-Everything_\(V2X\)_5G_в_эволюции_автомобилей](https://www.tadviser.ru/index.php/Статья:Vehicle-to-Everything_(V2X)_5G_в_эволюции_автомобилей) (date of access: 04.06.2025).
12. **Vrubel, Ju. A.** Determination of traffic losses / Ju. A. Vrubel, D. V. Kapski, E. N. Kot. – Minsk : BNTU, 2006. – 240 p. (in Russian).

LIU YUWEI, SARAZHINSKY D.S., KAPSKI D.V.

DEVELOPMENT OF A FLEXIBLE TRAFFIC FLOW MANAGEMENT OPTION FOR ORGANIZING NON-STOP TRAFFIC OF PUBLIC TRANSPORT IN THE AREA OF A CONTROLLED INTERSECTION

*Belarusian National Technical University
Minsk, Republic of Belarus*

Abstract. *The article provides an analysis of existing methods for reducing the likelihood of blocking the movement of public transport vehicles at controlled intersections. On the section of the street and road network in the area of the intersection of Nezavisimosti Avenue – Masherov Avenue – Kozlov Street, flexible control algorithms have been developed to reduce blockages of the movement of route passenger vehicles by other vehicles based on intelligent transport systems, and solutions have been proposed for the use of modern means of traffic light control. Using simulation micro-modeling, an assessment of the effectiveness of the proposed solutions and their efficiency was performed.*

Keywords: *traffic flow, controlled intersection, route vehicle, flexible regulation, control algorithm*



Лю Юйвэй, Белорусский национальный технический университет, Минск, Республика Беларусь. Кафедра «Транспортные системы и технологии», аспирантка.

Liu Yuwei, Belarusian National Technical University, Minsk, Republic of Belarus. Department of Transport Systems and Technologies, postgraduate student.



Саражинский Денис Сергеевич, Белорусский национальный технический университет, Минск, Республика Беларусь. Кандидат физ.-мат. наук, доцент кафедры «Транспортные системы и технологии».

Denis S. Sarazhinsky, Belarusian National Technical University, Minsk, Republic of Belarus. PhD in Physics and Mathematics, Associate Professor of the Department of Transport Systems and Technologies.



Капский Денис Васильевич, Высшая аттестационная комиссия Республики Беларусь, заместитель председателя ВАК, доктор техн. наук, профессор. Профессор кафедры «Транспортные системы и технологии», Белорусский национальный технический университет.

Denis V. Kapski, Higher Attestation Commission of the Republic of Belarus, Vice-chairman HAC, Doctor of Engineering Science, Professor. Professor of the Department of Transport Systems and Technologies, Belarusian National Technical University.

E-mail: d.kapsky@bntu.by, d.kapsky@gmail.com

<https://orcid.org/0000-0001-9300-3857>

**ОБРАБОТКА
ИНФОРМАЦИИ
И ПРИНЯТИЕ РЕШЕНИЙ**

**DATA PROCESSING
AND
DECISION-MAKING**

ХАЙДАРОВ Ш.И.

ОЦЕНКА ЭФФЕКТИВНОСТИ АЛГОРИТМОВ ВЫЯВЛЕНИЯ РАКА С ИСПОЛЬЗОВАНИЕМ СИНТЕТИЧЕСКИХ ДАННЫХ НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ

*Денауский институт предпринимательства и педагогики
Республика Узбекистан*

Аннотация. В данном исследовании проанализировано распределение реальных объектов и синтетически расширенных данных, а также оценено их влияние на модели машинного обучения. Были сопоставлены результаты обучения моделей: *Logistic Regression*, *Decision Tree*, *Random Forest* и *SVM* на синтетических данных с результатами, полученными на датасете реальных объектов. Экспериментальные результаты показали, что использование синтетически расширенных данных способствует повышению точности классификационной модели, причем особенно заметное улучшение наблюдается в некоторых алгоритмах.

Ключевые слова: медицинские объекты, классификация, эвристические алгоритмы, диагностика, искусственный интеллект

Введение

В области искусственного интеллекта и машинного обучения качественные и сбалансированные наборы данных имеют решающее значение при решении задач классификации [1]. Однако на практике часто встречается ситуация, когда некоторые классы представлены недостаточным количеством примеров, что снижает обобщающую способность модели [2]. Эту проблему можно эффективно решить путем создания синтетических обучающих выборок [3].

В данном исследовании проведен анализ распределения реальных объектов и синтетически расширенных данных, а также их оценка на основе четырех основных классификационных моделей [4]: *Logistic Regression*, *Decision Tree*, *Random Forest* и *SVM*. Цель работы – изучить влияние синтетических данных на результаты классификации и провести их сравнение с датасетом реальных объектов [5].

Результаты статистического анализа показали, что, хотя синтетические классы во многом схожи с классами реальных объектов, их распределение имеет значительные различия. Классификационные результаты продемонстрировали улучшение точности моделей при использовании синтетических данных в некоторых случаях [6]. Данные выводы важны для повышения точности моделей машинного обучения и решения проблемы нехватки данных [7].

В медицине правильная классификация объектов играет ключевую роль в эффективной диагностике и лечении пациентов. Поскольку традиционные методы классификации не всегда достаточно эффективны, широко применяются эвристические алгоритмы [8].

В современной медицине алгоритмические методы анализа данных и принятия решений играют важную роль в повышении эффективности диагностики и лечебных процессов. Эвристические алгоритмы активно используются в таких областях, как выявление заболеваний, биомедицинский анализ, обработка медицинских изображений и оптимизация стратегий лечения. Эти алгоритмы позволяют оперативно решать сложные и неопределенные задачи, поскольку основываются на интуитивных принципах принятия решений человеком [1, 2].

Эвристические алгоритмы имеют математическую основу и включают элементы вероятностного анализа, классификации, оптимизации и статистического анализа. Они помогают минимизировать ошибки и повышать точность принятия решений за счет анализа сложных признаков, наблюдаемых человеком. В медицине применение таких методов способствует автоматизации диагностических процессов и персонализации лечения, что повышает качество анализа [3, 4].

В данном исследовании рассматриваются математические модели применения эвристических алгоритмов в медицине. Эти подходы охватывают широкий спектр задач – от диагностики заболеваний до оптимизации стратегий лечения [5, 6].

Анализ литературы

Проблема дисбаланса данных и влияние синтетических обучающих выборок широко освещены в научных исследованиях. В этом разделе рассматриваются ключевые научные источники,

посвященные эффективности синтетических данных в процессе классификации.

Проблема дисбаланса данных.

Дисбаланс данных (imbalance problem) представляет собой серьезную проблему для моделей машинного обучения, так как может приводить к искажению результатов классификации. В исследовании He & Garcia (2009) [1] проанализировано влияние дисбаланса данных на точность модели. Было показано, что неравномерное распределение классов приводит к неправильной классификации редко встречающихся классов.

Методы генерации синтетических обучающих выборок.

Один из самых популярных методов создания синтетических данных – SMOTE (Synthetic Minority Over-sampling Technique). Данный подход, предложенный Chawla et al. (2002 [2]), доказал свою эффективность в улучшении результатов классификации за счет генерации новых образцов для редко встречающихся классов.

Кроме того, разработанные Goodfellow et al. (2014) [3] генеративно-состязательные сети (GANs) получили широкое распространение в создании высококачественных синтетических данных. Метод GANs позволяет искусственно генерировать данные в различных форматах, включая изображения и текст.

Влияние синтетических данных на классификацию.

Модели, такие как Logistic Regression, Decision Tree и, Random Forest, по-разному реагируют на синтетические данные. В исследованиях Fernandez et al. (2018) [4] было установлено, что добавление синтетических данных дало наилучшие результаты для модели Random Forest, в то время как для SVM улучшения наблюдались реже.

Проблема нехватки данных особенно актуальна в области медицинской диагностики. В исследовании Liu et al. (2020) [5] показано, что использование синтетических данных значительно повышает точность моделей, применяемых в медицинской классификации.

Выводы анализа литературы.

– Синтетические данные особенно полезны для несбалансированных датасетов и улучшают точность моделей.

– Методы SMOTE и GANs являются эффективными подходами для генерации синтетических данных.

– Добавление синтетических данных повышает точность моделей Random Forest и Logistic Regression, тогда как для SVM улучшения не всегда наблюдаются.

Принципы работы алгоритмов, математические формулы, преимущества и недостатки

1. Logistic Regression.

Логистическая регрессия – это алгоритм классификации, основанный на сигмоидной функции. Для заданного входного вектора X вероятность определяется следующим образом:

$$P(Y = 1|X) = \frac{1}{1 + e^{-(\omega_0 + \omega_1 X_1 + \omega_2 X_2 + \dots + \omega_n X_n)}}.$$

Здесь $P(Y=1 | X)$ – вероятность принадлежности к классу 1, ω_i – коэффициенты весов, X_i – входные признаки. Сигмоидная функция обладает нелинейным характером и нормализует выходное значение в диапазоне $[0, 1]$.

Функция потерь. Логистическая регрессия использует функцию потерь на основе средней кросс-энтропии [9]:

$$J(\omega) = -\frac{1}{m} \sum_{i=1}^m [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)].$$

Здесь y_i – фактическое значение, \hat{y}_i – предсказанное значение, m – общее количество образцов.

Рассмотрим их преимущества следующим образом: они отличаются легкостью интерпретации, удобством вероятностного вывода и хорошей работой на небольших наборах данных.

Конечно, есть и недостатки: они плохо справляются с нелинейными задачами и чувствительны к выбросам, что может привести к ошибкам.

2. Decision Tree.

Дерево решений основано на принципе ветвления, где каждый узел делит данные по определенному признаку. Построение дерева основано на критериях индекса Джини или энтропии [8].

Индекс Джини. Для измерения чистоты узла индекс Джини рассчитывается следующим образом:

$$Gini(D) = 1 - \sum_{i=1}^C p_i^2.$$

Здесь p_i – вероятность принадлежности к классу i , C – количество классов. Если все образцы принадлежат одному классу, то $Gini = 0$ (идеальное разделение).

Энтропия. В качестве альтернативной меры используется энтропия Шеннона, которая вычисляется по следующей формуле:

$$H(D) = -\sum_{i=1}^C p_i^2 \log_2 p_i.$$

Если все образцы принадлежат одному классу, энтропия будет равна 0.

Рассмотрим следующие преимущества: возможность легкой и удобной интерпретации, работа с категориальными и числовыми данными, устойчивость к шуму.

Конечно, есть и недостатки: проблема переобучения (overfitting), чувствительность на начальном этапе (требуется pruning).

3. Random Forest.

Random Forest – это ансамблевый метод, который берет средний результат нескольких Decision Trees. Он использует метод Bagging (bootstrap aggregation). Каждое Decision Tree обучается на Bootstrap Sample, а итоговый результат получается следующим образом.

Для классификации используется голосование, выраженное следующей формулой:

$$\hat{y} = \arg \max_k \sum_{t=1}^T I(h_t(X) = k).$$

Здесь T – количество деревьев, h_t – предсказание t -го дерева, I – индикаторная функция.

Для регрессии среднее значение рассчитывается по следующей формуле:

$$\hat{y} = 1/T \sum_{t=1}^T h_t(X).$$

Рассмотрим следующие преимущества: снижает проблему переобучения (overfitting); хорошо работает с большими наборами данных; отличается устойчивостью к шуму [10].

Конечно, есть и недостатки: при использовании большого количества деревьев скорость работы снижается, а интерпретация модели становится сложнее.

4. Метод опорных векторов (Support Vector Machine, SVM).

Находит оптимальную гиперплоскость для разделения классов. Если заданные данные линейно разделимы, используются следующие формулы:

$$\omega^T x + b = 0.$$

При этом правило оптимальной гиперплоскости, его можно выразить следующим образом [11]: $\max 2/|\omega|$.

5. Kernel trick.

Ядерные методы в машинном обучении – это класс алгоритмов распознавания образов, наиболее известным представителем которого является метод опорных векторов или SVM.

Если данные нелинейно разделимы, применяется ядерное преобразование. Рассмотрим наиболее популярные ядерные функции.

Математическое выражение полиномиального ядра имеет следующий вид:

$$K(x_i, x_j) = (x_i^T x_j + c)^d.$$

Математическое выражение ядра с радиальной базисной функцией (Radial Basis Function, RBF) имеет следующий вид:

$$K(x_i, x_j) = \exp(-\gamma \|x_i + x_j\|^2).$$

Рассмотрим следующие преимущества: хорошо справляется с нелинейными задачами, редко подвержен переобучению (overfitting) и обеспечивает качественный анализ результатов.

Конечно, есть и недостатки: медленная работа на больших наборах данных, необходимость настройки гиперпараметров, что может привести к искажению результатов [12].

В данном исследовании были проанализированы математические основы, принципы работы и преимущества алгоритмов Logistic Regression, Decision Tree, Random Forest и SVM. Эти алгоритмы широко применяются в медицинской диагностике, предсказательном анализе и в области искусственного интеллекта.

Генерация синтетического обучающего набора

Расширение данных (data augmentation) и генерация синтетических данных часто используются для решения проблемы несбалансированных выборок или нехватки данных. Существует несколько методов создания синтетических обучающих выборок, среди которых:

- SMOTE (Synthetic Minority Over-sampling Technique);
- GAN (Generative Adversarial Networks);
- VAE (Variational Autoencoders);
- Random Noise Injection.

Поскольку мы работаем с медицинскими изображениями, методы GAN и VAE считаются эффективными для создания синтетических образцов. Используя эти методы, мы расширим наш датасет на основе синтетической обучающей выборки.

Далее рассмотрим оценку классифицированных объектов.

После создания синтетической обучающей выборки ее необходимо сравнить с уже существующими классифицированными объектами. Для этого используются следующие метрики оценки:

- показатели классификации (F1-score, Precision, Recall, Accuracy);
- оценка производительности (ROC-AUC);
- меры ранговой корреляции, такие как Kendall's tau и Spearman's rho.

Основной результат исследования – создание синтетической выборки и ее сравнение с реальными данными. Если результаты синтетической выборки схожи с реальной, этот метод можно использовать для расширения данных. В противном случае синтетические данные необходимо улучшить [13].

Таблица отображает степень сходства между реальными и синтетическими объектами в разных классах в процентном выражении:

– Количество объектов – количество реальных объектов в каждом классе.

– Сходство (%) – средний процент сходства реальных объектов в классе. Чем выше этот показатель, тем ближе синтетический класс к реальному.

– Количество синтетических объектов – количество объектов в синтетических классах.

– Синтетическое сходство (%) – средний процент сходства для синтетических классов. В идеале этот показатель должен стремиться к 100%.

– Разница (%) – разница между реальными и синтетическими классами. Чем выше это значение, тем больше различие между реальными и синтетическими классами.

Результаты анализа показывают следующее.

– Для классов 1, 2, 4, 7, 8, 12 синтетические классы полностью соответствуют реальным (разница 0 %).

– Класс 6 демонстрирует наибольшее расхождение (100 %), что указывает на значительное отличие синтетического класса от реального.

– Классы 3, 5, 9, 10, 11, 13 также имеют заметные различия, что говорит о том, что синтетические данные не полностью соответствуют реальным классам.

Приведем код на Python, который оценивает процент классификации реальных и синтетически расширенных объектов, используя Logistic Regression, Decision Tree, Random Forest и SVM.

Таблица 1.

Класс	Количество объектов	Сходство (%)	Количество синтетических объектов	Синтетическое сходство (%)	Разница (%)
1	42	100.00	42	100.00	0.00
2	61	100.00	61	100.00	0.00
3	28	67.92	50	100.00	32.08
4	14	100.00	14	100.00	0.00
5	29	57.68	51	100.00	42.32
6	11	0.00	33	100.00	100.00
7	237	100.00	237	100.00	0.00
8	71	100.00	71	100.00	0.00
9	19	48.19	41	100.00	51.81
10	8	48.05	29	100.00	51.95
11	3	18.93	29	100.00	81.07
12	40	100.00	40	100.00	0.00
13	4	34.53	27	100.00	65.47
Общее количество объектов	567	875.30	725	1300.00	424.70

Результаты оценки введенных в программу объектов представлены следующим образом. Данные экспериментально-испытательные результаты направлены на оценку эффективности реальных и синтетически увеличенных объектов, включая количество объектов, принадлежащих различным классам, степень их

сходства и изменения после добавления синтетических объектов. Как видно из таблицы, уровень сходства оценивался с использованием алгоритмов Logistic Regression, Decision Tree, Random Forest и SVM по таким показателям, как точность, чувствительность, F1-score и уровень достоверности [14].

Таблица 2.

Алгоритм		Precision	Recall	F1-	Accuracy		Precision	Recall	F1-score	Accuracy
		Точность	Чувствительность	score	Уровень достоверности		Точность	Чувствительность	score	Уровень достоверности
Результаты Logistic Regression	Реальные объекты	88,22	90,05	88,89	90,05	Синтетически дополненные	94,53	94,03	93,86	94,03
Результаты Decision Tree		92,35	91,81	91,77	91,81		93,73	92,20	92,42	92,20
Результаты Random Forest		91,76	91,81	91,16	91,81		94,77	94,03	93,97	94,03
Результаты Support Vector Machine (SVM)		88,24	90,05	88,16	90,05		89,49	89,44	89,13	89,44

```
import numpy as np
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.metrics import precision_score, recall_score, f1_score, accuracy_score
from sklearn.ensemble import RandomForestClassifier
from sklearn.tree import DecisionTreeClassifier
from sklearn.svm import SVC
from sklearn.linear_model import LogisticRegression
from sklearn.preprocessing import LabelEncoder
from tkinter import Tk, filedialog
# ✎ CSV faylni tanlash
def load_file():
    root = Tk()
    root.withdraw()
    return filedialog.askopenfilename(title="CSV faylni tanlang", filetypes=[("CSV fayllar",
"* .csv")])
# ✎ CSV yuklash va optimallashtirish
def load_and_prepare_csv(file_path):
    if not file_path:
        print("✗ Xatolik: Fayl tanlanmadi!")
        exit()
    try:
        df = pd.read_csv(file_path, sep=None, engine='python', encoding="utf-8").dropna(axis=1,
how="all")
    except Exception as e:
        print(f"✗ Xatolik: CSV faylni yuklab bo'lmadi!\n{e}")
        exit()
    # Target ustunni olish va shovqinlarni olib tashlash
    y = df.iloc[:, -1]
    if y.dtype in [np.float64, np.float32]:
```

```

    y = y.astype(int)
    # Kategorik ustunlarni avtomatik raqamlashtirish
    X = df.iloc[:, :-1].apply(lambda col: LabelEncoder().fit_transform(col) if col.dtype == 'object'
else col).values
    return X, y
# ✨ Faylni tanlash va tayyorlash
file_path = load_file()
X, y = load_and_prepare_csv(file_path)
# ✨ Train-test bo'linishi
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
# ✨ Model natijalarini baholash
def evaluate_model(name, model):
    model.fit(X_train, y_train)
    y_pred = model.predict(X_test)
    return {
        "Model": name,
        "Precision": precision_score(y_test, y_pred, average='weighted', zero_division=0),
        "Recall": recall_score(y_test, y_pred, average='weighted', zero_division=0),
        "F1-score": f1_score(y_test, y_pred, average='weighted', zero_division=0),
        "Accuracy": accuracy_score(y_test, y_pred)
    }
# ✨ Model ro'yxati (avtomatik ro'yxat)
models = {
    "Logistic Regression": LogisticRegression(max_iter=1000, n_jobs=-1),
    "Decision Tree": DecisionTreeClassifier(),
    "Random Forest": RandomForestClassifier(n_estimators=100, random_state=42, n_jobs=-1),
    "SVM": SVC()
}
# ✨ Barcha modellarni parallel baholash
results = [evaluate_model(name, model) for name, model in models.items()]
# ✨ Natijalarni chiqarish

df_results = pd.DataFrame(results)
print("\n Model Natijalari:")
print(df_results.to_string(index=False))
# ✨ CSV faylga saqlash
df_results.to_csv("model_results.csv", index=False)
print("\n Natijalar 'model_results.csv' fayliga saqlandi.")

```

Данные таблицы показывают, что модели, обученные с синтетически дополненными классами, работали немного лучше по сравнению с моделями, обученными на реальных объектах. Random Forest и Logistic Regression показали высокие результаты на синтетическом датасете. Модель SVM немного лучше работала на датасете реальных объектов, но на синтетическом

датасете также показала почти аналогичный результат [15].

Синтетические данные улучшают модель, особенно для Logistic Regression и Random Forest, где были достигнуты более высокие показатели. Эти результаты демонстрируют, что использование синтетических данных способствует улучшению процесса обучения модели.



Реальные объекты и синтетически дополненные объекты: статистический анализ

Рисунок 1. Изменение средней степени сходства объектов классов

Для сравнительной оценки надежности разработанного алгоритма была проведена классификация реальных объектов и гибридной обучающей выборки с использованием популярных методов машинного обучения. Уровни распознавания каждого класса с помощью четырех различных методов подробно представлены в Таблице 2 [16].

Заключение

В данном исследовании была оценена эффективность диагностики рака молочной железы с помощью гибридной модели классификации, основанной на искусственном интеллекте. Анализ данных и результаты моделирования показали, что

предложенный подход достигает более высокой точности по сравнению с традиционными методами.

Кроме того, за счет глубокого анализа неправильно классифицированных объектов был создан новый синтетический обучающий набор, что повысило стабильность модели и её способность к обобщению.

Результаты исследования демонстрируют, что использование гибридных моделей может иметь важное значение в ранней диагностике рака молочной железы. В будущем необходимо дальнейшее совершенствование данного подхода и его тестирование в различных клинических условиях. Также рекомендуется использовать более широкий и разнообразный набор данных для повышения чувствительности и точности модели.

REFERENCES

1. He, H. Learning from imbalanced data / Haibo He, Edwardo A. Garcia // IEEE Transactions on Knowledge and Data Engineering. – 2009. – Vol. 21, Iss. 9. – P. 1263–1284. – DOI: 10.1109/TKDE.2008.239
2. SMOTE: synthetic minority over-sampling technique / N. V. Chawla, K. W. Bowyer, L. O. Hall, W. P. Kegelmeyer // Journal of Artificial Intelligence Research. – 2002. – Vol. 16. – P. 321–357. – DOI: 10.1613/jair.953
3. Generative Adversarial Networks / Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza [et al.] // Proceedings of the 27th International Conference on Neural Information Processing Systems. – 2014. – P. 2672–2680. – DOI: 10.48550/arXiv.1406.2661
4. SMOTE for learning from imbalanced data: progress and challenges, marking the 15-year anniversary / Alberto Fernandez, Salvador Garcia, Francisco Herrera, Nitesh V. Chawla // Journal of Artificial Intelligence Review. – 2018. – Vol. 61. – P. 863–905. – DOI: 10.1613/jair.1.11192

5. Liu, B., Ding, H., & Wang, Y. (2020). "Synthetic Data Augmentation for Medical Diagnosis". IEEE Transactions on Biomedical Engineering.
6. J. Smith, "Medical Classification Systems". Journal of AI in Medicine, 2020.
7. R. Brown, "Heuristic Algorithms in Diagnosis". Medical Informatics Review, 2019.
8. Nishanov, A. Modification of decision rules "ball Apolonia" the problem of classification / A.X. Nishanov, O.B. Ruzibaev, Nguyen H. Tran // 2016 International Conference on Information Science and Communications Technologies (ICISCT). – Tashkent, Uzbekistan, 2016 – DOI: 10.1109/ICISCT.2016.7777382
9. Nishanov, A. Analysis of methodology of rating evaluation of digital economy and e-government development in Uzbekistan / Akhram Khasanovich Nishanov, Saidrasulov Sherzod Norboy o'g'li, Babadjanov Elmurad Satimbaevich // International Journal of Early Childhood Special Education. – 2022. – Vol. 14, iss. 2. – P. 2447–2452. – DOI: 10.9756/INT-JECSE/V14I2.230
10. Algorithm for the selection of informative symptoms in the classification of medical data / A. Kh. Nishanov, O. B. Ruzibaev, J. C. Chedjou [et al.] // Developments of Artificial Intelligence Technologies in Computation and Robotics. – 2020. – P. 647–658. – DOI: 10.1142/9789811223334_0078
11. Nishanov, A.Kh. A decisive rule in classifying diseases of the visual system / A. Kh. Nishanov, A. Kh. Turakulov, Kh. V. Turakhanov // Meditsinskaia tekhnika. – 1999. – Iss. 4, July – August. – P. 16-18. – Article in Russian.
12. Clustering algorithm based on object similarity / A. Kh. Nishanov, V. Kh. Akbarova, A. T. Tursunov [et al.] // Journal of Mathematics, Mechanics and Computer Science. – 2024. – Vol. 123, № 3. – P. 108–120. – DOI: 10.26577/JMMCS2024-v123-i3-4
13. Stages of Preparing Symptoms of Breast Cancer for Machine Learning / Nishanov Akhram Khasanovich, Mamajanov Raxmatilla Yakubjanovich, Xaydarov Sherali Islom o'g'li [et al.] // Digital Transformation and Artificial Intelligence. – 2024. – Vol. 2, Iss. 6. – P. 237–249. – DOI: <https://dtai.tsue.uz/index.php/dtai/article/view/v2i633>
14. Stages of Forming Symptoms Used in the Diagnosis of Endocrine Diseases". / Nishanov Akhram Khasanovich, Mengturayev Farxod Ziyatovich, Allayarov Uktamjon Bektashovich, Xaydarov Sherali Islom o'g'li // Digital Transformation and Artificial Intelligence. – 2024. – Vol. 2, № 6. – P. 228–236. – DOI: <https://dtai.tsue.uz/index.php/dtai/article/view/v2i632>
15. Diagnostic algorithm for early detection of breast cancer based on error minimization approach / Nishanov Akhram Khasanovich, Mamazhanov Rakhmatilla Yakubzhanovich, Khaidarov Sherali Islom o'g'li [et al.] // International Journal of Innovative Science and Research Technology (IJISRT). – 2024. – Vol. 9, Iss. 12. – P. 1535–1542. – DOI: 10.5281/zenodo.14565218
16. The Importance of Early Detection of Cancer Diseases and Methods and Algorithms Based on Modern Technologies / Nishanov Akhram Khasanovich, Mamajanov Raxmatilla Yakubjanovich, Xaydarov Sherali Islom o'g'li, Mengturayev Farxod Ziyatovich // Digital Transformation and Artificial Intelligence. – 2025. – Vol. 3, № 1. – P. 110–117. – DOI: <https://dtai.tsue.uz/index.php/dtai/article/view/v3i117>

KHAYDAROV SHERALI ISLOMOVICH

ASSESSING THE EFFICIENCY OF THE CANCER DETECTION ALGORITHMS USING SYNTHETIC DATA BASED ON MACHINE LEARNING

*Denau Institute of Entrepreneurship and Pedagogy
Republic of Uzbekistan*

Abstract. *This study analyzes the distribution of real objects and synthetically augmented classes, as well as their impact on machine learning models. The training results of logistic regression, decision trees, random forest, and SVM models on synthetic data were compared with those obtained on a dataset of real objects. Experimental results showed that the use of synthetically augmented data improves the accuracy of classification models, with particularly noticeable improvements observed in some algorithms.*

Keywords: *medical objects, classification, heuristic algorithms, diagnosis, artificial intelligence*



Хайдаров Шерали Исламович, Денауский институт предпринимательства и педагогики (ДТПИ), Республика Узбекистан. Преподаватель кафедры информационных технологий.

Sherali Islomovich Khaydarov, Denau Institute of Entrepreneurship and Pedagogy (DTPI), Republic of Uzbekistan. Lecturer at the Department of Information Technologies.

E-mail: sh.haydarov@dtpi.uz

ORCID: 0000-0002-2514-3329

**ЗАЩИТА
ИНФОРМАЦИИ**

**INFORMATION
SECURITY**

ГОЛИКОВ В.Ф., РАДЮКЕВИЧ М.Л., ШУЛЯК Д.В.

ДВУХСТОРОННЯЯ АТАКА НА СИНХРОНИЗИРУЕМЫЕ ИСКУССТВЕННЫЕ НЕЙРОННЫЕ СЕТИ, ФОРМИРУЮЩИЕ ОБЩИЙ СЕКРЕТ

Научно-производственное республиканское унитарное предприятие
«Научно-исследовательский институт технической защиты информации»
г. Минск, Республика Беларусь

Аннотация. Рассматривается уязвимость технологии формирования общего криптографического ключа с помощью синхронизируемых искусственных нейронных сетей (ИНС) относительно нового типа атаки, названной двухсторонней. Суть атаки заключается в том, что криптоаналитик, прослушивая открытый канал связи, создает для этого две идентичные искусственные нейронные сети, одну из которых он синхронизирует с сетью одного из легальных абонентов, а вторую – с сетью другого легального абонента. Сравнивая вектора весовых коэффициентов атакующих сетей, криптоаналитик имеет возможность определить момент наступления полной синхронизации сетей легальных абонентов и значение сформированного секретного числа. Далее исследуются возможности двухсторонней атаки при различных моделях формирования секретного числа.

Ключевые слова: синхронизируемые искусственные нейронные сети, атака, общий криптографический ключ, отложенный перебор

Введение

В работах [1-4] излагается технология формирования общего секретного ключа шифрования у абонентов, имеющих аутентифицированный открытый канал связи. Технология основывается на использовании синхронизируемых искусственных нейронных сетей ТРМ структуры (рисунок 1).

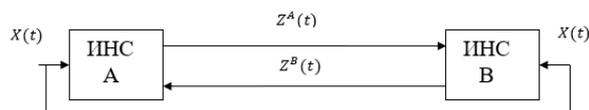


Рисунок 1. Схема синхронизации ИНС

На этом рисунке: ИНС А, ИНС В – искусственные нейронные сети абонентов А и В, формирующие общий криптографический ключ; $X(t)$ – вектор синхронизирующих случайных воздействий, t – номер такта синхронизации, $Z^A(t)$, $Z^B(t)$ – выходные величины сетей А и В соответственно. Архитектура и параметры всех сетей идентичны и представлены на рисунке 2.

Каждый персептрон имеет n входов, на каждый из которых поступает случайное число $x_{ij}(t) \in [-1, 1]$ (одна из компонент $X(t)$, где $j = 1, 2, \dots, n$; $i = 1, 2, \dots, K$). Каждый персептрон описывается вектором весовых коэффициентов $W_i(t)$ с компонентами $w_{ij}(t) \in [-L, L]$, где L – целое положительное число. Выходные величины персептронов $Y_i(t) \in [-1, 1]$ перемножаются и образуют выходные значения сетей $Z(t) \in [-1, 1]$.

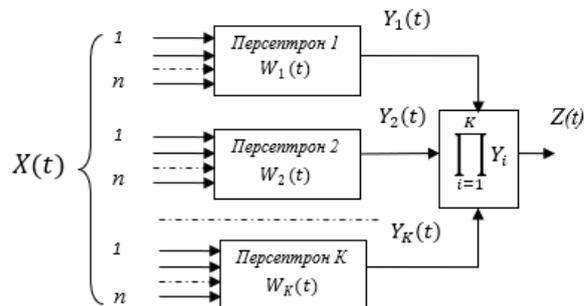


Рисунок 2. Структура ИНС

Начальные значения весовых коэффициентов персептронов сетей А и В: $W^A(0), W^B(0)$, где $W(0) = W_1(0) \| W_2(0) \| \dots \| W_K(0) \|$ выбираются абонентами случайно, независимо друг от друга и сохраняются в секрете. Подавая синхронно на входы своих сетей вектор $X(t)$, абоненты А и В вычисляют выходные величины сетей $Z^A(t)$ и $Z^B(t)$, обмениваются ими и корректируют значения весовых коэффициентов персептронов своих сетей таким образом, что через некоторое число тактов t_{AB} наступает равенство векторов весовых коэффициентов $W^A(t_{AB}) = W^B(t_{AB})$. Значение полученного вектора и является общим секретным числом для А и В. Поскольку величина t_{AB} является случайной и неизвестной, то абоненты А и В заранее договариваются о длительности синхронизации d , так чтобы с большой вероятностью выполнялось условие $t_{AB} \leq d$.

Односторонняя атака

Если третий абонент E имеет возможность прослушивать канал связи и пытается вычислить сформированный секрет, то ему необходимо подключить к каналу связи свою сеть с параметрами, идентичными параметрам сети A или B , за исключением начальных значений весовых коэффициентов персептронов, которые для E неизвестны, и попытаться синхронизировать свою сеть с сетью A или B . Такую атаку будем называть односторонней. Схема данной атаки представлена на рисунке 3.

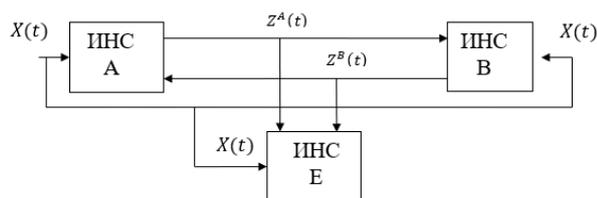


Рисунок 3. Односторонняя атака

Атакующая сеть E , используя значения $X(t)$, вычисляет $Z^E(t)$ и сравнивает его с перехваченными $Z^A(t)$ и $Z^B(t)$, корректирует значения весовых коэффициентов персептронов своей сети по определенному алгоритму и через некоторое число тактов t_{EA} добивается равенства

$$W^E(t_{EA}) = W^A(t_{EA}). \quad (1)$$

В зависимости от выбранного абонентом E алгоритма коррекции различают несколько видов атак. Наиболее эффективной считается «геометрическая атака» [3]. Исследования показали, что независимо от вида атаки обеспечивается

$$P(t_{AB} \leq d) > P(t_{EA} \leq d). \quad (2)$$

Выражение (2), однако, совсем не означает, что в процессе атаки обязательно произойдет событие $(t_{AB} \leq d, t_{EA} \leq d)$, т.е. будет иметь место успешная атака, что приведет к выполнению (1). Тем не менее в статье [5] показано, что любой выбранный тип атаки, реализованный в отложенном варианте, будет успешным при сравнительно небольших затратах вычислительных мощностей. Этот тип атак назван «отложенный перебор». Суть метода заключается в том, что абонент E , прослушивая канал связи между A и B , запоминает значения $X(t)$, $Z^A(t)$, $Z^B(t)$, d и организует многократное повторение синхронизаций своей сети с сетью A или B . Причем легальная сеть в каждой синхронизации повторяется в соответствии с записанными параметрами, а злоумышленная сеть меняет начальные значения вектора весовых коэффициентов $W^E(0)$. В работе [5] показано, что необходимый объем отложенного моделирования (количество моделируемых синхронизаций) равен

$$m = \frac{\ln(1-\gamma)}{\ln(1-P_{EA}^1)},$$

где $P_{EA}^1 = P(t_{EA} \leq d)$ – вероятность успешной синхронизации сети E в одной попытке, γ – вероятность того, что из m проведенных синхронизаций хотя бы одна закончилась успешно (вероятность γ задается близкой к 1). Как показывают практические расчеты, объем отложенного перебора относительно невелик. Например, при $P_{EA}^1 = 10^{-4}$ и $\gamma = 0,98$ имеем $m \approx 3,9 \cdot 10^4$.

Для обеспечения более высокой секретности формируемого общего ключа против этой атаки в статье [6] предлагается способ усиления секретности, основанный на интеграции результатов многократных синхронизаций (ИМС). Суть метода [6] заключается в том, что A и B проводят r синхронизаций, не проверяя успех каждой синхронизации. В качестве итоговой секретной бинарной последовательности используют свертку полученных r последовательностей. В качестве свертки можно использовать побитовое сложение соответствующих битов этих последовательностей. Абонент E , не имея хэш-значение результата отдельно взятой синхронизации, не может произвести проверку правильного результата отложенного перебора в отношении каждой синхронизации, а только в отношении свертки r синхронизаций (интегрированного результата r синхронизаций), хэш-значение которой оглашается абонентами A и B . Поэтому E вынужден, осуществляя перебор в отношении совокупности из r синхронизаций, проверять идентичность полученного результата с объявленным хэш-значением. Вероятность успеха при этом в каждой i -той синхронизации равна P_{EAi}^1 , а в отношении свертки $P_{EA,r} = \prod_{i=1}^r P_{EAi}^1 = (P_{EA}^1)^r$, а объем моделирования при этом равен

$$m = \frac{\ln(1-\gamma)}{\ln(1-(P_{EA}^1)^r)}. \quad (3)$$

Из (3) следует, что объем отложенного моделирования экспоненциально возрастает с ростом r . В рассмотренном ранее численном примере $P_{EA}^1 = 10^{-4}$ и $\gamma = 0,98$, $r = 10$ имеем $m \approx 10^{40}$.

Этот способ демонстрирует надежную безопасность формируемого ключа по отношению к атаке «отложенный перебор» и стимулирует поиск новых методов взлома.

Двухсторонняя атака

В данной статье рассматривается новый тип атак, названный двухсторонней атакой. Схема данной атаки представлена на рисунке 4.

Для реализации этой атаки абонент E строит две ИНС: ИНС E_1 и ИНС E_2 . Параметры этих сетей должны быть идентичны параметрам сетей ИНС A и ИНС B за исключением векторов весовых коэффициентов, которые выбраны случайно и независимо друг от друга и равны: $W^A(0)$, $W^B(0)$, $W^{E1}(0)$, $W^{E2}(0)$. A и B синхронизируют свои сети за время d , проверяют равенство весовых коэффициентов

$W^A(d) = W^B(d)$ сравнением хэш-значений этих чисел и успешно заканчивают процесс, при этом $W^A(d) = W^B(d) = W^{AB}(d)$, где $W^{AB}(d)$ – общий секретный ключ. Абонент E организует атаку «отложенный перебор» двумя сетями E_1 и E_2 . При этом он синхронизирует сеть E_1 с сетью А, а сеть E_2 с сетью В. В процессе синхронизации абонент E сравнивает значения весовых коэффициентов своих сетей между собой, т.е. проверяет равенство $W^{E1}(t) = W^{E2}(t)$. Если на момент d окажется, что: $W^{E1}(d) = W^{E2}(d)$, а это видно прямым сравнением векторов $W^{E1}(d), W^{E2}(d)$

на стороне E , то это означает, что $W^{E1}(d) = W^A(d)$, а $W^{E2}(d) = W^B(d)$. Следовательно, $W^A(d) = W^B(d)$, $W^{E1}(d) = W^{E2}(d) = W^{AB}(d)$. Т.е. сформированный секретный ключ известен абоненту E . Графически рассматриваемый процесс представлен на рисунке 5. На этом рисунке показаны условные траектории изменения векторов весовых коэффициентов сетей A, B, E_1, E_2 в процессе синхронизации. Изображена ситуация, при которой произошла синхронизация сетей E_1 с A, E_2 с B и A с B , т.е. $t_{E1A} \leq d, t_{E2B} \leq d, t_{AB} \leq d$.

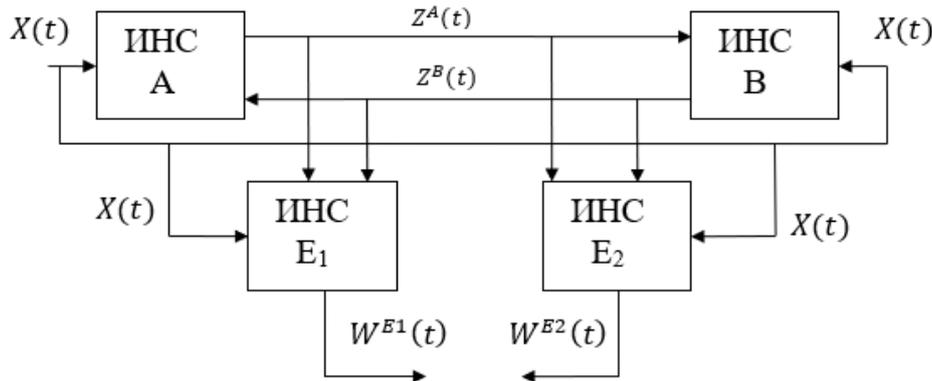


Рисунок 4. Двухсторонняя атака

Если синхронизм E_1 с A и E_2 с B за d тактов не достигнут, то абонент E меняет начальные значения весовых коэффициентов своих сетей: $W^{E1}(0)$ и $W^{E2}(0)$ и повторяет синхронизацию, как предусматривает атака «отложенный перебор».

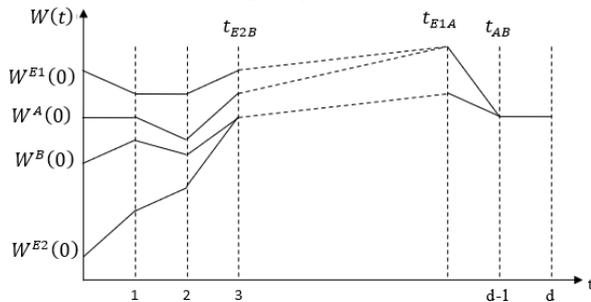


Рисунок 5. Траектории изменения векторов весовых коэффициентов сетей в процессе синхронизации

При атаке одной сетью E_1 вероятность успешной синхронизации абонентов E_1 с A в одной попытке равна

$$P^1_{E1A} = P(t_{E1A} < d).$$

При атаке двумя сетями вероятность успешной синхронизации абонентов E_1 с A и E_2 с B и как итог обнаружение синхронизации E_1 с E_2 в одной попытке равна

$$P^1_{E1E2} = P(t_{E1A} < d, t_{E2B} < d).$$

Так как $P^1_{E1E2} = P(t_{E1A} < d)P(t_{E2B} < d / t_{E1A} < d)$, где второй множитель есть условная вероятность, то следует, что вероятность успешной атаки двух сетей меньше, чем одиночной атаки. Эта вероятность тем меньше, чем меньше корреляция $W^{E1}(t)$ с $W^{E2}(t)$. При слабой корреляции можно считать, что $P(t_{E2B} < d / t_{E1A} < d) \approx P(t_{E2B} < d)$, а так как $P(t_{E1A} < d) \approx P(t_{E2B} < d)$, то $P^1_{E1E2} = P^2(t_{E1A} < d) = P^2(t_{E2B} < d)$.

Это делает применение двухсторонней атаки не актуальным для E , тем более, что одиночная атака позволяет E добиваться дискредитации формируемого секретного ключа после относительно небольшого объема моделирования, как было показано выше.

Рассмотрим далее эффективность двухсторонней атаки против метода ИМС.

При двухсторонней атаке согласно её алгоритму у абонента E появляется возможность осуществлять атаку отложенного перебора относительно каждой синхронизации A с B в отдельности до полного успеха. Для этого E имеет записанные параметры атакуемой синхронизации A с B : $X(t), Z^A(t), Z^B(t), d$ и критерий останковки моделирования в нужный момент, при котором $W^A(d) = W^B(d)$. Как указывалось выше, абонент E , сравнивая значения весовых коэффициентов своих сетей между собой, т.е. проверяя равенство $W^{E1}(t) = W^{E2}(t)$, обнаруживает наступление $W^{E1}(d) = W^A(d), W^{E2}(d) = W^B(d)$, а значит и $W^{E1}(d) = W^{E2}(d) = W^{AB}(d)$.

Такой критерий отсутствует при односторонней атаке. Таким образом, абонент E успешно атакует каждую i -тую синхронизацию A с B . Объём моделирования при этом равен:

$$m_i = \frac{\ln(1-\gamma)}{\ln(1-P_{E1E2}^1)}, \text{ где } P_{E1E2}^1 = P(t_{E1A} < d)P(t_{E2B} < d) \approx (P_{EA}^1)^2.$$

При атаке на r синхронизаций суммарный объём моделирования равен:

$$M = \sum_{i=1}^r m_i = \sum_{i=1}^r \frac{\ln(1-\gamma)}{\ln(1-P_{E1E2}^1)}.$$

Считая $m_1 = m_2 = m_3 = \dots = m_r = m$, получим

$$M = r \frac{\ln(1-\gamma)}{\ln(1-P_{E1E2}^1)}.$$

Т.е. объём атакующего моделирования при двухсторонней атаке на метод ИМС зависит от r линейно, что указывает на более высокую эффективность этой атаки по сравнению с односторон-

ней атакой. В рассматриваемом численном примере $P_{EA}^1 = 10^{-4}$ и $\gamma = 0,98$, $r = 10$ имеем $P_{E1E2}^1 \approx (P_{EA}^1)^2$, $M \approx 3,9 \cdot 10^9$. Т.е. объём атакующего моделирования при двухсторонней атаке меньше, чем необходимый объём атакующего моделирования при односторонней атаке примерно в 10^{30} раз.

Возможно, что методы формирования общего секретного числа, использующего технологию синхронизируемых искусственных нейронных сетей, изложенные в [7, 8], окажутся более безопасными к двухсторонней атаке, однако это требует дополнительных исследований.

Заключение

Таким образом, двухсторонняя атака на процесс формирования общего секретного числа, использующего технологию ИМС, может существенно снизить её защищенность и требует дополнительного усиления безопасности применяемых методов.

ЛИТЕРАТУРА

1. **Kanter, I.** The Theory of Neural Networks and Cryptography / Ido Kanter, Wolfgang Kinzel // The Physics of Communication. – 2003. – P. 631–642. – DOI: 10.1142/9789812704634_0044
2. **Kinzel, W.** Neural Cryptography / W. Kinzel, I. Kanter // ICONIP'02 : proc. of the 9th Intern. Conf. on Neural Information Processing, Nov. 18–22, 2002, Orchid Country Club, Singapore. – Singapore, 2002. – Vol. 3. – P. 1351–1354. – DOI: 10.1109/ICONIP.2002.1202841.
3. **Ruttor, A.** Dynamics of neural cryptography / A. Ruttor, I. Kanter, W. Kinzel // Physical Review E – Statistical, Nonlinear, and Soft Matter Physics. – 2007. – Vol. 75, iss. 5. – P. 056104.
4. **Урбанович, П.П.** Использование гиперкомплексных чисел в протоколе согласования криптографических ключей на основе нейронных сетей / П.П. Урбанович, Н.П. Шутько // Журнал Белорусского государственного университета. Математика. Информатика. – 2024. – № 2. – С. 81–92.
5. **Голиков, В.Ф.** Атака на синхронизируемые искусственные нейронные сети, формирующие общий секрет, методом отложенного перебора / В.Ф. Голиков, А.Ю. Ксеневиц // Доклады БГУИР. – 2017. – № 8. – С. 48–53.
6. **Радюкевич, М.Л.** Усиление секретности криптографического ключа, сформированного с помощью синхронизируемых искусственных нейронных сетей / М.Л. Радюкевич, В.Ф. Голиков // Информатика. – 2020. – Т. 17, № 1. – С. 102–108. – DOI: 10.37661/1816-0301-2020-17-1-102-108
7. **Радюкевич, М.Л.** Комбинированный метод формирования криптографического ключа с помощью синхронизируемых искусственных нейронных сетей / М.Л. Радюкевич, В.Ф. Голиков // Доклады БГУИР. – 2021. – Т. 19, № 1. – С. 79–87. – DOI: 10.35596/1729-7648-2021-19-1-79-87
8. **Радюкевич, М.Л.** Комбинированный метод формирования криптографического ключа с секретной модификацией результатов синхронизации искусственных нейронных сетей / М.Л. Радюкевич // Системный анализ и прикладная информатика. – 2021. – № 3. – С. 51–58. – DOI: 10.21122/2309-4923-2021-3-51-58

REFERENCES

1. **Kanter, I.** The Theory of Neural Networks and Cryptography / Ido Kanter, Wolfgang Kinzel // The Physics of Communication. – 2003. – P. 631–642. – DOI: 10.1142/9789812704634_0044
2. **Kinzel, W.** Neural Cryptography / W. Kinzel, I. Kanter // ICONIP'02 : proc. of the 9th Intern. Conf. on Neural Information Processing, Nov. 18–22, 2002, Orchid Country Club, Singapore. – Singapore, 2002. – Vol. 3. – P. 1351–1354. – DOI: 10.1109/ICONIP.2002.1202841
3. **Ruttor, A.** Dynamics of neural cryptography / A. Ruttor, I. Kanter, W. Kinzel // Physical Review E – Statistical, Nonlinear, and Soft Matter Physics. – 2007. – Vol. 75, iss. 5. – P. 056104.
4. **Urbanovich, P.P.** Usage of hypercomplex numbers in a cryptographic key agreement protocol based on neural networks / P.P. Urbanovich, N.P. Shutko // Journal of the Belarusian State University. Mathematics and Informatics. – 2024. – Vol. 2. – P. 81–92.
5. **Golikov, V.F.** Attack on synchronized artificial neural networks, forming a common secret by deferred search / V.F. Golikov, A.Y. Ksenevich // Doklady BGUIR. – 2017. – Vol. 8. – P. 48–53. (In Russ.)

6. **Radziukevich, M.L.** Enhancing the secrecy of a cryptographic key generated using synchronized artificial neural networks / M.L. Radziukevich, V.F. Golikov // Informatics. – 2020. – Vol. 17, № 1. – P. 102-108. – DOI: 10.37661/1816-0301-2020-17-1-102-108

7. **Radziukevich, M.L.** Combined formation of a cryptographic key using synchronized artificial neural networks / M.L. Radziukevich, V.F. Golikov // Doklady BGUIR. – 2021. – Vol. 19, № 1. – P. 79-87. – DOI: 10.35596/1729-7648-2021-19-1-79-87

8. **Radziukevich, M.L.** A combined method of formation of a cryptographic key with secret modification of the results of synchronization of artificial neural networks. System analysis and applied information science. – 2021. – Vol. 3. – P.51-58. (In Russ.). – DOI: 10.21122/2309-4923-2021-3-51-58

HOLIKAU U.F., RADZIUKEVICH M.L., SHULIAK D.V.

TWO-WAY ATTACK ON SYNCHRONIZED ARTIFICIAL NEURAL NETWORKS FORMING A COMMON SECRET

*Scientific Production Republican Unitary Enterprise "Research Institute for Technical Protection of Information"
Minsk, Republic of Belarus*

Abstract. *The vulnerability of the technology for generating a common cryptographic key using synchronized artificial neural networks (ANN) is considered in a relatively new type of attack called two-way. The essence of the attack is that a cryptanalyst, listening to an open communication channel, creates two identical artificial neural networks, one of which he synchronizes with the network of one of the legal subscribers, and the second with the network of another legal subscriber. By comparing the vectors of weight coefficients of attacking networks, the cryptanalyst is able to determine the moment of full synchronization of the networks of legal subscribers and the value of the generated secret number. Next, we examine the possibilities of a two-way attack using various models of secret number generation.*

Keywords: *synchronized artificial neural networks, attack, shared cryptographic key, delayed brute force*



Голиков Владимир Федорович, Доктор технических наук, профессор. Сфера научных интересов: защита информации, криптография.

Uladzimir F. Holikau, Doctor of Technical Sciences, Professor. Area of scientific interests: information security, cryptography.

E-mail: gvfl47@mail.ru



Радюкевич Марина Львовна, Научно-производственное республиканское унитарное предприятие «Научно-исследовательский институт технической защиты информации», г. Минск, Республика Беларусь. Кандидат технических наук, начальник испытательной лаборатории по требованиям безопасности информации. Сфера научных интересов: защита информации.

Maryna L. Radziukevich, Scientific Production Republican Unitary Enterprise "Research Institute for Technical Protection of Information", Minsk, Republic of Belarus. Ph.D. of Engineering Sciences, head of the testing laboratory for information security requirements. Area of scientific interests: information security.

E-mail: 1218a@list.ru



Шуляк Дмитрий Викторович, Научно-производственное республиканское унитарное предприятие «Научно-исследовательский институт технической защиты информации», г. Минск, Республика Беларусь. Магистр технических наук, ведущий инженер испытательной лаборатории по требованиям безопасности информации. Сфера научных интересов: защита информации.

Dmitry V. Shuliak, Scientific Production Republican Unitary Enterprise "Research Institute for Technical Protection of Information", Minsk, Republic of Belarus. Master of Engineering Science, leading engineer of the testing laboratory for information security requirements. Area of scientific interests: information security.

E-mail: shuliak.dv@gmail.com

**ИНФОРМАЦИОННЫЕ
ТЕХНОЛОГИИ
В ОБРАЗОВАНИИ**

**INFORMATION
TECHNOLOGIES
IN EDUCATION**

КОНОПАЦКИЙ Д.А., ЛОБАТЫЙ А.А.

СИСТЕМА ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ПРИ УПРАВЛЕНИИ ОБРАЗОВАТЕЛЬНЫМ ПРОЦЕССОМ

Белорусский национальный технический университет
г. Минск, Республика Беларусь

Аннотация. Статья посвящена исследованию особенностей применения систем поддержки принятия решений при создании автоматизированных интеллектуальных систем управления образовательными процессами. Проводится обоснование принципов и методик синтеза интеллектуальной системы, особенностей применения различных математических моделей регуляторов, их достоинств и недостатков. Сделан обоснованный вывод о том, что применение традиционных подходов, основанных на использовании теоретических положений классической теории автоматического управления применительно к синтезу систем управления социальными системами, к которым относятся системы управления образовательными процессами, не позволяет достичь желаемого результата. Предложено при построении системы управления образовательным процессом использовать принципы и методы построения интеллектуальных систем, основное отличие которых состоит в том, что система сама синтезирует цель управления на основе внешних условий, имеющейся в системе базы знаний и мотивации к задачам функционирования системы. Рассматривается построение системы поддержки принятия решений как элемента управляющего блока, основным элементом которого является человек – руководитель (преподаватель), осуществляющий непосредственное управление объектом, которым является также человек – обучаемый (ученик, студент, слушатель). Предложена структурная схема построения интеллектуальной системы управления информационными потоками образовательного процесса и модель воздействия на объект управления. Основой системы управления является динамическая экспертная система, осуществляющая прогнозное моделирование результатов управляющего воздействия, формируемого на основе теории нечетких множеств. Приведен пример моделирования управления информационным потоком, демонстрирующий качественную картину происходящих в системе процессов с учетом внешних воздействий на объект управления.

Ключевые слова: интеллектуальная система управления, образовательный процесс, система поддержки принятия решений, информационный поток

Введение

Понятие (термин) «управление» присутствует практически во всех сферах человеческой деятельности. При различных широких толкованиях этого понятия его смысл сводится к тому, что управление — это целенаправленное воздействие на объект. Теория управления как часть группы наук, основанных на математическом моделировании процессов и систем, под общим названием «кибернетика» наибольшее развитие получила в областях технических наук, так как практически все математические модели технических систем основаны на хорошо известных и апробированных законах физики (механика, электрика, гидравлика и т.д.). Это принципиально отличает техническую кибернетику от экономической кибернетики, военной, социальной и прочих, математические модели которых, как правило, разработаны на основе результатов наблюдений и не подтверждаются исследованиями в областях фундаментальных наук (физика, химия и прочие).

Интенсивное развитие информационных систем и технологий привело к появлению и широкому

использованию таких понятий, как «интеллектуальная система», «искусственный интеллект». Несмотря на различное толкование этих терминов, принципы практического использования, их основной смысл сводится к тому, что они подразумевают наличие возможности с помощью технических средств реализовать некоторые элементы мыслительной, творческой деятельности, которая присуща только умственной деятельности человека.

В теории управления перспективным является направление, получившее название «интеллектуальные системы управления», способные синтезировать цель управления, принимать решение к действию, обеспечивать действие для достижения цели, прогнозировать значения параметров результата действия и сопоставлять их с реальными, образуя обратную связь, корректировать цель или управление [1].

Принципиальное отличие интеллектуальной системы управления от традиционных систем автоматического управления (САУ) состоит в том, что при синтезе цели управления системой учитывается изменяющееся собственное состояние системы

управления, окружающая среда и мотивация, которая подразумевает изначально заложенные в систему управления неизменные принципы, определяющие смысл предназначения и существования управляемой интеллектуальной системы.

Интеллектуальная система управления

Структура интеллектуальной системы управления (ИСУ), её составляющие элементы основаны на результатах исследований систем функционирования живых организмов, в том числе и человека. В общем случае её структурная схема имеет вид, представленный на рис. 1.

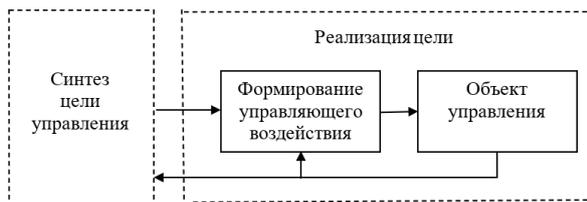


Рисунок 1. Структурная схема интеллектуальной системы управления

В работе [2] дано следующее определение: цель – идеальное, мысленное предвосхищение результата деятельности. Иными словами, синтез цели управления представляет собой формирование некоторого основного свойства (качества), которое должно обеспечить интеллектуальная система управления. Если ставить задачу формализации этого свойства (качества) как представление его в виде, удобном для решения, то это может означать математическое обоснование (выбор) целевой функции или функционала качества, обеспечение экстремума (максимума или минимума, в зависимости от задачи), которого требуется обеспечить с помощью реализации управления. Для этого используется соответствующая база знаний: фактуальных (база данных), алгоритмических и, что особенно важно, концептуальных знаний, основанных на законах фундаментальных наук об окружающем мире.

Несмотря на технический прогресс и достижения в развитии микроэлектроники, для того чтобы решить задачу синтеза цели непосредственно в ИСУ, требуются мощные информационные системы и технологии. В то же время технологии Интернета позволяют использовать внешние, не входящие непосредственно в состав ИСУ, базы знаний на основе облачных технологий [3] и технологий блокчейн [4]. Кроме того, существуют доступные технологии искусственного интеллекта на основе обучаемых нейронных сетей [5]. Комплексное использование этих технологий позволит решать задачи синтеза цели для ИСУ различного предназначения.

Особенностью ИСУ является также обязательное наличие в ней элемента, который называется динамической экспертной системой (ДЭС) [2, 6], которая на основе заданной цели и знаний о собственном состоянии и окружающей среде вырабатывает управление (действие) и прогнозирует результат (моделирует процесс управления).

Построение ДЭС как модели системы автоматического управления может быть основано на различных принципах и методах теории автоматического управления. В составе ДЭС ключевым элементом является регулятор – элемент, формирующий управляющее действие (управление) на основе входной информации. Если элементы САУ представлены в виде математической модели (адекватно формализованы), то для решения задачи синтеза регулятора существуют методы классической и современной теории автоматического управления. Однако, для сложных, трудноформализуемых и неформализуемых задач синтеза управления необходимо применять методы, не требующие строгих математических решений. К числу таких методов следует отнести получившие успешное развитие методы нечетких регуляторов, основанные на теории нечеткой логики.

В автоматической ИСУ синтезированное в ДЭС управление преобразуется в соответствующий сигнал для исполнительных устройств системы. В автоматизированной ИСУ окончательное решение о действии принимает человек – лицо, принимающее решение (ЛПР), для которого ДЭС вырабатывает рекомендации по принятию соответствующего решения. Таким образом, структурную схему формирования управляющего воздействия можно представить в следующем виде (рис. 2). Элементы, формирующие рекомендации для ЛПР, объединены в отдельную группу, которая называется системой поддержки принятия решений (СППР).

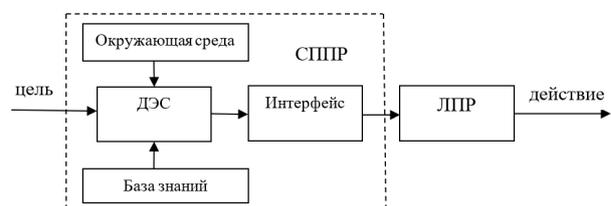


Рисунок 2. Структурная схема формирования управляющего воздействия

СППР представляет собой удобное с точки зрения эргономики представление рекомендаций для ЛПР. Это, как правило, визуальное представление этих рекомендаций (интерфейс) в привычной для человека форме, например, на экране монитора.

Управление образовательным процессом

Среди различных в широком смысле систем управления, в которых интенсивно внедряются информационные системы и технологии, следует выделить образовательные системы (от начального образования до высшего и далее) [7]. В отличие от таких сфер, как экономика, здесь объектом управления является человек–ученик (обучаемый), который должен приобретать в процессе обучения определенный набор (совокупность, множество) знаний, умений и навыков.

Многолетний опыт применения в образовательном процессе информационных систем, в том числе – технологий дистанционного обучения [8], показывает, что присутствие в этом процессе человека-преподавателя существенно повышает эффективность образовательного процесса. Опытный педагог, человек–преподаватель не только доводит до обучающихся необходимую информацию, но и учитывает при проведении занятий индивидуальные интеллектуальные и психологические особенности обучающихся, воздействует на аудиторию интеллектуально и психологически.

Создание полной компьютерной модели ДЭС и СППР достаточно трудоёмко. Рассмотрим в каче-

стве примера качественную упрощенную модель управления объемом информации, которая необходима для усвоения обучающимися.

Пусть в качестве управляемой переменной образовательного процесса рассматривается информационный поток, воздействующий на обучаемого. Его объем определяется соответствующими компьютером 10] рассмотрена задача оптимизации информационных потоков образовательного процесса. Для учета динамики прохождения информационного потока образовательного процесса введем в рассмотрение понятие «условная временная единица» (УВЕ), в качестве которой рассмотрим, например, академический час (45 минут). В качестве регулятора ДЭС используем нечеткий регулятор [11] с обратной связью по скорости. На рисунках 3 и 4 представлены схемы канала управления и воздействия внешней помехи, выполненные в среде моделирования динамических систем SiminTech.

В качестве внешней помехи рассматривается периодическое пилообразное снижение уровня усвоения обучаемым полезной информации, обусловленное, например, промежутками (пропусками) между занятиями (рис. 5).

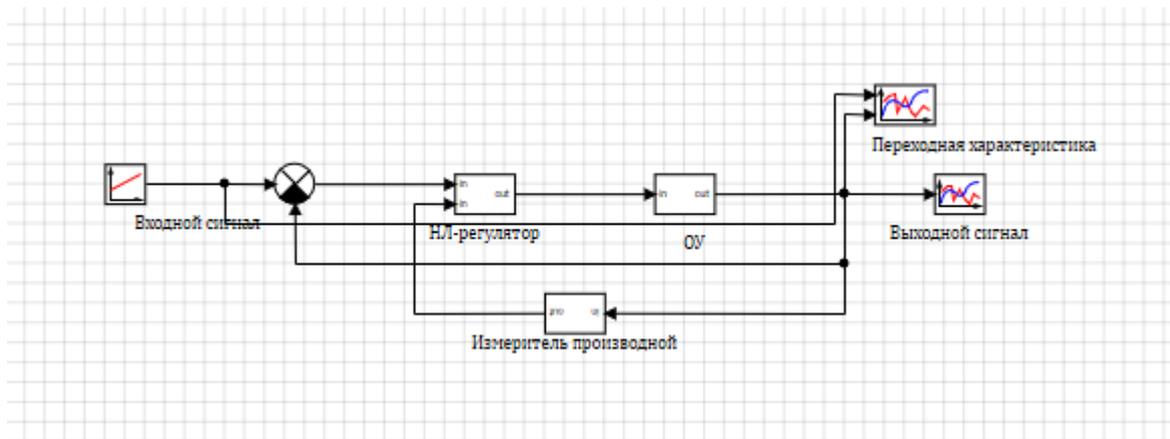


Рисунок 3. Схема канала управления с НЛ-регулятором

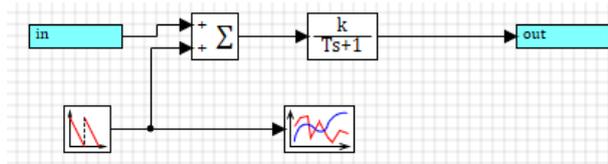


Рисунок 4. Схема воздействия внешней помехи

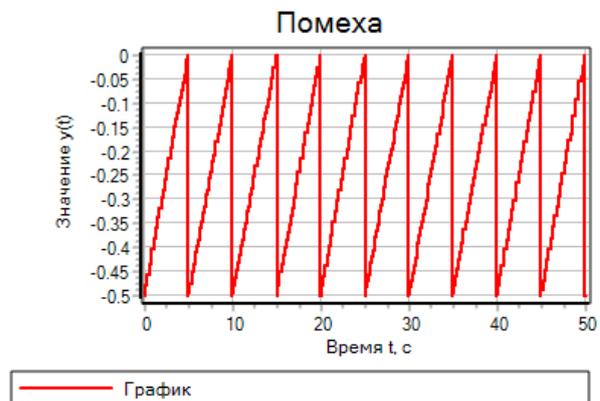


Рисунок 5. Воздействие внешней помехи

Динамические свойства объекта управления (обучаемого) представлены в данном примере аperiодическим (инерционным) звеном, характеризующим инерционные свойства обучаемого в процессе усвоения информации. Постоянная времени аperiодического звена в общем случае определяется экспериментально. В данном примере для удобства сравнительной оценки коэффициент усиления принят 100, а постоянная времени принята равной 0.2УВЕ (0.2 условные временные единицы).

На рис. 6 представлены графики изменения входного (воздействующего на обучаемого) и выходного (усвоенного обучаемым) информационных потоков, вычисленных на основе моделирования динамической экспертной системой. Из рис. 6 видно, что с увеличением объема входной информации увеличивается отрицательное влияние помехи (пропусков занятий), что приводит к значительным уменьшениям выходной (усвоенной обучаемым) информации.

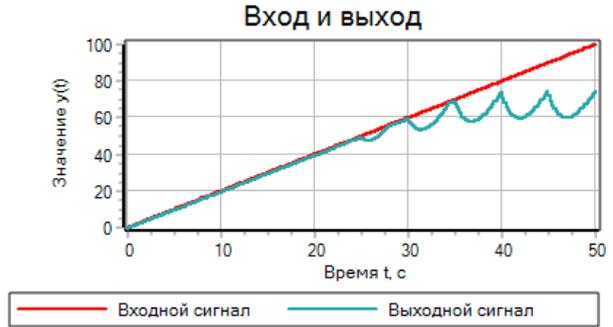


Рисунок 6. Входной и выходной потоки информации

На рис. 7 представлена схема НЛ-регулятора (РНЛ), реализованная в среде SiminTech. На входы РНЛ поступают отклонение регулируемого параметра и скорость изменения данного параметра. Отклонение в данном случае означает разность между заданным (требуемым) и фактическим (измеренным) значениями регулируемого параметра, характеризующего информационный поток, воздействующий на обучаемого.

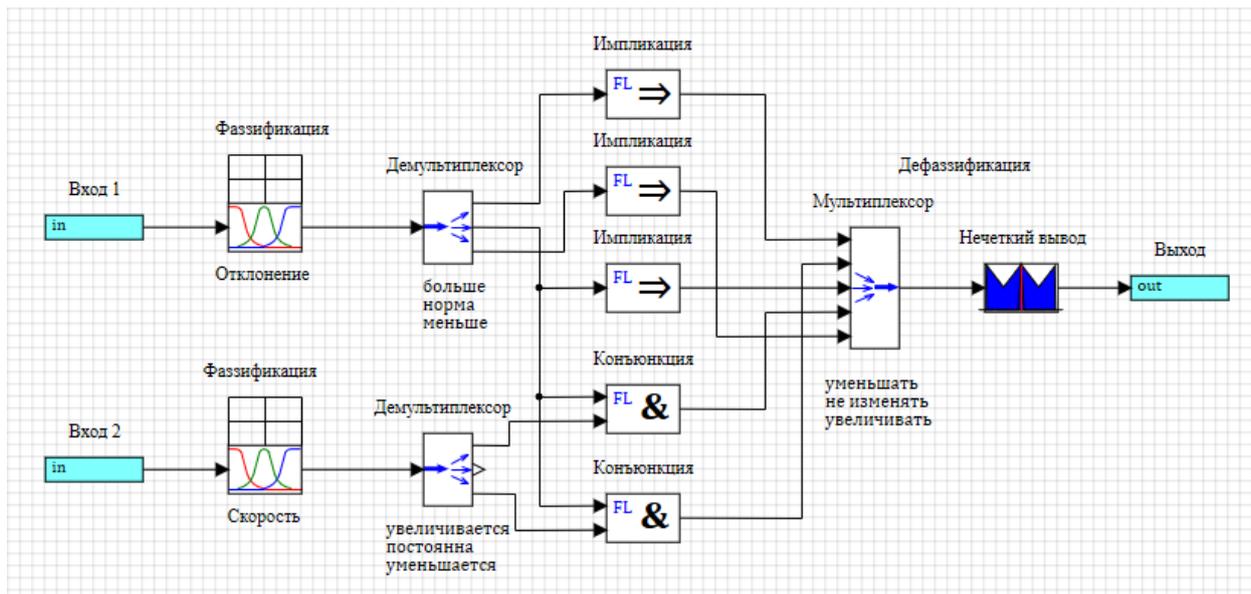


Рисунок 7. Схема НЛ-регулятора

На рис. 7 обозначено: => – блоки импликации и & – блоки конъюнкции, которые осуществляют операцию нечеткого логического вывода, включающего вычисление степени истинности заданных условий, соединенных логической операцией (процедура агрегации) и определение истинности для всех условий каждого правила (процедура активизации). Заключение из каждого правила объединяются для каждого правила (процедура аккумуляции) [11-13]. Блоки фаззификации и демультиплексоры преобразуют конкретные численные значения входных сигналов (отклонение и скорость) в лингвистические переменные (больше, норма,

меньше, увеличивается, постоянна, уменьшается). Мультиплексор и блок нечеткого вывода (треугольная функция) выполняют операцию дефаззификации (приведение к четкости) – расчет числового значения выходной переменной.

Заключение

Системы управления социальными процессами, в том числе и образовательными, будут основаны на широком применении информационных систем и технологий, включая технологии искусственного интеллекта. В то же время в процессе управления

этими процессами должен присутствовать человек (лицо, принимающее решение – ЛПР), так как объектом управления является человек (социальная среда), на которого необходимо оказывать не только информационное, но также и эмоциональное (психологическое) воздействие. Для успешного управления образовательным процессом це-

лесообразно иметь систему поддержки принятия решений, основанную на технологиях построения интеллектуальной системы управления, ключевым элементом которой является динамическая экспертная система, осуществляющая моделирование и прогноз результатов воздействия на объект управления.

ЛИТЕРАТУРА

1. Пупков, К. А. Интеллектуальные системы: проблемы теории и практики / К. А. Пупков // Изв. вузов. Приборостроение. – 1994. – Т. 37. – № 9–10. – С. 5–7.
2. Методы классической и современной теории автоматического управления : в 5 т. — М. : Издательство МГТУ им. Н.Э. Баумана. – 2004. – Т. 5 : Методы современной теории автоматического управления / ред. К. А. Пупкова и Н. Д. Егупова. – 784 с.
3. Батура, Т. В. Облачные технологии: основные модели, приложения, концепции и тенденции развития / Т. В. Батура, Ф. А. Мурзин, Д. Ф. Семич // Программные продукты и системы. – 2014. – № 3 – С. 64–72. – URL: <https://cyberleninka.ru/article/n/oblachnye-tehnologii-osnovnye-modeli-prilozheniya-kontseptsii-i-tendentsii-razvitiya-1/viewer> (дата обращения: 15.05.2025).
4. Вишняков, В. А. Управление интернет-маркетингом в системе образования с использованием блокчейн технологий / В. А. Вишняков, Д. А. Качан // Доклады БГУИР. – 2020. – № 2. – С. 30-36. – DOI: 10.35596/1729-7648-2020-18-2-30-36
5. Мелихова, О. А. Методы обучения в системах искусственного интеллекта / Мелихова Оксана Аскольдовна, Григораш Андрей Сергеевич, Джамбинов Сергей Владимирович [и др.] // Технические науки – от теории к практике : сб. ст. по материалам ЛП междунар. науч.-практ. конф. – 2015. – № 11 – С. 19–28. – URL: <https://cyberleninka.ru/article/n/metody-obucheniya-v-sistemah-iskusstvennogo-intellekta/viewer> (дата обращения: 15.05.2025).
6. Пупков, К.А. Динамические экспертные системы в управлении / К. А. Пупков // Изв. вузов. Приборостроение. – 1996. – № 8–9. – С.39–50.
7. Бровка, Г. М. Управление образовательными системами / Г. М. Бровка. – Мн.: БНТУ, 2004. – 274 с.
8. Богущ, В. А. Информационные технологии в образовании / В. А. Богущ // Наука и инновации. – 2015. – № 11. – С. 9–12.
9. Лобатый, А. А. Сетевые модели организации учебного процесса / А. А. Лобатый, Д. А. Конопацкий // Системный анализ и прикладная информатика. – 2023. – № 2. – С. 65-69. – DOI: 10.21122/2309-4923-2023-2-65-69
10. Конопацкий, Д. А. Оптимизация информационных потоков сетевых моделей / Д. А. Конопацкий, А. А. Лобатый // Наука и техника. – 2025. – Т. 24, № 1. – С. 5-11. – DOI: 10.21122/2227-1031-2025-24-1-5-11
11. Гостев, В. И. Проектирование нечетких регуляторов для систем автоматического управления / Владимир Гостев. – СПб. : БХВ – Петербург, 2011. – 416 с.
12. Демичева, Г. Л. Регуляторы на основе нечеткой логики в системах управления техническими объектами / Г. Л. Демичева, Д. В. Лукичев. – СПб : Университет ИТМО, 2017. – 81 с.

REFERENCES

1. Pupkov K. A. (1994) Intelligent systems: problems of theory and practice. News of universities. Instrument-making, 37 (9-10), 5–7 (in Russian).
2. Pupkov K. A., Egupov N. D. (eds.) (2004) Methods of Classical and Modern Theory of Automatic Control. Vol. 5. Methods of modern theory of automatic control. Moscow, Publishing House of Bauman Moscow State Technical University. 784 (in Russian)/
3. Batura T. V., Murzin F. A., Semich D. F. (2014) Cloud technologies: main models, applications, concepts and development trends. Software products and systems, 3. Available at: <https://cyberleninka.ru/article/n/oblachnye-tehnologii-osnovnye-modeli-prilozheniya-kontseptsii-i-tendentsii-razvitiya-1/viewer> (accessed: 15.05.2025) (in Russian).
4. Vishniakou U. A., Kachan D. A. (2020) Management of internet marketing in education system with block chain technologies. Doklady BGUIR. 2020, 18(2), 30-36. DOI: 10.35596/1729-7648-2020-18-2-30-36 (in Russian).
5. Melikhova O. A. (2015) Training methods in systems artificial intelligence // Technical Sciences – from Theory to Practice, 11. Available at: <https://cyberleninka.ru/article/n/metody-obucheniya-v-sistemah-iskusstvennogo-intellekta/viewer> (accessed: 15.05.2025) (in Russian).
6. Pupkov K. A. (1996) Dynamic expert systems in management. News of universities. Instrument-making, (8–9), 39-50 (in Russian).

7. **Brovka G. M.** (2004) Management of Educational Systems. Minsk, Belarusian National Technical University. 274 (in Russian).
8. **Bogush V. A.** (2015) Information Technologies in Education. *Nauka i Innovatsii = Science and Innovations*, (11), 9–12 (in Russian).
9. **Lobaty A. A., Konopacki D. A.** (2023) Network models for organizing the learning process. *Sistemny Analiz i Prikladnaya Informatika = Systems Analysis and Applied Informatics Science*, (2), 65–69. DOI: 10.21122/2309-4923-2023-2-65-69 (in Russian).
10. **Konopacki D. A., Lobaty A. A.** (2025) Optimization of Information Flows Based on Network Models of Systems. *Science and Technique*. 24 (1), 5–11. DOI: 10.21122/2227-1031-2025-24-1-5-11 (in Russian).
11. **Gostev V. I.** (2011) Design of fuzzy controllers for automatic control systems. St. Petersburg, BHV–Petersburg. 416 (in Russian).
12. **Demicheva G. D.** (2017) Regulators based on fuzzy logic in control systems of technical objects. St. Petersburg, ITMO University. 81 (in Russian).

KONOPACKI D.A., LOBATY A.A.

DECISION SUPPORT SYSTEM IN EDUCATIONAL PROCESS MANAGEMENT

*Belarusian National Technical University
Minsk, Republic of Belarus*

Abstract. *The article is devoted to the study of the features of using decision support systems in creating automated intelligent systems for managing educational processes. The substantiation of the principles and methods of synthesizing an intelligent system, the features of using various mathematical models of regulators, their advantages and disadvantages is carried out. A reasonable conclusion is made that the use of traditional approaches based on the use of theoretical provisions of the classical theory of automatic control as applied to the synthesis of control systems for social systems, which include educational process control systems, does not allow achieving the desired result. It is proposed to use the principles and methods of building intelligent systems when building an educational process control system, the main difference of which is that the system itself synthesizes the control goal based on external conditions, the knowledge base available in the system and motivation for the tasks of the system functioning. The construction of a decision support system as an element of the control block is considered, the main element of which is a person - a manager (teacher), who directly manages the object, which is also a person - a student (pupil, student, listener). A structural diagram of the construction of an intelligent system for managing information flows of the educational process and a model of influence on the control object are proposed. The basis of the control system is a dynamic expert system that carries out predictive modeling of the results of control action formed on the basis of the theory of fuzzy sets. An example of modeling information flow control is given, demonstrating a qualitative picture of the processes occurring in the system taking into account external influences on the control object.*

Keywords: *intelligent control system, educational process, decision support system, information flow*



Конопацкий Денис Александрович, Директор филиала Белорусского национального технического университета «Институт повышения квалификации и переподготовки кадров по новым направлениям развития техники, технологии и экономики БНТУ». Проводит исследования в области анализа и синтеза систем организации управления учебным процессом.

Denis A. Konopacki, Director of the branch of the Belarusian National Technical University "Institute for advanced training and retraining of personnel in new areas of development of engineering, technology and economics of the BNTU". Conducts research in the field of analysis and synthesis of educational process management systems.

Тел.: +375 (29) 346-82-56

E-mail: deniskon@bntu.by



Лобатый Александр Александрович, Белорусский национальный технический университет. Доктор технических наук, профессор. Проводит исследования в области анализа и синтеза стохастических динамических систем управления. Автор и соавтор множества статей в научных журналах и конференциях, автор ряда книг и учебных пособий.

Alexander A. Lobaty, Belarusian National Technical University. Doctor of Engineering Science, Professor. Conducts research in the field of analysis and synthesis of stochastic dynamic control systems. He is the author and co-author of many articles in scientific journals, conferences and books.

Тел.: +375 (29) 346-82-56

E-mail: lobaty@bntu.by

НИКУЛЬШИН Б.В., КИСЕЛЬ Т.В.

ОПТИМИЗАЦИЯ РАСПРЕДЕЛЕНИЯ ЗАЧИСЛЕННЫХ АБИТУРИЕНТОВ ПО УЧЕБНЫМ ГРУППАМ

*Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь*

*Полесский государственный университет
г. Пинск, Республика Беларусь*

Аннотация. В статье предлагается подход к решению задачи оптимального распределения зачисленных абитуриентов по учебным группам с учетом уровня мотивации распределяемых. Результаты данной работы могут быть использованы вузами в качестве естественного административного инструмента для достижения лучших образовательных результатов в контексте академической неоднородности.

Ключевые слова: качество высшего образования, качество приема, академическая неоднородность, эффект сообучения, мотивация, формирование учебных групп

Введение

Качество высшего образования причисляется к числу наиболее актуальных проблем, которой активно занимаются многие страны. Одной из причин роста интереса к вопросу качества стал переход к массовому высшему образованию. В этом контексте перед высшими учебными заведениями во многих странах, в том числе и в Республике Беларусь, встал вопрос: «Каким образом можно поддерживать качество в системе массового высшего образования?»

Качество высшего образования зависит от многих факторов и в первую очередь от уровня подготовки зачисленных на первый курс студентов. Привлечение хорошо подготовленных и мотивированных абитуриентов – важная задача учреждений высшего образования, возможность реализации которой во многом зависит от системы отбора. В Республике Беларусь с 2023 года утверждена новая редакция Правил приема лиц для получения общего высшего и специального высшего образования [1]. Изменения преимущественно направлены на совершенствование системы отбора абитуриентов в белорусские вузы, которая, в первую очередь, ориентирована на отбор подготовленных (акцент направлен на олимпиадную систему отбора) и мотивированных (особая роль отводится системе целевого набора) абитуриентов.

В соответствии с нововведениями организована многоступенчатая система приема в вузы: 1-й этап – университетские олимпиады; 2-й этап – республиканская олимпиада по учебным предметам; 3-й этап – централизованные экзамены; 4-й этап – прием на целевое обучение; 5-й этап – централизованное тестирование; 6-й, основной этап – поступление на общих основаниях.

В основной этап поступления, благодаря автоматизации приемной кампании, у вузов появилась возможность организации конкурсного отбора по группам специальностей на основе системы приоритетов. В соответствии с 30 пунктом 5 главы Правил приема, по решению приемной комиссии, при использовании автоматизированной системы зачисления, абитуриенту может быть предоставлена возможность участия в конкурсном отборе на любое число специальностей в рамках выбранной группы (зачисление производится на специальность) в порядке приоритета, определенного им самим в заявлении при подаче документов. Данная возможность, широко используется среди белорусских вузов, позволяя отбирать наиболее подготовленных, автоматически отсеивая слабых участников [2].

Безусловно, от системы отбора, в общем, и от качества работы приемной комиссии, в частности, во многом зависит успех приемной кампании, а значит – и качество студенческой аудитории, зачисленной на первый курс.

Однако, несмотря на то что система приема в вузы максимально ориентирована на отбор лучших абитуриентов, качество приема в вузах сильно дифференцируется. Ведущие вузы привлекают наиболее подготовленных и мотивированных учащихся, в региональные вузы чаще поступают студенты со средними и низкими баллами. С другой стороны, последние несколько лет политика в сфере образования направлена на то, чтобы талантливые студенты из регионов оставались в своих вузах. Да и по ряду причин не всегда у ребят с хорошей подготовкой есть возможность учиться в другом городе. В результате, часть сильных выпускников остается в своем регионе для получения высшего образования, тем самым

увеличивая разрыв в уровне подготовки зачисленных на первый курс.

Неоднородность студенческого контингента способна оказывать негативное воздействие на выполнение вузами своей фундаментальной функции предоставления качественного образования [3]. Конечно, академическая неоднородность в той или иной степени присуща всем вузам, абсолютно академически однородных учреждений быть не может в силу естественных различий людей. Однако, высокая академическая неоднородность требует определенного подхода к управлению ею со стороны учебного заведения. Уже на стадии приемной кампании университеты могут анализировать, насколько варьируется уровень подготовки поступающих студентов, предсказывать с какими возможными вызовами им придется столкнуться и планировать свою деятельность исходя из этих вызовов.

Анализ качества приема

С целью определения уровня академической неоднородности был проведен анализ качества приема в Полесском государственном университете (ПолесГУ), самом молодом высшем учебном заведении республики, расположенном в районном центре.

Для оценки уровня академической неоднородности использовались данные мониторинга приемной кампании, планы набора и проходные баллы в ПолесГУ за период с 2020 по 2024 гг.

Исследование охватывало группу специальностей экономической направленности, в состав которой входят следующие специальности: 1) экономика и управление (sp¹); 2) бизнес-администрирование (sp²); 3) менеджмент (sp³); 4) маркетинг (sp⁴); 5) экономика (sp⁵); 6) финансы и кредит (sp⁶); 7) бухгалтерский учет, анализ и аудит (sp⁷); 8) инженерная экономика (sp⁸).

В качестве показателя неоднородности было принято стандартное отклонение баллов, набранных при поступлении, от среднего значения.

$$S = \sqrt{\frac{\sum_{i=1}^n (x_i - x_{cp})^2}{n-1}}, \quad (1)$$

где S – стандартное отклонение; n – размер выборки; x_i – величина отдельного значения выборки; x_{cp} – среднее арифметическое выборки.

Для количественного анализа академической неоднородности использовалась 5-балльная шкала, в основе которой лежит стандартное отклонение набранных баллов от их среднего значения [4].

Таблица 1. Шкала академической неоднородности студенческого контингента

Значение показателя неоднородности	Степень	Интерпретация
неоднородность < 15	1	низкая неоднородность
от 15 до 25	2	неоднородность ниже среднего
от 25 до 35	3	средняя неоднородность
от 35 до 45	4	неоднородность выше среднего
неоднородность > 45	5	высокая неоднородность

В следующей таблице, для каждой специальности приведены данные о средних баллах зачисленных абитуриентов; представлено рассчитанное значение показателя неоднородности (стандартное

отклонение), которое показывает разброс баллов, набранных абитуриентами при поступлении; минимальные и максимальные баллы, отражающие разницу в уровне подготовки зачисленных абитуриентов.

Таблица 2. Данные по группе специальностей экономической направленности о зачисленных абитуриентах в 2024 г.

№ п/п	Специальность (направление специальности)	Средний балл	Неоднородность (стандартное отклонение)	Шкала	Макс. балл	Мин. балл	Число студентов
1	sp ¹	251,00	38,64	4	309	199	48
2	sp ²	256,85	55,11	5	333	177	26
3	sp ³	261,78	44,61	4	332	199	23
4	sp ⁴	274,90	51,60	5	392	212	29
5	sp ⁵	243,14	38,26	4	340	189	21
6	sp ⁶	251,50	29,46	3	317	181	84
7	sp ⁷	253,60	19,18	2	270	192	15
8	sp ⁸	265,83	44,78	4	398	175	29

Почти все из рассмотренных специальностей (6 из 8) демонстрируют неоднородность четвертого и пятого уровней по вышеописанной 5-балльной шкале, что позволяет говорить о неоднородности студенческого контингента, а максимальный и мини-

мальный баллы – о разном уровне подготовки зачисленных.

Отдельно в динамике была рассмотрена специальность из объединенной группы с самым большим набором.

Таблица 3. Динамика изменения академической неоднородности зачисленных на специальность «Финансы и кредит» в период с 2020 по 2024 гг.

№ п/п	Год приема	Количество чел.			Средний балл	Макс. балл	Мин. балл	Стандартное отклонение	Шкала
		план (всего)	факт (бюджет/ платно)						
1	2020	115	70	43	267,17	400	105	42,88	4
2	2021	115	70	31	262,80	328	161	36,84	4
3	2022	96	63	20	259,82	351	165	33,37	3
4	2023	90	65	25	254,14	319	161	34,91	3
5	2024	84	65	19	251,5	317	181	29,46	3

Из таблицы видно, что уровень неоднородности в разные годы приема колеблется. Основные изменения в динамике указывают на снижение уровня неоднородности за счет уменьшения набора на специальность. В целом, результаты анализа позволяют утверждать, что уровень подготовки студенческой аудитории, зачисленной на первый курс, довольно неоднородный.

Научно доказано, что совместное обучение сильных и слабых студентов ведет к возникновению эффектов образовательной среды, или сообучения (peer group effect – PGE) [5]. Под эффектом сообучения в образовании понимают влияние, которое оказывают на успеваемость студента другие учащиеся. Существует ряд важных вопросов образовательной

политики, относительно которых принимаются решения, которые должны обязательно учитывать потенциальные эффекты сообучения в академически неоднородной среде [6]. В их числе – вопрос формирования учебных групп, поскольку именно на уровне студенческой группы эффект сообучения проявляется наиболее значительно.

Каким образом вузы учитывают исходную неоднородность при распределении студентов по группам (и учитывают ли вообще)? Результат распределения абитуриентов, зачисленных на первый курс ПолесГУ, по учебным группам, на примере специальности с самым большим набором, в годы приема, характеризующиеся наибольшей исходной неоднородностью, представлен в таблице 4.

Таблица 4. Распределение по группам абитуриентов, зачисленных на специальность «Финансы и кредит» в 2020, 2021 гг.

Год приема	Группа	Количество чел.		Средний балл	Макс. балл	Мин. балл	Стандартное отклонение	Шкала
		бюджет	платно					
2020	1	18	12	278,03	400	177	43,83	4
	2	16	12	264,8	321	222	31,67	3
	3	16	11	253,1	321	156	45,16	5
	4	20	8	271,5	356	105	47,36	5
2021	1	13	13	252,0	294	162	38,88	4
	2	13	13	252,0	328	161	43,9	4
	3	26	0	281,5	307	270	10,36	1
	4	18	5	266,0	316	165	37,93	4

По данным, приведенным в таблице, видно, что уровень неоднородности после распределения зачисленных абитуриентов по учебным группам, по

сравнению с исходным, увеличился, а средний балл свидетельствует о неодинаковом уровне подготовки студентов в разных группах.

В качестве еще одной не менее важной предпосылки возникновения академической неоднородности следует отметить изменение (по сравнению с советским периодом) мотивации студентов к поступлению и способов принятия решений относительно выбора специальности. Раньше при подготовке к вузовским экзаменам студенты ориентировались на требования конкретного вуза. Нынче вступительные испытания, организованные в форме централизованного экзамена и централизованного тестирования, позволили абитуриентам выбирать вуз уже после сдачи экзамена, по его результатам.

Возможность организации конкурсного отбора по группам специальностей, которая широко используется среди белорусских вузов, позволяя отбирать абитуриентов с самыми высокими балла-

ми, повышая шансы абитуриента стать студентом (поскольку вероятность быть зачисленным, участвуя в общем конкурсе, выше, чем при участии в конкурсе на одну специальность), кроме преимуществ имеет и недостатки. Так, при зачислении на специальность наименее предпочтительную, выбранную абитуриентом как запасной вариант, наряду с абитуриентами, осознанно поступавшими на конкретную специальность, увеличивается количество «случайных» студентов, что в свою очередь провоцирует неоднородность студенческого контингента в целом.

В таблице 5 представлен результат распределения по учебным группам студентов, поступивших на специальность «Финансы и кредит» в период с 2020 по 2024 гг. с учетом приоритета специальности.

Таблица 5. Результат распределения студентов по учебным группам с указанием порядкового номера специальности, на которую они были зачислены

Год приема	Номер группы	Кол. чел. в группе	Количество человек, поступивших по приоритету							
			1	2	3	4	5	6	7	8
2020	1	30	29	1	-	-	-	-	-	-
	2	28	26	1	1	-	-	-	-	-
	3	27	23	3	-	1	-	-	-	-
	4	27	25	2	-	-	-	-	-	-
2021	1	26	24	2	-	-	-	-	-	-
	2	26	19	2	2	1	1	1	-	-
	3	26	14	2	5	2	2	-	1	-
	4	23	16	4	2	-	-	1	-	-
2022	1	28	22	3	3	-	-	-	-	-
	2	27	17	4	2	2	-	1	1	-
	3	27	18	2	3	3	-	1	-	-
2023	1	30	21	4	2	1	-	1	1	-
	2	30	19	1	2	2	4	2	-	-
	3	30	17	4	5	1	2	1	-	-
2024	1	28	17	5	3	-	2	1	-	-
	2	28	21	1	3	-	3	-	-	-
		28	25	-	1	-	2	-	-	-

Данные таблицы свидетельствуют о том, что при распределении студентов по группам не учитывался уровень мотивации распределяемых. В результате, в одних и тех же учебных группах оказались

студенты не только с разным уровнем подготовки, но и разной мотивацией, что в конечном итоге может негативно отразиться на успеваемости в процессе обучения и качестве образования в целом.

Решение задачи оптимального распределения зачисленных абитуриентов по учебным группам

Распределение студентов первого курса по учебным группам осуществляется после выхода приказа о зачислении, но не позднее начала учебного года. Обычно формированием учебных групп занимаются сотрудники деканатов, чаще всего вручную, руководствуясь, как правило, общими требованиями.

Комплексные решения, такие как автоматизированные информационные системы управления вузом, в состав которых входят отдельные подсистемы («Приемная комиссия», «Деканат» и другие), позволяют автоматизировать большой спектр задач, в том числе процесс формирования учебных групп. Как правило, первоначальное разбиение абитуриентов на группы проводится автоматически подсистемой «Приемная комиссия», после чего в полученное разбиение вручную могут быть внесены локальные корректировки. При необходимости разбиение на группы может полностью производиться вручную путем явного указания для каждого абитуриента номера группы (обычно таким образом реализована функция распределения в подсистеме «Деканат»).

В ПолесГУ для сопровождения приемной кампании ряд лет используется автоматизированная учетно-информационная система «Абитуриент-п» (где p – порядковый номер года текущей приемной кампании, например, «Абитуриент-2024»). Система, разработанная специалистами информационно-аналитического центра университета, автоматически распределяет зачисленных абитуриентов по учебным группам, обеспечивая равенство групп по численному составу и половому признаку. Также система в автоматическом режиме, используя правила именования групп, формирует номера групп по схеме: $xxYY-z$, где xx – последние две цифры года набора;

YY – название специальности (используется аббревиатура); z – порядковый номер в пределах факультета (например: 24Фик-1).

В рамках данного исследования в контексте исходной академической неоднородности, с целью повышения успеваемости студентов в процессе обучения, предлагается оптимальным образом распределить зачисленных абитуриентов по учебным группам. При распределении учитывать не только уровень подготовки, но и порядковый номер специальности, на которую он был зачислен (т.е. уровень мотивации).

На базе разработанной модели оптимизации распределения может быть создана система программной поддержки распределения студентов первого курса по учебным группам, поскольку ручное распределение студентов сотрудниками деканата, с учетом вышеперечисленных факторов, представляет собой непростую задачу.

В условиях ограничения временного фактора целесообразно разделить процесс формирования учебных групп на два этапа: первый (предварительный) – в рамках подсистемы «Приемная комиссия»; второй (корректировочный) – в рамках подсистемы «Деканат».

Рассмотрим алгоритм предварительного распределения зачисленных абитуриентов по учебным группам с учетом мотивации. При распределении будем учитывать значимость (удельный вес в общей группе) специальности. Удельный вес специальности рассчитаем по следующей формуле:

$$z(i) = \frac{k_i}{\sum_{i=1}^8 (k_i)}, \quad (2)$$

где $z(i)$ – удельный вес специальности в общей группе; k_i – число поданных заявлений на специальность (указанную 1-м приоритетом); i – номер специальности ($i = 1, \dots, 8$).

Таблица 6. Удельный вес специальностей объединенной группы

№ п/п	Специальность	Подано заявлений (по 1-му приоритету)	Удельный вес специальности
1	экономика и управление	40	0,163265306
2	бизнес-администрирование	33	0,134693878
3	менеджмент	23	0,093877551
4	маркетинг	41	0,167346939
5	экономика	6	0,024489796
6	финансы и кредит	68	0,277551020
7	бухгалтерский учет, анализ и аудит	11	0,044897959
8	инженерная экономика	23	0,093877551
	всего	245	1

На основании удельного веса специальности, определим уровень мотивации студенческой группы:

$$M = \sum_{i=1}^8 (r_i \times z_i), \quad (3)$$

где M – уровень мотивации группы; i – ранг ($i = 1, \dots, 8$); r_i – число студентов i -го ранга, включенных в группу; z_i – удельный вес специальности.

Рассчитаем уровень мотивации учебных групп, сформированных сотрудниками деканата вручную.

Результаты ручного распределения (без учета мотивации) и рассчитанного уровня мотивации в сформированных группах представлены в таблице 7.

Распределим по учебным группам абитуриентов, зачисленных на специальность «Финансы и кредит» в 2024 году, с учетом порядковых номеров специальности, указанных ими в заявлении, таким образом, чтобы уровень мотивации в группах был приблизительно одинаковым.

Таблица 7. Результат распределения зачисленных абитуриентов по учебным группам сотрудниками деканата, без учета мотивации

Год приема	Номер группы	Кол. чел. в группе	Ранг (приоритет) специальности / количество человек поступивших по приоритету								Уровень мотивации (удовлетворенность)
			1	2	3	4	5	6	7	8	
2024	1	28	17	5	3	-	2	1	-	-	4,06
	2	28	21	1	3	-	3	-	-	-	3,92
	3	28	25	-	1	-	2	-	-	-	4,22

Таблица 8. Результат распределения зачисленных абитуриентов по учебным группам, с учетом мотивации

Год приема	Номер группы	Кол. чел. в группе	Ранг (приоритет) специальности / количество человек поступивших по приоритету								Уровень мотивации (удовлетворенность)
			1	2	3	4	5	6	7	8	
2024	1	28	22	1	3	-	2	-	-	-	4,06
	2	28	20	2	2	-	3	1	-	-	4,07
	3	28	21	3	2	-	2	-	-	-	4,07

Таким образом, сразу после процедуры зачисления, в рамках подсистемы «Приемная комиссия», в автоматическом режиме, в результате предварительного распределения будут сформированы группы с максимально одинаковым уровнем подготовки и мотивации, что позволит студентам обучаться в равных условиях и положительно отразиться на успеваемости в процессе обучения и качестве образования в целом.

Вывод

В ходе работы проведен анализ качества приема на примере регионального вуза. Результаты анализа свидетельствуют о том, что уровень подготовки студенческой аудитории, зачисленной на первый курс, довольно неоднородный. Кроме того, наличие «случайных» студентов, зачисленных на специаль-

ность, выбранную в качестве запасной, еще больше провоцирует академическую неоднородность. Поскольку академическая неоднородность способна оказывать негативное воздействие на выполнение вузами своей фундаментальной функции предоставления качественного образования, перед вузами встает задача реагирования на высокую академическую неоднородность студенческого контингента.

В работе предложен способ воздействия на уровень академической неоднородности через решение задачи оптимального распределения зачисленных абитуриентов по учебным группам с учетом уровня подготовки и мотивации распределяемых.

Результаты данной работы могут быть использованы вузами в качестве естественного административного инструмента с целью достижения лучших образовательных результатов в контексте исходной академической неоднородности.

ЛИТЕРАТУРА

1. О правилах приема лиц для получения высшего и среднего специального образования [Электронный ресурс]: Указ Президента Респ. Беларусь от 27 янв. 2022 г. № 23 // Национальный правовой Интернет-портал Республики Беларусь. – Режим доступа: <https://pravo.by/document/?guid=12551&p0=P32200023>. – Дата доступа: 23.05.2025.
2. **Кисель, Т.В.** Оптимизация моделей конкурсного отбора абитуриентов / Т.В. Кисель // Системный анализ и прикладная информатика. – 2024. – № 3. – С. 55-61. – DOI: 10.21122/2309-4923-2024-3-55-61
3. **Загирова, Ф.Р.** Академическая неоднородность студентов и управление вузами: формирование исследовательской повестки / Ф.Р. Загирова // Университетское управление: практика и анализ. – 2018. – Т. 22, № 3. – С. 141-154. – DOI: 10.15826/umpa.2018.03.033
4. **Froumin, I.** Academic heterogeneity of universities freshmen / Froumin I., Kardanova E., Enchikova E.S., Ivanova A. // INTED 2013 Proceedings : 7th International Technology, Education and Development Conference, Valencia, Spain, 4-5 March 2013. – Valencia, 2013. – P. 447-465.
5. **Androushchak, G.** Role of peers in student academic achievement in exogenously formed university groups / Gregory Androushchak, Oleg Poldin, Maria Yudkevich // Educational Studies. – 2013. – Т. 39, № 5. – P. 568-581. – DOI: 10.1080/03055698.2013.814561
6. **Польдин, О.В.** Эффекты сообучения в высшем образовании: обзор теоретических и эмпирических подходов / О.В. Польдин, М.М. Юдкевич // Вопросы образования. – 2011. – № 4. – С. 106-123. – DOI: 10.17323/1814-9545-2011-4-106-123

REFERENCES

1. On the rules for admission of persons to obtain higher and secondary specialized education [Electronic resource]: Decree of the President of the Republic of Belarus dated January 27, 2022 No. 23 // National Legal Internet Portal of the Republic of Belarus. – Access mode: <https://pravo.by/document/?guid=12551&p0=P32200023>. – Access date: 23.05.2025.
2. **Kisel, T.V.** Optimization of models of competitive selection of applicants / T.V. Kisel // Systems analysis and applied informatics. – 2024. – No. 3. – P. 55-61. – DOI: 10.21122/2309-4923-2024-3-55-61
3. Zagirova F.R. Academic heterogeneity of students and university management: formation of a research agenda / Zagirova F.R. // University management: practice and analysis. – 2018. – Vol. 22, No. 3. – P. 141-154. – DOI: org/10.15826/umpa.2018.03.033
4. **Froumin, I.** Academic heterogeneity of universities freshmen / Froumin I., Kardanova E., Enchikova E.S., Ivanova A. // INTED 2013 Proceedings : 7th International Technology, Education and Development Conference, Valencia, Spain, 4-5 March 2013. – Valencia, 2013. – P. 447-465.
5. **Androushchak, G.** Role of peers in student academic achievement in exogenously formed university groups / Gregory Androushchak, Oleg Poldin, Maria Yudkevich // Educational Studies. – 2013. – Vol. 39, № 5. – P. 568-581. – DOI:10.1080/03055698.2013.814561
6. **Poldin, O.V.** Effects of peer learning in higher education: a review of theoretical and empirical approaches / Oleg Poldin, Maria Yudkevich // Educational Studies. – 2011. – No. 4. – P. 106-123. – DOI: 10.17323/1814-9545-2011-4-106-123

NIKULSHIN B.V., KISEL T.V.

OPTIMIZATION OF DISTRIBUTION OF ENROLLED APPLICANTS IN STUDY GROUPS

*Belarusian State University of Informatics and Radioelectronics
Minsk, Republic of Belarus
Polessky State University
Pinsk, Republic of Belarus*

Abstract. *The article proposes an approach to solving the problem of optimal distribution of enrolled applicants by study groups, taking into account the level of motivation of those being distributed. The results of this work can be used by universities as a natural administrative tool to achieve better educational results in the context of academic heterogeneity.*

Keywords: *quality of higher education, quality of admission, academic heterogeneity, peer learning effect, motivation, formation of study groups*

Никольшин Борис Викторович, Белорусский государственный университет информатики и радиоэлектроники, г. Минск, Республика Беларусь. Кандидат технических наук, доцент, заведующий кафедрой электронных вычислительных машин Белорусского государственного университета информатики и радиоэлектроники. Область научного интереса: инновационные технологии принятия решений в проектной и управленческой деятельности, методы и модели принятия решений, теория системного анализа и принятия решений в инфокоммуникациях, системный анализ.

Nikulshin B. V., Belarusian State University of Informatics and Radioelectronics, Minsk, Republic of Belarus. PhD in Engineering, Associate Professor, Head of the Department of Electronic Computers. Research interests include innovative technologies for decision-making in project and management activities, methods and models of decision-making, theory of system analysis and decision-making in infocommunications, system analysis.

E-mail: nik@bsuir.by

Кисель Татьяна Васильевна, Полесский государственный университет, г. Пинск, Республика Беларусь. Аспирант кафедры электронных вычислительных машин Белорусского государственного университета информатики и радиоэлектроники, старший преподаватель кафедры информационных технологий и интеллектуальных систем Полесского государственного университета. Область научных интересов связана с оптимизацией приемной кампании вуза.

Kisel T. V., Polesky State University, Pinsk, Republic of Belarus. Postgraduate at the Department of Electronic Computers of the Belarusian State University of Informatics and Radioelectronics, Senior Lecturer at the Department of Information Technologies and Intelligent Systems, Polesky State University. The area of scientific interests is related to the optimization of the university admissions campaign.

E-mail: kisel_t@mail.ru

О ЖУРНАЛЕ

Международный научно-технический журнал «Системный анализ и прикладная информатика» издается 4 раза в год, на русском и английском языке. Распространяется на территории Беларуси, России и странах СНГ. В журнале публикуются статьи по системному анализу, программному обеспечению информационных технологий, хранению и обработке данных, защите информации, применению информационных технологий в образовательном процессе.

Журнал «Системный анализ и прикладная информатика» является отличной площадкой для продвижения результатов научных исследований не только известных, но и начинающих исследователей. Журнал включен в крупнейшие базы данных научного цитирования РИНЦ, eLIBRARY.RU, ЭБС «Лань», Google Scholar, НЭБ «КиберЛенинка», EBSCO, BASE Search, OpenAIRE, WorldCat, OpenDOAR, ROAR которые признаны авторитетными для мирового научного сообщества.

Подписаться на журнал можно через подписные каталоги:
РУП «Белпочта», ООО «Прессинформ», ООО «Криэйтив Сервис Бэнд»,
ООО «Екатеринбург-Опт», ООО «Глобалпресс»

Подписной индекс журнала «Системный анализ и прикладная информатика»:
Ведомственный – 013902 Индивидуальный – 01390

Также предлагаем услуги по размещению рекламы в журнале «Системный анализ и прикладная информатика»

Вид рекламного модуля	Для Республики Беларусь Стоимость в бел. руб. с НДС	Для стран СНГ Стоимость в рос. руб.
На обложке (стр.2,3) полноцветный	689,88	26975
Внутри журнала (формат 1/1), полноцветный	536,49	20950
Внутри журнала (формат 1/2), полноцветный	263,27	11235
Внутри журнала (формат 1/1), черно-белый	363,10	11235
Внутри журнала (формат 1/2), черно-белый	181,56	5390

Размещение рекламы в очередном номере осуществляется
после предварительной оплаты Заказчиком
Информацию для рекламодателей можно получить по тел. (+375) 44 566 47 88,
email: l.katkova@bntu.by

Адрес и телефоны редакции:
Республика Беларусь, г. Минск, 220013, пр. Независимости, 65
тел. +375 17 266 26 58
www.sapi.bntu.by
email: ca_pi@bntu.by
