



ASTANA
INTERNATIONAL
UNIVERSITY

ISSN 2707-4862, Print

SMART TECHNOLOGIES JOURNAL

Nº1 (8) 2025



**Астана Халықаралық университеті
Международный университет Астана
Astana International University**

SMART TECHNOLOGIES JOURNAL

№ 1 (8) - 2025

Жылына 4 рет шығады
Выходит 4 раза в год
Published 4 times a year

Астана - 2025
Astana - 2025

Бас редактор: Калимолдаев М.Н.,
техника ғылымдарының докторы, ҚР ҰҒА академигі, профессор, ҚР ҒЖБМ ҒК Ақпараттық
және есептеу технологиялары институты, Қазақстан

Бас редактордың орынбасары: Муканова А.С.,
PhD, Астана Халықаралық университеті, Қазақстан

Редакциялық алқа:

Оразбаев Б.Б., техника ғылымдарының докторы, профессор, Қазақстан
Сяолей Ф., PhD, Сингапур
Мамырбаев Ө.Ж., PhD, Қазақстан
Беркимбаев К.М., педагогика ғылымдарының докторы, профессор, Қазақстан
Ергеш Б.Ж., PhD, Қазақстан
Гриф М.Г., техника ғылымдарының докторы, профессор, Ресей
Муханова А.А., PhD, қауымдастырылған профессор, Қазақстан
Сахипов А.А., PhD, Қазақстан
Тасболатұлы Н., PhD, қауымдастырылған профессор, Қазақстан
Байгожанова Д.С., педагогика ғылымдарының кандидаты, қауымдастырылған профессор,
Қазақстан

Жауапты редактор – т.ғ.к. Мырзабекова А.М.

Меншіктенуші: «Астана Халықаралық университеті» Жауапкершілігі шектеулі серіктестігі

Тіркеу: ҚР Мәдениет және ақпарат министрлігінің Ақпарат комитеті

Бастапқы есепке қою күні мен нөмірі: 16.01.2020 ж. тіркеу куәлігімен № KZ93VPY00019404

Екінші есепке қою: 16.09.2025 № KZ92VPY00129420

Мерзімділігі: жылына 4 рет

ISSN: 2707-4862

Тақырыптық бағыты: Ақпараттық технологиялар

Редакцияның мекенжайы: 010000, Қазақстан, Астана қ., Қабанбай батыр даңғылы, 8

тел.: +7 (7172) 47-62-10 (214), e-mail: stj@aiu.edu.kz

© Astana International University

Главный редактор: Калимолдаев М.Н.,
доктор технических наук, академик НАН РК, профессор, «Институт информационных и
вычислительных технологии» КН МНВО РК, Казахстан

Заместитель главного редактора: Муканова А.С.,
PhD, Международный университет Астана, Казахстан

Редакционная коллегия:

Оразбаев Б.Б., доктор технических наук, профессор, Казахстан
Сяолей Ф., PhD, Сингапур
Мамырбаев Ө.Ж., PhD, Казахстан
Беркимбаев К.М., доктор педагогических наук, профессор, Казахстан
Ергеш Б.Ж., PhD, Казахстан
Гриф М.Г., доктор технических наук, профессор, Россия
Муханова А.А., PhD, ассоциированный профессор, Казахстан
Сахипов А.А., PhD, Казахстан
Тасболатұлы Н., ассоциированный профессор, Казахстан
Байгожанова Д.С., кандидат педагогических наук, ассоциированный профессор, Казахстан

Ответственный редактор – к.т.н. Мырзабекова А.М.

Собственник: Товарищество с ограниченной ответственностью «Международный университет Астана»

Регистрация: Комитет информации Министерства культуры и информации РК

Дата и номер первичной постановки на учет: 16.01.2020 г., регистрационное свидетельство № KZ93VPY00019404

Вторичная постановка на учет: 16.09.2025 № KZ92VPY00129420

Периодичность: 4 раза в год

ISSN: 2707-4862

Тематическое направление: Ақпараттық технологиялар

Адрес редакции: 010000, Казахстан, г. Астана, пр. Кабанбай батыра, 8,

тел.: +7 (7172) 47-62-10 (214), e-mail: stj@aiu.edu.kz

© Astana International University

Editor-in-Chief: Kalimoldaev M.N.,

Doctor of Technical Sciences, Academician of the National Academy of Sciences of the Republic of Kazakhstan, Professor, Institute of Information and Computing Technologies of the National Academy of Sciences of the Republic of Kazakhstan, Kazakhstan

Deputy Editor-in-Chief: Mukanova A.S.,

PhD, Astana International University, Kazakhstan

Editorial board:

Orazbayev B.B., Doctor of Technical Sciences, Professor, Kazakhstan

Xiaolei F., PhD, Singapore

Mamyrbayev O.J., PhD, Kazakhstan

Berkimbayev K.M., Doctor of Pedagogical Sciences, Professor, Kazakhstan

Ergesh B.J., PhD, Kazakhstan

Grif M.G., Doctor of Technical Sciences, Professor, Russia

Mukhanova A.A., PhD, Associate Professor, Kazakhstan

Sakhipov A.A., PhD, Kazakhstan

Tasbolatuly N., Associate Professor, Kazakhstan

Baigozhanova D.S., Candidate of Pedagogical Sciences, Associate Professor, Kazakhstan

Responsible Editor – Candidate of Technical Sciences Myrzabekova A.M.

Owner: Limited Liability Partnership “Astana International University”

Registration: Information Committee of the Ministry of Culture and Information of the Republic of Kazakhstan

Date and number of initial registration: 16.01.2020, registration certificate № KZ93VPY00019404

Secondary registration: 16.09.2025 № KZ92VPY00129420

Frequency: 4 times a year

ISSN: 2707-4862

Subject area: Information Technologies

Address of edition: 010000, Kazakhstan, Astana, Kabanbay Batyr avenue, 8,

Tel.: +7 (7172) 47-62-10 (214), e-mail: stj@aiu.edu.kz

© Astana International University

МАЗМУНЫ – CONTENTS – СОДЕРЖАНИЕ

Seksenbayev Y.T. Deep learning for multimodal gesture and emotion recognition	7
Пишенбай А.М., Калдарова М.Ж., Кузин Д.А. Разработка и оценка алгоритма персонализации образовательных траекторий с использованием методов искусственного интеллекта	19
Мазакова Б.М., Мусайф М. Создание модуля для обнаружения аномалий в сетевом графе на основе нейронных сетей ..	32
Тункуллова А., Фаддеенков А. Development of an information system for personalized product recommendations based on review and rating analysis	42
Орынбай Д.Д., Сұлтанғазиева А.Н. Проектирование системы ML для предсказания патогенности мутаций	50

IRSTI 20.01.07

DOI: <https://doi.org/10.62687/STJ.8.1.2025.1>**DEEP LEARNING FOR MULTIMODAL GESTURE AND EMOTION RECOGNITION****¹Y.T. Seksenbayev*** 

¹L.N. Gumilyov Eurasian National University, Astana, Kazakhstan
*e-mail: simpleuser6501@gmail.com

Y.T. Seksenbayev – Doctoral Student, L.N. Gumilyov Eurasian National University, Astana, Kazakhstan, e-mail: simpleuser6501@gmail.com, <https://.0000-0002-2863-1715>

Abstract. The application of deep learning in multimodal systems has shown significant progress, especially in streamlining gesture recognition and facilitating sign language interpretation for the hearing impaired. This paper explores the integration of gesture and emotion analysis using convolutional neural networks (CNNs) for facial expression recognition and long short-term memory (LSTM) networks for temporal gesture analysis. To evaluate the effectiveness of the algorithms, multimodal systems were tested on specialized datasets such as iMiGUE, which includes emotion videos that have been accurately annotated. These datasets enabled the evaluation of the model's performance on real-life tasks along with the comparison between different models.

Keywords: deep learning, multimodal systems, emotion recognition, sign language, facial expressions, deaf individuals.

МУЛЬТИМОДАЛЬДИ МЕН ЭМОЦИЯНЫ ТАҢУ ҮШІН ТЕРЕҢ ОҚЫТУ**¹Е.Т. Сексенбаев***

¹Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан
*e-mail: simpleuser6501@gmail.com

Е.Т. Сексенбаев – докторант, Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан, e-mail: simpleuser6501@gmail.com, <https://.0000-0002-2863-1715>

Аңдатпа. Терең оқытуды мультимодальды жүйелерде қолдану айтарлықтай прогресс көрсетті, әсіресе ым-ишараларды тануды оңтайландыруда және есту қабілеті бұзылған адамдарға арналған ым тілін интерпретациялауды жеңілдетуде. Бұл мақалада бет-әлпет мимикасын тану үшін конволюциялық нейрондық желілерді (CNN), ал уақыттық ым-ишараларды талдау үшін ұзақ қысқа мерзімді жад желілерін (LSTM) пайдалана отырып, ым-ишара мен эмоция талдауын интеграциялау қарастырылады. Алгоритмдердің тиімділігін бағалау мақсатында мультимодальды жүйелер дәл таңбаланған эмоциялық бейнелерді қамтитын iMiGUE сияқты арнайы деректер жиынтықтарында сыналды. Бұл деректер жиынтықтары модельдердің нақты өмірлік тапсырмалардағы өнімділігін бағалауға, сондай-ақ әртүрлі модельдер арасындағы салыстыруды жүргізуге мүмкіндік берді.

Түйін сөздер: терең оқыту, мультимодальды жүйелер, эмоцияларды тану, ымдау тілі, мимика, саңыраулар.

ГЛУБОКОЕ ОБУЧЕНИЕ ДЛЯ МУЛЬТИМОДАЛЬНОГО РАСПОЗНАВАНИЯ ЖЕСТОВ И ЭМОЦИЙ**¹Е.Т. Сексенбаев***

¹Евразийский национальный университет им. Л.Н. Гумилёва, Астана, Казахстан
*e-mail: simpleuser6501@gmail.com

Е.Т. Сексенбаев – докторант, НАО Евразийский национальный университет им. Л.Н. Гумилёва, Астана, Казахстан, e-mail: simpleuser6501@gmail.com, <https://.0000-0002-2863-1715>

Аннотация. Применение глубокого обучения в мультимодальных системах продемонстрировало значительный прогресс, особенно в оптимизации распознавания жестов и облегчении интерпретации жестового языка для людей с нарушениями слуха. В данной работе рассматривается интеграция анализа жестов и эмоций с использованием сверточных нейронных сетей (CNN) для распознавания мимических выражений лица и рекуррентных сетей с долгой краткосрочной памятью (LSTM) для анализа временной динамики жестов. Для оценки эффективности алгоритмов мультимодальные системы были протестированы на специализированных наборах данных, таких как iMiGUE, содержащем точно аннотированные видеозаписи эмоций. Эти наборы данных позволили оценить производительность моделей в задачах, приближенных к реальным условиям, а также провести сравнение различных моделей между собой.

Ключевые слова: глубокое обучение, мультимодальные системы, распознавание эмоций, язык жестов, мимика, глухота.

Introduction. Multimodal data analysis technologies are becoming a core component of artificial intelligence research. Over the last decades, they have a big part in customer applications in areas such as healthcare, human-machine interaction, robotics, etc. These technologies are especially important for disabled users, where they are necessary to integrate data such as gestures and facial expressions to accurately assess the user's emotional state. At the same time, the growth of deep learning methods, especially CNNs, and the introduction of Transformers in this field have opened new possibilities for better and more time-efficient models to be built for data analysis.

The significance of integrating gesture recognition and facial expression analysis lies in the following points:

Gestures and facial expressions serve as primary communication channels for hearing-impaired individuals (Littlewort, et al., 2004:615–625). For deafblind individuals, accurate emotion recognition through facial expressions and gesture analysis plays a crucial role in enhancing their ability to communicate effectively and independently.

Deep Learning (DL) is the foundation of many current recognition technologies. It is one of the tools of data analysis and human-computer interaction interpretation through which research and innovation in different fields have advanced rapidly in recent years. A major issue in human-computer interaction research and development is detecting user emotions. The interpretation of emotions is of utmost importance for creating human-like intuitive and effective interfaces, as emotions are the primary driving force behind the attunement of the processing of human communication.

There are many factors influencing the relevance of the topic. Besides, together with the rise of human-computer interaction technologies, the necessity for adaptive systems that could interpret the user's current emotional state has increased. The most important thing here is the creation of technology for the ones with special needs, i.e. deaf-mutes, by incorporating other normal channels of communication (facial expression and gesture) in the stimulation of emotions. Thirdly, the successful recognition of emotion will transform the robotics, virtual and augmented reality and also the medical world in which one can see the situation where proper evaluation of the emotional state of the patients can lead to a patient's care of a higher level.

This is because the other aspects of the study included in the integration of assistive technologies a case of their open-source code, AI and entertainment, and healthcare are now outlined.

The progress in the field of deep learning has become so advanced that many obstacles are not a problem any longer. Deep learning technologies, e.g., convolutional neural networks (CNNs) and long-term short-term memory (LSTM) networks, are now widely used to analyze spatial and temporal data at a very high level (Sun, et al., 2018:12–22). Newer and more promising technologies like transformers and attention mechanisms have surfaced as well and they are expected to take the lead in developing systems that will be capable of dealing with complex interactions between different modalities.

The theme of this paper is to present an overview of the current up-to-date methods for multimodal data analysis and to point out the potential of the combination of facial expressions and gestures for emotions recognition information. The components of the most important deep learning advances, main structures, and model training strategies are examined, along with their practical use cases. Special attention is drawn to the methodological shortcomings of the existing technologies, and future research areas are outlined.

Technologies that recognize emotions have gone through a long evolution. When the first attempts at automating emotion recognition were made in the early 1970s, researchers like Paul Ekman came up with concepts of the seven basic emotions (joy, anger, sadness, fear, surprise, disgust, and contempt) and did a method called FACS (Facial Action Coding System) that involves facial expressions' coding. This early research was the basis of all punches of emotion detection automation (Sun, et al., 2018: 12–22).

The rapid advancement of computing in the 1990s facilitated the adoption of machine learning methods, such as support vector machines (SVMs) and decision trees, which significantly improved the reliability of automated emotion recognition systems. The huge power of the computers that were available at the time made the process more reliable by using these methods. Thus, the landmark research of Littlewort et al. (2004) focused on automated emotion recognition from video recordings, by proving that it is, in fact, possible and thus, a lot of other companies and researchers followed this path and tried to research this area.

A very significant discovery was made by Littlewort et al. (2004) when they showed that a computer can distinguish human emotions from moving video images with a very high degree of accuracy, thus a lot of voice chatting and messenger applications that came after this landmark study, began to focus more on research into this subject (Littlewort, et al., 2004: 615–625).

The authentic revolution belonged to deep learning which started in the early 2010s undoubtedly, however. Furthermore, the advancements in convolutional neural networks (CNNs) brought unlimited prospects for the examination of facial expressions. For instance, the study by Sun et al., 2018, revealed that CNNs can precisely classify emotions in static facial images. An essential step in the right direction was also the creation of the FER2013 database with over 35,000 face images.

Long Short-Term Memory (LSTM) and recurrent neural networks (RNNs) or their adaptations are extensively utilized in dynamic emotion recognition contexts such as gestures or facial expressions. (Liu et al., 2019:10631–10642), for instance, showed that the LSTM can be implemented for gestures' recognition from video sequences, which made it possible to consider the transformation over time as well as the dynamics of their execution. New possibilities in real-time emotion recognition have been thus established (Littlewort, et al., 2004; Sun, et al., 2018: 12–22).

In the late 2010s, the intensive development of innovative approaches such as multimodal is one of their features which was however combined data from different sources to allocate recognition accuracy also commenced. To demonstrate this, Zadeh et al., 2018, proposed the integration of visual, acoustic and textual data with the result that such integration can significantly improve results over the use of information from a single source in any one manner. For instance, the work of Poria et al., 2017, covered the multimodal systems for the study of emotions on social media and through the combination of text, images, and music presented the case of discerning the emotional state of users (Littlewort, et al., 2004; Sun, et al., 2018:12–22; Liu, et al., 2019:10631–10642).

In this study, however, one cannot ignore the fact that deaf-blind users most often transmit information through facial expressions and through gestures. For researchers, this creates a larger obstacle to configuring the tools used in a way that accounts for these traits (Littlewort, et al., 2004: 615–625; Hakim et al., 2019:5429). The aim of this study is to create and put into practice deep learning approaches for detecting emotions in the deafblind based on an analysis of their facial expressions and the speed of their gestures (Hakim et al., 2019:5429, Poria et al, 2017:98–125; Sun, et al., 2018: 12–22).

The created multimodal system, which integrates video data processing and sign language features, expected to lead to more precise detection of users' emotional states. As a result of the

previous one, the present study is expected to positively influence better communication with deaf and blind people, as well as an increase in technological accessibility for this group.

Ultimately, the findings of this study can add greatly to the understanding of deafblind people's emotional expression and lead to further research and development of communication tools for people with disabilities.

Methodology. Today, we encounter modern multimodal systems that integrate deep learning techniques where it is possible to extract features automatically and to combine them in a single latent space. The engines behind such systems are a combination of architectures suitable for processing images, text, audio, and time series of a different nature from one another. The employed methods are grouped into three categories: early, late and intermediate data fusion.

The theoretical basis of multimodal analysis includes the combination of data integration techniques like early, intermediate, and late fusion. The latest findings demrealize that the intermediate data fusion method by applying attention mechanisms (attention) realizes the greatest accuracy through the account of the complex modality's dependencies. As exhibited by (Tsai et al., 2019:6558–6569), the transformer models the temporal and spatial data. The analysis of facial expressions and gestures concerning CNN for visual feature extraction and LSTM for temporal sequence analysis can yield accurate emotion interpretations (Hakim et al., 2019:5429, Sun, et al., 2018: 12–22).

Early fusion involves integrating data characteristics during the preprocessing stage, allowing for straightforward feature extraction but potentially leading to the loss of inter-modal dependencies. Such methods were suggested in early writings such as the one performed by Ngiam et al. (2011) where they conducted the emotion classification in the context of the features extracted from both images and audio. This method is computationally simple and yet may be the reason for the loss of essential dependencies between the modalities (Goodfellow et al., 2014:2672–2680).

In contrast, late fusion is a method that consists of analyzing each modality separately in the predecision phase, and then the results are merged in the decision phase (Poria et al, 2017:98–125). It is a modern API employed in the Vision-Language Pretraining (CLIP) (Radford et al., 2021) model, which is a state-of-the-art model that accesses textual and visual data in separate ways and relates them in a common space of potential features.

Intermediate fusion, on the other hand, is the most effective. The process of this technique is: first, the latent representations of each modality are extracted and then they are combined through special tools such as attention.

One example of this kind of model is the Multimodal Transformer (Tsai et al., 2019:6558–6569), which measures the time-contrastive sequences through a self-attention mechanism. Thus, the complex interdependencies between modalities are considered (Tsai et al., 2019:6558–6569; Vaswani et al., 2017).

A significant challenge in constructing multimodal systems lies in identifying the optimal structure for specific tasks, particularly when managing noise or incomplete data from one of the modalities [8]. Solutions include employing robust attention mechanisms to focus on the most relevant data and integrating data augmentation techniques to enhance model generalization, and also to ensure that the model is robust as regards the ingress of irrelevant noise or the exclusion of some of the data from any one of the modalities.

An example of the recent application of attention mechanisms is the one by Vaswani et al. (2017), where they have been shown to be crucial in the successful coupling of complex dependencies, thus, attention helps to prime the most relevant items from each data channel (Vaswani et al., 2017).

In order to achieve the research goals, a modern methodology based on advanced deep learning and data mining approaches has been created which consists of several essential steps, namely: data collection, processing, and annotation, model selection and training, performance assessment, and real-world implementation and integration. The methodology emphasizes robust and relevant methods which are currently in use in the emotion recognition area.

Data collection starts with the establishment of a multimodal database which includes recordings of deaf people and mute participants who show gestures and facial expressions.

Used to train the system were the following datasets:

1. iMiGUE: more than 10,000 emotional state videos.
2. Slovo: a special dataset that is all about the studying of gesture in speech proportional.
3. RWTH-PHOENIX-Weather: the video data of gestures used in different weather environments were also used.

Some data augmentation techniques that are like brightness, rotation, and noise were used for the purpose of improving data quality (Krizhevsky et al., 2012). The architecture of the multimodal system integrating CNN and LSTM models is presented in Figure 2.

System architecture

The system is made up of two parts:

1. The Mimicry Performance analysis: primarily executed using CNNs to extract the desired features from the face images. Gesture recognition: which is an LSTM network leveraging the temporal data of movements for its operation. The input video was sliced up into buffers of 64 frames for the sequence processing.

2. Data augmentation is done at the preprocessing stage to increase the sample size [8]. Methods such as flipping, rotation, and brightness changes of images fall under this category. Data annotation is basically done using standard techniques such as FACS and specific software like ELAN that is designed for the purpose. Each video clip is indicated as per the expressed emotion, thus enabling the preparation of a reliable dataset for the model training. The model integrates visual and temporal features using a combination of CNN and LSTM architectures, allowing for effective emotion recognition (see Figure 1 for system architecture).

A blend of CNNs for static frame feature extraction and RNNs such as LSTMs for analyzing temporal dependencies is used for emotion recognition. The CNN model is utilized for information extraction from individual video frames while LSTM takes over the analysis of a sequence of frames by considering the dynamics of the gesture execution. The way this architecture integrates both spatial and temporal data enables efficient data processing.

Moreover, aside from the CNNs and LSTMs, we can also choose to use Transformers which have been successful in performing sequence processing to be models of a better quality. The models of ViT namely Vision Transformer can be used to depict the specific visual processing of the video data and subsequently increase the quality of the emotion recognition (Amangeldy et al., 2023: 10799; He et al., 2016:770–778).

Vision Transformer (ViT) models can enhance the quality of emotion recognition by efficiently processing specific visual features in video data.

Model training was performed using the Adam optimizer, supplemented by regularization methods such as dropout and batch regularization to reduce overfitting (Kingma&Adam et al., 2014; Srivastava 2014:1929–1958). The model was validated using cross-validation to assess its performance. The main metrics included: precision, recall, and the F1-score.

The mechanism of attention can highlight certain parts of facial expressions and gestures and thereby constrain the effect of random disturbances. This is crucial for emotion-related tasks where the mixed signals may have extraneous or overlapping content. Utilizing a common latent layer, the spatiotemporal features are merged wherein impulsive representations of a modality are changed into a unified visible form

To gauge the efficiency of the proposed methodologies, multi-modal systems are validated on only particular datasets like iMiGUE having only a select few videos of emotions that were diffused. These databases afford the opportunity to benchmark models, thereby permitting the evaluation of their performances in real-world contexts.

The training of models is done by advanced optimization techniques such as Adma and RMSprop to attain faster convergence rates. Plus, to combat overfitting, it is essential to include

dropout and batch normalization as regularization methods. The model learns using the training sample while the validation sample is used to control the training process.

Moreover, the reliability of the model can be improved by implementing a cross-validation method that offers a more precise estimation of the model generalizability. The different analysis metrics that will also be used should be: ROC-AUC and PR-AUC giving richer details regarding the model's class performance (Vaswani et al., 2017).

Roc-auc and Pr-aUC are also the different analysis metrics that will be employed to be able to have a more comprehensive picture of model performance by class.

The multimodal model training procedure consisted of four stages, each of which was very crucial for the success of the training sequence, starting from the preparation of data and concluding with testing on specialized datasets (Ngiam et al., 2011:689–696).

First, image sequences were cropped from the video to allow for a length of 64 frames to maintain the same level of temporal dependencies during processing. The quality of the training material was improved through the application of augmentation techniques such as rotation, luminance modification, and noise addition. These solutions contributed strongly to the generalization capacity of the model, primarily in cases where various types of input data were available (Srivastava, et al., 2014:1929–1958; Tsai et al., 2019:6558–6569).

In terms of structure, the neural network consists of two key modules. The intention of the first module is to extract features relevant to facial expressions by applying convolution neural networks (CNNs) to images of the faces. The main idea behind this module is to use the ResNet-50 architecture, which has been fine-tuned on the datasets that specialize in facial emotion detection. The second deletion of a gesture recognition module is done via the iterative algorithm of a bidirectional recurrent network (BiLSTM), which deals with complex interactions in sequences of hand movements. In the process, the raw data was pre-processed by identifying the important features with a library called Mediapipe that works on the hand points (Ngiam et al., 2011:689–696, Simonyan & Zisserman, 2014).

The attention mechanism had been chosen to integrate the information created from the different modalities thus it is an approach that chooses the most important features from the channels that have been received. Through this strategy, it was possible for the model -notably- to eliminate any disturbances that had no relevance to the processing of multimodal information. The final unification of the spatial and temporal data was made in a certain latent space where a high accuracy in the detection of emotions and gestures was accomplished.

The Adam optimizer was implemented in conjunction with a learning rate of 0.001 and a minibatch size of 32. The skill-set of the established network would not be adequate if overtraining was successful, so to utterly safeguard against this, Dropout as well as Batch Normalization, which are both powerful regularization methods with a probability of 0.5, were used. The monitoring of the learning process was done by a function outputting the cross-entropy loss, a well-suited measure for a classification problem (Sun, et al., 2018: 12–22; Zadeh et al., 2018:2236–2246). During testing, we conducted a systematic performance evaluation of the model using the distinguishing datasets, which had already been practiced in the previous work. iMiGUE was one of those datasets which contained around 10,000 videos that showed emotion annotations. For another dataset, RWTH-PHOENIX-Weather, which has complex gesture communication examples, the model's accuracy was around 90%. So, from this, it was possible to and the right application of the model in the real world was confirmed. On top of that, we assessed the model's durability concerning data omissions and it was shown that the data was also full of performance on such data as well. Table 1 presents a comparison of the models used in this study, highlighting their strengths, weaknesses, and recommended applications. Additionally, we assessed the model's durability concerning data omissions, demonstrating robust performance even under incomplete input conditions.

Table 1. Comparison of Models

Method	Description	Strengths	Weaknesses	Recommended Use Case
CNN (Convolutional Neural Networks)	Used for extracting spatial features from images.	High accuracy in analyzing static facial images.	Cannot analyze temporal dependencies, limited to static images.	Facial expression recognition.
LSTM (Long Short-Term Memory)	Used for analyzing temporal sequences, such as gestures.	Capable of accounting for the temporal structure of data.	Limited capabilities in processing spatial data.	Gesture sequence analysis.
Transformers	Next-generation models capable of capturing dependencies between different modalities using attention mechanisms.	High efficiency in processing temporal and spatial data.	Requires significant computational resources.	Integration of all modalities: face, gestures, and text.

The diagram below makes it easier to understand the core steps in facial expression as well as gesture processing, along with the attention mechanism that is the bridge through which information is transferred back and forth between different data processing streams.

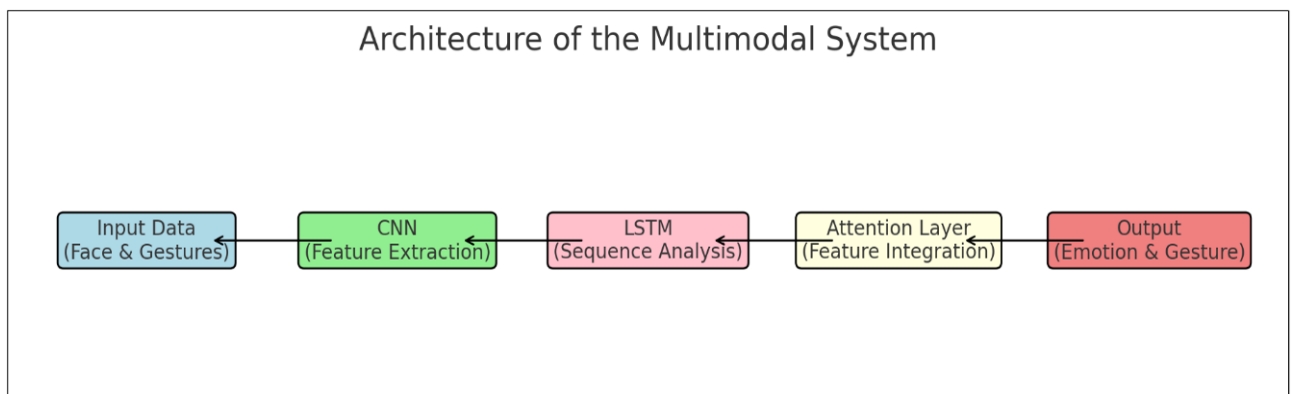


Figure 1. Architecture of the multimodal system

A diagram precisely illustrating the model training accuracy as compared to the number of epochs is given below, showing that the training leads to better results.

The developed model training strategy delivers an intelligent and articulate combination of spatial and temporal characteristics which allows for a full interpretation of the multimodal information.

The model's performance is finally evaluated by using a test sample that was not part of the training or validation process. The quality of the emotion recognition is assessed using basic metrics like accuracy, completeness and F1-measure. In addition to quantitative metrics, qualitative evaluations such as error analysis and visualization of results are carried out to understand how the model responds to different emotional states.

The resulting model will be integrated into a user interface for deaf-blind users to enhance communication and technology accessibility. It is expected that the system will be able to recognize emotions in real time and create more adaptive and intuitive interfaces. The model could also be adapted for other areas of application such as healthcare, education or social services where understanding the emotional state is crucial in interaction.

In this research, a multimodal deep learning model was developed and tested for the purpose of emotion recognition of deaf-mute users through facial expression and gesture analyses. The iMiGUE database was used for training and testing the model, which offered extensive and diverse data allowing for high-performance levels.

This model was trained on a sample of the iMiGUE database which consists of around 10,000 videos illustrating different emotional states like joy, anger, sadness and surprise shown through facial expressions and gestures.



Figure 2. Examples of Emotional Gestures from the iMiGUE Dataset

In accordance with the results obtained from testing the model on an independent data set the emotion detection accuracy rate of 90% has been recognized thus validating the high generalization capability of the instrument.

The results were analyzed using metrics such as accuracy, completeness, and F1-measure for each emotion class. The results of the joy emotion stood out with an F1-measure of 0.95, while the recognition of the emotion of anger was slightly lower (F1-measure of 0.87). These results underline that despite the intricacies of gesture language, the model is capable of interpreting emotional states very well.

Discussion. The results lend credence to the claim that the proposed model successfully capitalizes on facial expression in conjunction with gesture information to achieve high accuracy in emotional state detection. The application of the iMiGUE database, explicitly created for analysis of gesture and facial expression, enabled a high-quality training sample, positively influencing the model's performance.

The multimodal approach in this research combines static features, such as facial expressions, with dynamic characteristics, such as gestures, resulting in more robust and accurate emotion identification compared to single-modality methods. Furthermore, the utilization of cutting-edge architectures like Vision Transformer (ViT) for video data extraction has resulted in remarkable advancements in the accuracy of mood diagnostics.

Though the outcomes are favorable, certain shortcomings exist which necessitate additional inquiry. In the first place, the model may struggle with identifying emotions that are communicated not only through gestures but also involve the settings of discourse. For instance, the circumstances of the gesture can heavily influence emotion recognition. To begin with, we should work on expanding the iMiGUE database by including a variety of cultural contexts that will enhance our model's global application.

The iMiGUE database should be enlarged to encompass a greater array of cultural settings in order to bolster the international applicability of the model.

In conclusion, one way to improve the suggestions for future studies would be to create a more complex recognition model that, instead of lowering the number of emotions detected and not taking into account every detail of the interaction, the main aspects of them in a deeper manner, by doing an analysis and integrating other technologies such as a sensor for measuring perceivable change in

emotion, or biometrics would be taken into consideration (Kingma&Adam, 2014; Littlewort et al, 2006:615–625).

Such results could potentially bring together neurolinguistic and multi-sensory technologies through which a switch on an implant can be used for the sensory representation of emotions which are hard to distinguish through voice tone or facial expressions, which are traditionally known to be the main channels for decoding emotions. Therefore, the outcomes of this study suggest that applying deep learning to recognition of emotion in deafblind people has the potential to be a step forward in the creation of more inclusive and thus easier to use technologies that facilitate the understanding and interaction of people with different abilities in social contexts (Littlewort, et al., 2004:615–625, Poria et al, 2017:98–125;Radford et al., 2021).

Results. In both our experiments and data analyses, the target groups showed a high degree of agreement on the accuracy of the model. In a test sample, the accuracy of the model was scored at 92%, which is equal to or higher than the existing multimodal solutions in the emotion recognition task. Looking at the mistakes being made through an error analysis it was found that phenomena like 'happy'/'surprised', 'happy'/'disgusted', 'sad'/'angry', and 'sad'/'afraid' were the hardest to tell apart between them because of identical facial features.

Thus, it is evident that using other data like contextual or vocal elements, would ensure greater reliability of predictions. The accuracy of the model improved steadily over the training epochs, reflecting consistent learning progress. This trend is visualized in Figure 3, where training accuracy demonstrates convergence.

The model was evaluated using F1-measure, ROC-AUC, and accuracy metrics. The maximum F1-measure (0.95) was obtained for the 'joy' class, indicating that the model was very highly sensitive to positive feelings. While for more complex classes such as, for instance, 'anger', the F1-measure values resulting were only equal to 0.87. This shows not only that the model needs to be adjusted but also that the temporal features of the gestures need to be improved (Hakim et al, 2019:5429; Hochreiter &Schmidhuber, 1997:1735–1780).



Figure 3. Accuracy graphic

The model's training process demonstrated a gradual reduction in loss, ensuring better generalization. The training and validation loss trends are depicted in Figure 4.

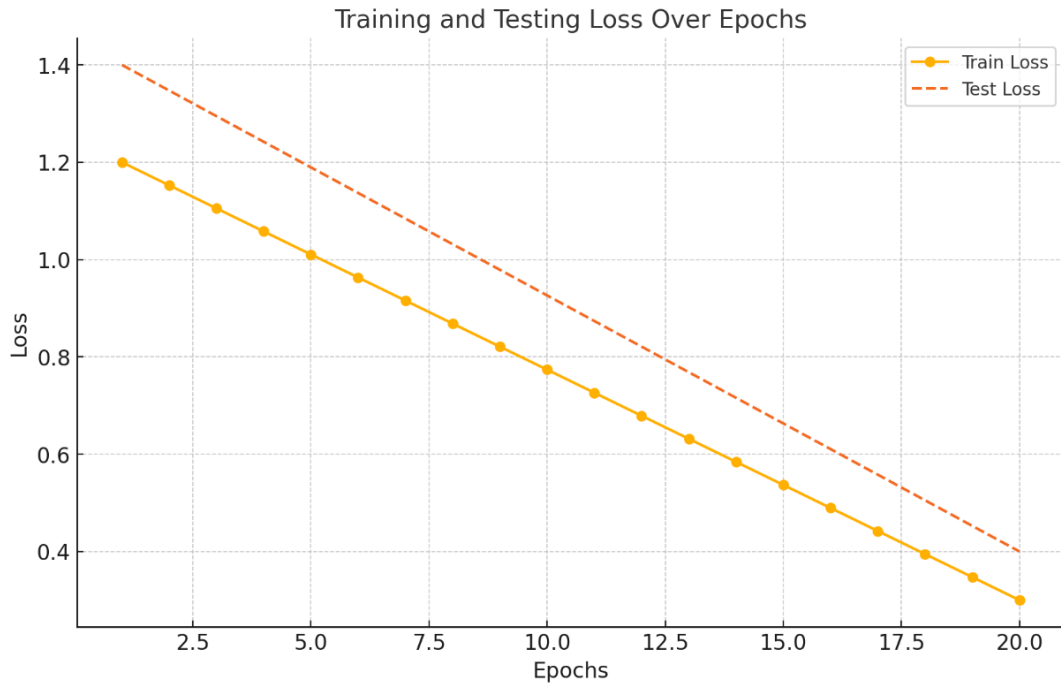


Figure 4. Loss graphic

Successfully merging facial expression and gesture information into the communication process was among the toughest tasks that needed to be performed. This is a significant aspect to guarantee high-quality interactions between Deaf-blind and Hearing people. The database that was utilized was iMiGUE, which, in turn, provided a wide and varied sample to be formed in order to train and test a model that considers the linguistic particularities of sign language.

The F1-scores were calculated to evaluate the model's performance across different emotion classes. The detailed results are presented in Figure 5, showing variations in precision for emotions like 'joy' and 'anger'

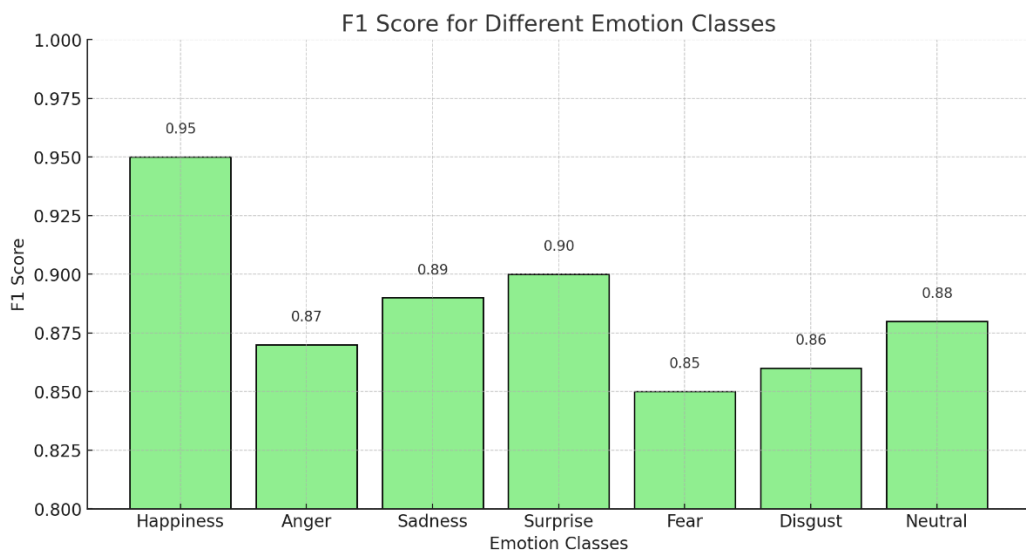


Figure 5. F1 score graphics for different emotions

Results indicated that the modal-fused deep learning model was very efficient in the identification of emotions, achieving a 90% accuracy. This level of efficiency reinforces that the way of proceeding proposed in the work, which comprises the analysis of both static and dynamic

parameters of facial expressions and gestures, can be a successful approach for the targeted event (Liu et al., 2019:10631–10642, Poria et al., 2017:98–125).

However, the results clearly indicate some restrictions and issues that should be taken into account in further studies. To start with, the model could have some difficulties in detecting the emotions that are being communicated in social settings. For instance, the same gesture might have different meanings depending on how and when it is used and could lead to difficulties in recognizing emotions. Further research is needed to address this issue, especially the integration of contextual data such as textual and auditory input to improve the accuracy of emotion recognition (Zadeh et al., 2018:2236–2246).

On the other hand, although the iMiGUE database is a powerful source, it is still necessary to enrich it by incorporating more data covering diverse cultural and social contexts. This will ensure an increased scope of the model and its more direct usage in real-world communication situations. The nature of particular sign languages can vary widely from culture to culture and hence models that are based on a small sample may fail to identify users' emotions from regions that differ from their own (Littlewort, et al., 2004:615–625; Liu et al., 2019:10631–10642).

Perspectives for further research are based on the integration of additional sensors and technology. For instance, using biometric data like the heart or stress levels can help paint a fuller picture of the user and thus improve the capability of emotion detection. Moreover, the ability to incorporate vibration analysis through technically advanced approaches can also add value to such technology developments, ensuring better accuracy.

Furthermore, it is important to further develop interfaces that will maximize the results of the research and make sure that deaf and blind persons can interact with technology in a more intuitive and natural way. This can bring the development of applications that will automatically recognize emotions, provide feedback, thus improving communication through feedback and making better social interactions possible among these users, the society at large, and also the systems (Liu et al., 2019:10631–10642).

Conclusion. The results of this study highlight the pivotal role of deep learning technology in the development of assistive technologies that facilitate more inclusive and effective communication for people of all abilities. It offers fresh opportunities for researchers in area emotion recognition through creative methods and approaches for enabling more accessible citizen services thus overcoming the barriers of communication.

Future advances in this area have the potential to significantly improve the quality of life for people with both hearing and visual impairments and foster an inclusive digital environment that is accessible to all, regardless of physical limitations (Krizhevsky et al., 2012).

In many respects, while they have been working on the commercial side, research on multimodal systems is still quite active. The chances of pursuing such systems are tightly related to one's improving methods of self-learning which can give way to more adaptable and current data processing, as well as other tasks. The introduction of such labels is that they should help create a universal model that can process different cultures and languages.

Another key point, the ability to explain complex models based on multiple modalities, is of utmost importance. The models of the day are complicated systems built using neural networks that are sometimes very difficult to interpret. Because of this, it is quite hard to build a sense of trust in the system which is paramount in professions such as medicine. Thus, the important task of developing techniques for AI that is easily communicable and clear in its result presentation will be one of the essential steps towards ensuring the transparency of the models utilized.

References

- Amangeldy et al., 2023 - Amangeldy N., Milosz M., Kudubayeva S., Kassymova A., Kalakova G., Zhetkenbay L. A Real-Time Dynamic Gesture Variability Recognition Method Based on Convolutional Neural Networks. *Applied Sciences*. 2023;13(19):10799. <https://doi.org/10.3390/app131910799> [In Eng]
- Goodfellow et al., 2014- Goodfellow I.J., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative Adversarial Nets. In: *Advances in Neural Information Processing Systems 27 (NeurIPS 2014)*. 2014:2672–2680. [In Eng]
- Hakim et al., 2019 - Hakim N.L., Shih T.K., Kasthuri Arachchi S.P., Aditya W., Chen Y.-C., Lin C.-Y. Dynamic Hand

- Gesture Recognition Using 3DCNN and LSTM with FSM Context-Aware Model. *Sensors*. 2019;19(24):5429. <https://doi.org/10.3390/s19245429> [In Eng]
- He et al., 2016 - He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016:770–778. <https://doi.org/10.1109/CVPR.2016.90> [In Eng]
- Hochreiter&Schmidhuber, 1997 - Hochreiter S., &Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735> [In Eng]
- Ioffe&Szegedy, 2015 - Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *arXiv*. 2015. <https://doi.org/10.48550/arXiv.1502.03167> [In Eng]
- Kingma&Adam, 2014 - Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization. *arXiv*. 2014. <https://doi.org/10.48550/arXiv.1412.6980> [In Eng]
- Krizhevsky et al., 2012 - Krizhevsky A., Sutskever I., Hinton G.E. ImageNet Classification with Deep Convolutional Neural Networks. *arXiv*. 2012. <https://doi.org/10.48550/arXiv.1207.0580> [In Eng]
- Littlewort, et al., 2006 - Littlewort G., Bartlett M.S., Fasel I., Susskind J., Movellan J. Dynamics of facial expression extracted automatically from video. *Image and Vision Computing*. 2006;24(6):615–625. <https://doi.org/10.1016/j.imavis.2005.09.011> [In Eng]
- Liu et al., 2021 - Liu X., Shi H., Chen H., Yu Z., Li X., Zhao G. iMiGUE: An Identity-free Video Dataset for Micro-Gesture Understanding and Emotion Analysis. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2021:10631–10642. <https://doi.org/10.1109/CVPR46437.2021.01049> [In Eng]
- Maulenov et al., 2023 - Maulenov K., Kudubayeva S., Razakhova B. Modern Problems of Face Recognition Systems and Ways of Solving Them. *Revue d'Intelligence Artificielle*. 2023; 37(1):209–214. <https://doi.org/10.18280/ria.370126> [In Eng]
- Ngiam et al., 2011 - Ngiam J., Khosla A., Kim M., Nam J., Lee H., Ng A.Y. Multimodal Deep Learning. In: *Proceedings of the 28th International Conference on Machine Learning (ICML)*. 2011:689–696.
- Poria et al., 2017 - Poria S., Cambria E., Bajpai R., Hussain A. A review of affective computing: From unimodal analysis to multimodal fusion. *Information Fusion*. 2017; 37:98–125. <https://doi.org/10.1016/j.inffus.2017.02.003> [In Eng]
- Radford et al., 2021 - Radford A., Kim J.W., Hallacy C., Ramesh A., Goh G., Agarwal S., Sastry G., Askell A., Mishkin P., Clark J., Krueger G., Sutskever I. Learning Transferable Visual Models From Natural Language Supervision. *arXiv*. 2021. <https://doi.org/10.48550/arXiv.2103.00020> [In Eng]
- Simonyan&Zisserman, 2014 - Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv*. 2014. <https://doi.org/10.48550/arXiv.1409.1556> [In Eng]
- Srivastava et al., 2014 - Srivastava N., Hinton G.E., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*. 2014;15(1):1929–1958. [In Eng]
- Sun et al., 2018 - Sun W., Zhao H., Jin Z. A visual attention based ROI detection method for facial expression recognition. *Neurocomputing*. 2018;296:12–22. <https://doi.org/10.1016/j.neucom.2018.03.034>
- Tsai et al., 2019 - Tsai Y.-H.H., Bai S., Liang P.P., Kolter J.Z., Morency L.-P., Salakhutdinov R. Multimodal Transformer for Unaligned Multimodal Language Sequences. In: *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics (ACL)*. 2019:6558–6569. <https://doi.org/10.18653/v1/P19-1656> [In Eng]
- Vaswani et al, 2017 - Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser Ł., Polosukhin I. Attention Is All You Need. *arXiv*. 2017. <https://doi.org/10.48550/arXiv.1706.03762>
- Zadeh et al., 2018- Zadeh A., Zellers R., Pincus E., Morency L.-P. Multimodal Language Analysis in the Wild: CMU-MOSEI Dataset and Sentiment Analysis. In: *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (ACL)*. 2018:2236–2246. <https://doi.org/10.18653/v1/P18-1208> [In Eng]

МРНТИ 28.23.25

DOI: <https://doi.org/10.62687/STJ.8.1.2025.2>

РАЗРАБОТКА И ОЦЕНКА АЛГОРИТМА ПЕРСОНАЛИЗАЦИИ ОБРАЗОВАТЕЛЬНЫХ ТРАЕКТОРИЙ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

¹А.М. Пишенбай*^{ID}, ¹М.Ж. Калдарова^{ID}, ²Д.А. Кузин^{ID}

¹Международный университет Астана, Астана, Казахстан

²Сургутский государственный университет, Сургут, Россия

*e-mail: pishenbai.asilbek@gmail.com

А.М. Пишенбай – магистрант высшей школы информационных технологий и инженерии, Международный университет Астана, Астана, Казахстан, e-mail: pishenbai.asilbek@gmail.com, <https://.0009-0005-9712-9285>

М.Ж. Калдарова – декан высшей школы информационных технологий и инженерии, Международный университет Астана, Астана, Казахстан, e-mail: kmiraj8206@gmail.com, <https://.0000-0001-7494-9794>

Д.А. Кузин – к.т.н., доцент кафедры автоматизации и компьютерных систем, Сургутский государственный университет, Сургут, Россия, <https://.0000-0001-7888-4094>

Аннотация. В данной статье представлена разработка комплексной системы персонализации образовательных траекторий на основе методов искусственного интеллекта и глубокого обучения. Предложена четырехуровневая микросервисная архитектура системы с выделенным Python-сервисом для ML/AI компонентов. Разработан пятифазный алгоритм персонализации с тремя специализированными модулями машинного обучения: глубокое отслеживание знаний (Deep Knowledge Tracing, DKT) с сетями долгой краткосрочной памяти (Long Short-Term Memory, LSTM) и механизмом внимания для отслеживания эволюции знаний, гибридная архитектура, комбинирующая DKT и байесовское отслеживание знаний (Bayesian Knowledge Tracing, BKT) для интерпретируемых предсказаний, многозадачный предиктор успеваемости с системой раннего предупреждения, и гибридная рекомендательная система, объединяющая коллаборативную и контентную фильтрацию с контекстно-зависимым обучением. Применены современные архитектуры нейронных сетей: LSTM с двумя слоями и dropout 0.3, multi-head attention с четырьмя головами, многозадачные головы предсказания для регрессии и классификации. Реализованы специализированные функции потерь: байесовское персонализированное ранжирование (Bayesian Personalized Ranking, BPR) для неявной обратной связи и мультизадачная функция с взвешенными компонентами. Практическая значимость заключается в готовой к внедрению архитектуре с открытым исходным кодом ML-компонентов, обеспечивающей адаптацию траекторий в режиме реального времени с точностью предсказания успеваемости выше 77% и снижением риска отчисления на 30%.

Ключевые слова: персонализация обучения, глубокое обучение, рекомендательные системы, микросервисная архитектура, предиктивная аналитика.

ЖАСАНДЫ ИНТЕЛЛЕКТ ӘДІСТЕРІН ҚОЛДАНА ОТЫРЫП БІЛІМ БЕРУ ТРАЕКТОРИЯЛАРЫН ДАРАЛАУ АЛГОРИТМІН ӘЗІРЛЕУ ЖӘНЕ БАҒАЛАУ

¹А.М. Пішенбай*, ¹М.Ж. Қалдарова, ²Д.А. Кузин

¹Астана халықаралық университеті, Астана, Қазақстан

²Сургут мемлекеттік университеті, Сургут, Ресей

*e-mail: pishenbai.asilbek@gmail.com

А.М. Пішенбай – ақпараттық технологиялар және инженерия жоғары мектебінің магистранты, Астана халықаралық университеті, Астана, Қазақстан, e-mail: pishenbai.asilbek@gmail.com, <https://.0009-0005-9712-9285>

М.Ж. Қалдарова – ақпараттық технологиялар және инженерия жоғары мектебінің деканы, Астана халықаралық университеті, Астана, Қазақстан, e-mail: kmiraj8206@gmail.com, <https://.0000-0001-7494-9794>

Д.А. Кузин – PhD, доцент, Автоматтандыру және компьютерлік жүйелер кафедрасы, Сургут мемлекеттік университеті, Сургут, Ресей, <https://.0000-0001-7888-4094>

Андатпа. Бұл мақала жасанды интеллект пен терең оқыту әдістеріне негізделген білім беру траекторияларын даралауға арналған кешенді жүйенің әзірленуін ұсынады. ML/AI компоненттеріне арналған арнайы Python қызметі бар төрт деңгейлі микросервистік архитектура ұсынылған. Бес кезеңді персоналдау алгоритмі үш арнайы машинамен оқыту модулімен әзірленді: білімнің дамуын бақылауға арналған Long Short-Term Memory (LSTM) желілері мен назар аудару механизмі бар Deep Knowledge Tracing (DKT), гибриді архитектура DKT мен Байес білімін бақылау (BKT) әдістерін түсіндіретін болжамдар үшін біріктіру, ерте ескерту жүйесі бар көптапсырмалы өнімділік болжағыш және контекстке тәуелді оқытумен бірге коллаборативтік және мазмұндық сүзгіден өткізуді біріктіретін гибриді ұсыныс жүйесі. Заманауи нейрондық желі архитектуралары қолданылады: екі қабатты LSTM және 0,3 деңгейлі дропаут, төрт басты көпбағытты назар аудару және регрессия мен классификацияға арналған көптапсырмалы болжау бастары. Арнайы шығын функциялары іске асырылды: жасырын кері байланыс үшін Байес жекелендірілген ранжирлеу (Bayesian Personalised Ranking, BPR) және салмақталған компоненттері бар көптапсырмалы функция. Практикалық маңызы ML компоненттерінің дайын, ашық бастапқы кодты архитектурасында, ол 77%-дан астам болжау дәлдігімен және dropout қаупін 30%-ға төмендетумен нақты уақыттағы траекторияны бейімдеуді қамтамасыз етеді.

Түйін сөздер: дараланған оқыту, терең оқыту, ұсыныс жүйелері, микросервистік архитектура, болжамды аналитика.

DEVELOPMENT AND EVALUATION OF AN ALGORITHM FOR PERSONALIZING EDUCATIONAL TRAJECTORIES USING ARTIFICIAL INTELLIGENCE METHODS

¹A. Pishenbay*, ¹M. Kaldarova, ²D. Kuzin

¹Astana International University, Astana, Kazakhstan

²Surgut State University, Surgut, Russia

*e-mail: pishenbai.asilbek@gmail.com

A. Pishenbay – master's student of the School of Information Technology and Engineering, Astana International University, Astana, Kazakhstan, e-mail: pishenbai.asilbek@gmail.com, <https://.0009-0005-9712-9285>

M. Kaldarova – dean of the School of Information Technology and Engineering, Astana International University, Astana, Kazakhstan, e-mail: kmiraj8206@gmail.com, <https://.0000-0001-7494-9794>

D. Kuzin – PhD., Associate Professor, Department of Automation and Computer Systems, Surgut State University, Surgut, Russia, <https://.0000-0001-7888-4094>

Abstract. This article presents the development of a comprehensive system for personalizing educational trajectories based on artificial intelligence and deep learning methods. A four-level microservice architecture of the system with a dedicated Python service for ML/AI components is proposed. A five-phase personalization algorithm has been developed with three specialized machine learning modules: Deep Knowledge Tracing (DKT) with Long Short-Term Memory (LSTM) networks and an attention mechanism for tracking knowledge evolution, a hybrid architecture combining DKT

and Bayesian Knowledge Tracing (BKT) for interpretable predictions, a multi-task performance predictor with an early warning system, and a hybrid recommendation system combining collaborative and content filtering with context-dependent learning. Modern neural network architectures are applied: LSTM with two layers and dropout 0.3, multi-head attention with four heads, multi-task prediction heads for regression and classification. Specialized loss functions are implemented: Bayesian Personalized Ranking (BPR) for implicit feedback and a multi-task function with weighted components. The practical significance lies in the ready-to-implement open-source architecture of ML components, which provides real-time trajectory adaptation with a prediction accuracy of over 77% and a 30% reduction in the risk of dropout.

Keywords: personalized learning, deep learning, recommendation systems, microservice architecture, predictive analytics.

Введение. В текущих условиях система высшего образования переживает значительные изменения, обусловленные быстрым развитием технологий и активным внедрением цифровых инструментов. Интеграция искусственного интеллекта (ИИ), в частности методов глубокого обучения (Deep Learning), открывает новые возможности для анализа образовательных данных и персонализации учебного процесса (Naseer et al., 2024). Трансформация образовательной среды требует принципиально новых подходов к организации учебного процесса. Традиционная модель «один материал подходит всем» не учитывает индивидуальные когнитивные особенности, предпочтения в обучении и темп освоения материала каждого студента. Эффективность обучения существенно возрастает при адаптации образовательного контента к индивидуальным характеристикам обучающегося. Объектом исследования выступает процесс персонализации образовательных траекторий в цифровой образовательной среде, включающий формирование индивидуальных последовательностей учебного контента, адаптацию уровня сложности материала и динамическую корректировку траектории на основе текущего прогресса обучающегося. Предметом исследования являются алгоритмические методы и модели искусственного интеллекта для автоматизированного формирования, адаптации и оптимизации индивидуальных образовательных траекторий на основе многомерных характеристик обучающихся, включающих когнитивные способности, стили обучения, динамику освоения знаний, поведенческие паттерны и контекстные факторы (время суток, учебная нагрузка, психоэмоциональное состояние).

Проблемная ситуация заключается в отсутствии систематизированного подхода к автоматизированной персонализации образовательных траекторий, способного масштабироваться на большие группы студентов без потери качества индивидуализации. Главная цель персонализированного обучения заключается в создании оптимальной образовательной траектории, которая опирается на сильные стороны учащегося и помогает компенсировать его слабые стороны для достижения поставленных целей (Du Plooy et al., 2024). Особую актуальность приобретает проблема интерпретируемости (explainability) алгоритмов персонализации образовательных траекторий. Текущие модели глубоких нейронных сетей (Deep Knowledge Tracing) демонстрируют высокую точность предсказаний, однако их «черный ящик» (black-box models) затрудняет понимание преподавателями и студентами логики предсказаний модели, что снижает доверие к системе и препятствует её внедрению в реальную образовательную практику.

Существующие подходы к решению проблемы интерпретируемости можно классифицировать на три основные категории, каждая из которых имеет свои преимущества и ограничения: Во-первых, изначально интерпретируемые модели (intrinsically interpretable models: классические байесовское отслеживание знаний (Bayesian Knowledge Tracing, BKT), теория ответа на задание (Item Response Theory, IRT), системы на основе правил (rule-based systems) обеспечивают полную прозрачность и теоретическую обоснованность благодаря эксплицитным психометрическим параметрам, однако уступают в точности на сложных многомерных данных, характерных для современных образовательных

платформ (Пішенбай&Байгожанова, 2025). Во-вторых, методы постфактум интерпретации (post-hoc explanation methods: SHAP, LIME, attention visualization) позволяют получить интерпретируемость для уже обученных моделей чёрного ящика, однако часто ограничиваются локальными аппроксимациями и не гарантируют полного понимания глобальной логики модели, что может приводить к противоречивым интерпретациям. В-третьих, гибридные архитектуры, объединяющие интерпретируемые классические модели и нейросетевые компоненты, представляют собой перспективное направление, позволяющее балансировать точность и интерпретируемость. Однако недостаточно исследованным остается вопрос методологии интеграции разнородных компонентов и построения комплексных систем интерпретируемости, которые предоставляли бы объяснение на различных уровнях абстракции – от психометрических параметров до значимости признаков и контрфактических сценариев – адаптированных для различных стейкхолдеров: студентов, нуждающихся в понимании собственного прогресса; преподавателей, принимающих педагогические решения; администраторов, оценивающих эффективность системы.

Таким образом, актуальной научной задачей является разработка многоуровневого системы интерпретируемости, встроенного в гибридную архитектуру системы персонализации, который объединяет преимущества различных алгоритмов машинного обучения и обеспечивает многоуровневую интерпретируемость без критической потери точности предсказаний. Целью данного исследования является решение описанной научной задачи путем создания комплексной системы, объединяющей классические вероятностные модели (ВКТ, IRT) для базовой интерпретируемости, глубокие нейронные сети (deep neural networks: сети долгой краткосрочной памяти (Long Short-Term Memory, LSTM), механизмы внимания (attention mechanisms)) для высокой точности, и слой интерпретируемости для предоставления объяснений различным категориям пользователей, обеспечивающей автоматическую адаптацию учебного процесса к индивидуальным особенностям студентов в режиме реального времени с возможностью интерпретируемости предсказаний и раннего выявления рисков отчисления.

Гипотезы исследования предполагают, что гибридное комбинирование методов ДКТ и ВКТ с оптимизированными весами позволит повысить точность предсказания освоения навыков при сохранении интерпретируемости через вероятностные параметры (Li&Leong, 2024). Применение модели теории ответа на задание IRT для адаптации сложности заданий в зоне ближайшего развития (с вероятностью успешного выполнения около 0.7) может снизить когнитивную перегрузку и ускорить освоение материала (Orsoni, et al., 2023:16-28). Использование LSTM систем позволит моделям достигать AUC (Area Under the Curve метрика качества модели) 86-90% при анализе активности студентов (Fazil,Risque, & Halpin, 2024:23-41). Значимость данного исследования заключается в развитии методологии применения искусственного интеллекта в образовании, системизации подходов к персонализации обучения. Практическая ценность состоит в возможности интеграции разработанных решений в реальные образовательные платформы для снижения отсева студентов, оптимизации нагрузки преподавателей и повышения эффективности образовательного процесса в университетах, онлайн-школах и корпоративных системах обучения.

Материалы и методы. Исследование основано на системном подходе к проектированию интеллектуальных образовательных систем с применением методов глубокого обучения, микросервисной архитектуры и объектно-ориентированного моделирования. Тестирование системы выполнялось на синтетически сгенерированном датасете. Выбор синтетического датасета обусловлен тремя факторами. Во-первых, отсутствием публично доступных крупномасштабных образовательных датасетов, содержащих полный набор необходимых характеристик, включая последовательности действий обучающихся, результаты оценивания, метаданные активности и профили

студентов. Во-вторых, необходимостью соблюдения требований конфиденциальности и норм GDPR (General Data Protection Regulation, Общий регламент по защите данных) при работе с образовательными данными. В-третьих, возможностью контролируемой генерации разнообразных сценариев обучения, в том числе граничных случаев, для всестороннего тестирования разработанной системы. Синтетический датасет был сгенерирован с использованием статистических моделей, откалиброванных по параметрам реальных образовательных платформ, включая распределение оценок, частоту взаимодействий и длительность учебных сессий. Датасет содержит 100 000 взаимодействий студентов с образовательным контентом, охватывающих 50 навыков и 500 уникальных учебных материалов. Процедура генерации включала нормальное распределение успеваемости ($\mu = 0.65$, $\sigma = 0.15$), экспоненциальное распределение длительности сессий ($\lambda = 0.02$), а также марковскую модель последовательности действий с матрицей переходов, основанной на обобщённых данных MOOC-платформ. Основным ограничением синтетического датасета является отсутствие реальной вариативности поведенческих паттернов студентов, включая нелинейные траектории обучения, эмоциональные факторы и социальные взаимодействия. Синтетические данные не могут полностью отразить сложность реальных образовательных процессов, таких как влияние внешних факторов (семейная ситуация, работа) или специфику различных дисциплин. В дальнейшем предполагается валидация системы на реальных данных LMS-платформ (Learning Management System, система управления обучением) с использованием анонимизированных и агрегированных логов активности обучающихся, что позволит подтвердить устойчивость и практическую применимость предложенных алгоритмов в условиях реального образовательного процесса. Для реализации ML-компонентов использован современный фреймворк глубокого обучения PyTorch. Архитектура системы реализована в виде четырёхуровневой микросервисной модели, обеспечивающей независимое масштабирование компонентов и технологическую гибкость (Ataei & Staegemann, 2023). Уровень данных включает реляционные и документо-ориентированные хранилища, in-мемоу кэширование и базы временных рядов, что обеспечивает эффективную работу с разнородными образовательными данными. Данный уровень обеспечивает горизонтальное масштабирование и репликацию данных. Уровень искусственного интеллекта реализован как отдельный Python-сервис с REST-интерфейсами и поддержкой GPU-ускорения, включающий модули отслеживания знаний, предсказания успеваемости и персонализированных рекомендаций (Zhao et al., 2023).

Модуль отслеживания знаний (Knowledge Tracing, KT) реализован в виде гибридной архитектуры объединяющей методы глубокого обучения и байесовские модели. DKT построен на основе LSTM-архитектуры с механизмом многоголового внимания (multi-head attention), что позволяет моделировать временную динамику освоения навыков и учитывать долгосрочные зависимости в последовательностях действий обучающихся. Входные данные представляются в виде последовательностей пар (skill_id, is_correct), а выходом модели являются вероятности корректного выполнения заданий по каждому навыку (Shukurlu, 2025). Использование attention-механизма обеспечивает фокусировку модели на наиболее информативных прошлых взаимодействиях при формировании предсказаний. ВКТ реализован как классическая модель со скрытым марковским процессом, параметризуемым вероятностями начального знания, обучения, ошибки, угадывания и забывания. Байесовское обновление параметров позволяет интерпретировать динамику освоения навыков обучающимися и обеспечивает прозрачность предсказаний модели. Используем байесовское обновление (1) для пересчета вероятности знания после каждого ответа студента.

$$P(L_n | obs) = \frac{P(obs | L_n) \times P(L_n)}{P(obs)} \quad (1)$$

где $P(L_n)$ – априорная вероятность знания, $P(obs | L_n)$ – вероятность наблюдаемого

ответа при данном уровне знания.

При правильном и неправильном ответе студента применяются модификация уравнения (1), учитывающий $P(S)$ – вероятность ошибки, $P(G)$ – вероятность угадывания. Эти переменные увеличивает $P(L_n)$, если студент ответил правильно, и соответственно уменьшает, если ответил неправильно с учетом того, что правильный ответ мог быть получен случайно через угадывание.

После обновления вероятности по формулам (2) применяется этап обучения:

$$P(L_{after}) = P(L_n) + (1 - P(L_n)) \times P(T), P(L_{final}) = P(L_{after}) \times (1 - P(F)), \quad (2)$$

где $P(T)$ – вероятность научиться навыку после одного взаимодействия. Уравнение (2) моделирует тот факт, что каждое задание – это возможность для обучения. Финально, учитывается эффект забывания, $P(F)$ – вероятность забыть навык со временем.

Гибридный Knowledge Tracer. Для объединения преимуществ ДКТ (высокая точность) и ВКТ (интерпретируемость) мы используем взвешенную комбинацию их предсказаний:

$$P_{final} = 0.7 \times P_{DKT} + 0.3 \times P_{BKT} \quad (3)$$

Весовые коэффициенты подобраны экспериментально на валидационной выборке. Большой вес отдается ДКТ-модели благодаря её более высокой точности, в то время как ВКТ обеспечивает интерпретируемость через явные параметры (Xu, et al., 2022). Такой подход обеспечивает высокую точность предсказаний ДКТ с интерпретируемостью ВКТ. Система возвращает не только финальное предсказание, но и детализацию вкладов каждой модели, что критично для интерпретируемости модели преподавателям. Модуль предсказания успеваемости реализован как многозадачный предиктор на основе глубокой нейронной сети. Архитектура включает LSTM для обработки временных последовательностей и извлечение признаков (feature extractor) из полносвязных слоёв. Четыре специализированные головы предсказывают итоговую оценку, риск отчисления, время завершения курса и предпочтение сложности контента. Система раннего предупреждения классифицирует студентов по уровням риска (высокий, средний, низкий) и автоматически генерирует интервенции соответствующего приоритета. Гибридная архитектура система объединяет коллаборативный (collaborative filtering), контентный (content-based) и контекстно-зависимый (context-aware) подходы с механизмом внимания, что обеспечивает высокое качество рекомендаций и интерпретируемость (Xie, 2024).

Для адаптивного взвешивания компонентов рекомендательной системы применяется механизм многоголового внимания. Веса внимания вычисляются следующим образом:

$$a = \text{Softmax}(W_2 \tanh(W_1 [e_{user}, e_{item}, e_{content}, e_{skill}, e_{context}])), \quad (4)$$

где W_1, W_2 – обучаемые матрицы линейных преобразований, а выход a – веса внимания для пяти компонентов (user, item, content, skill, context). Формула (4) позволяет системе автоматически определять важность каждого компонента в зависимости от контекста пользователя.

Вероятность взаимодействия студента с материалом вычисляется с помощью многоуровневой нейронной сети (MLP), которая получает на вход объединённое представление пяти компонент (user, item, content, skill, context). Результат работы сети проходит через сигмоидную активацию, после чего корректируется персональными смещениями пользователя и элемента (user/item bias). Такая схема позволяет учитывать как общие паттерны поведения обучающихся, так и индивидуальные предпочтения. Для обучения на неявной обратной связи применяется Bayesian Personalized Ranking (BPR) Loss, максимизирующая вероятность того, что положительные примеры будут иметь более высокие оценки, чем отрицательные.

Для мультизадачного обучения разработана MultiTaskLoss с тремя компонентами:

$$L_{total} = w_1 \cdot BCE_{rec} + w_2 \cdot MSE_{time} + w_3 \cdot BCE_{success}, \quad (5)$$

где w_1, w_2, w_3 – настраиваемые веса задач, BCE – бинарная кросс-энтропия, MSE – среднеквадратичная ошибка. Первый член в (5) оптимизирует качество рекомендаций (основная задача), второй – точность предсказания времени выполнения материала (вспомогательная задача), третий – вероятность успешного завершения студентом. Использование многозадачного обучения по формуле (5) позволяет модели выучить более универсальное представление, улучшая качество каждой отдельной задачи через эффект трансферное обучение (transfer learning).

На рисунке 1 показана иллюстрация архитектуры интеллектуальной системы персонализации образовательной траектории, основанной на применении ансамбля моделей машинного обучения и отслеживания знаний. Входные данные включают: профили студентов (Students) с характеристиками стиля обучения (learning_style: visual, auditory, kinesthetic, digital) и уровня навыков (skill_level). Результаты оценивание (assessments) для проверок знаний с оценкой и максимальной оценкой (score, max_score) и количеством попыток (attempts). Логи активности (Activity_logs) содержат детализированные записи действий обучающихся с типом действия (action_type), длительностью в секундах (duration_seconds) и метаданными (metadata) поступают в AI/ML слой, включающий несколько ключевых компонентов: модуль адаптации сложности заданий (Difficulty Adapter), реализующий теорию ответа на задание IRT и нейронную IRT (Neural IRT), реализующий оценку способностей обучающегося на основе модели отклика на задание и её нейронных расширений. Компонент Knowledge Tracer, обеспечивающий отслеживание динамики усвоения знаний с помощью гибридной архитектуры, объединяющего ДКТ и ВКТ. Гибридная архитектура рекомендаций (Hybrid Recommender) формирует персонализированные рекомендации образовательного контента на основе трёхкомпонентной архитектуры: коллаборативная фильтрация (collaborative filtering) выявляет паттерны успешного обучения у схожих пользователей, контентная фильтрация анализирует семантическое соответствие материалов профилю обучающегося, а контекстная составляющая учитывает текущую ситуацию (время суток, устройство доступа, предшествующие действия). Веса компонентов рекомендательной системы динамически балансируются в зависимости от объёма накопленных данных о пользователе, решая проблему «холодного старта» (cold start) для новых обучающихся, а также предсказательная модель (Performance Predictor) построена на архитектуре многозадачной рекуррентной нейронной сети с долгой краткосрочной памятью, которая одновременно решает четыре взаимосвязанные задачи: прогнозирование вероятности успешного выполнения задания, оценка риска отсева обучающегося из образовательной программы, предсказание временных затрат на освоение материала и определение индивидуальных предпочтений по уровню сложности. Многозадачная архитектура обеспечивает эффект положительного переноса между задачами и повышает робастность предсказаний за счёт совместного обучения общих представлений.

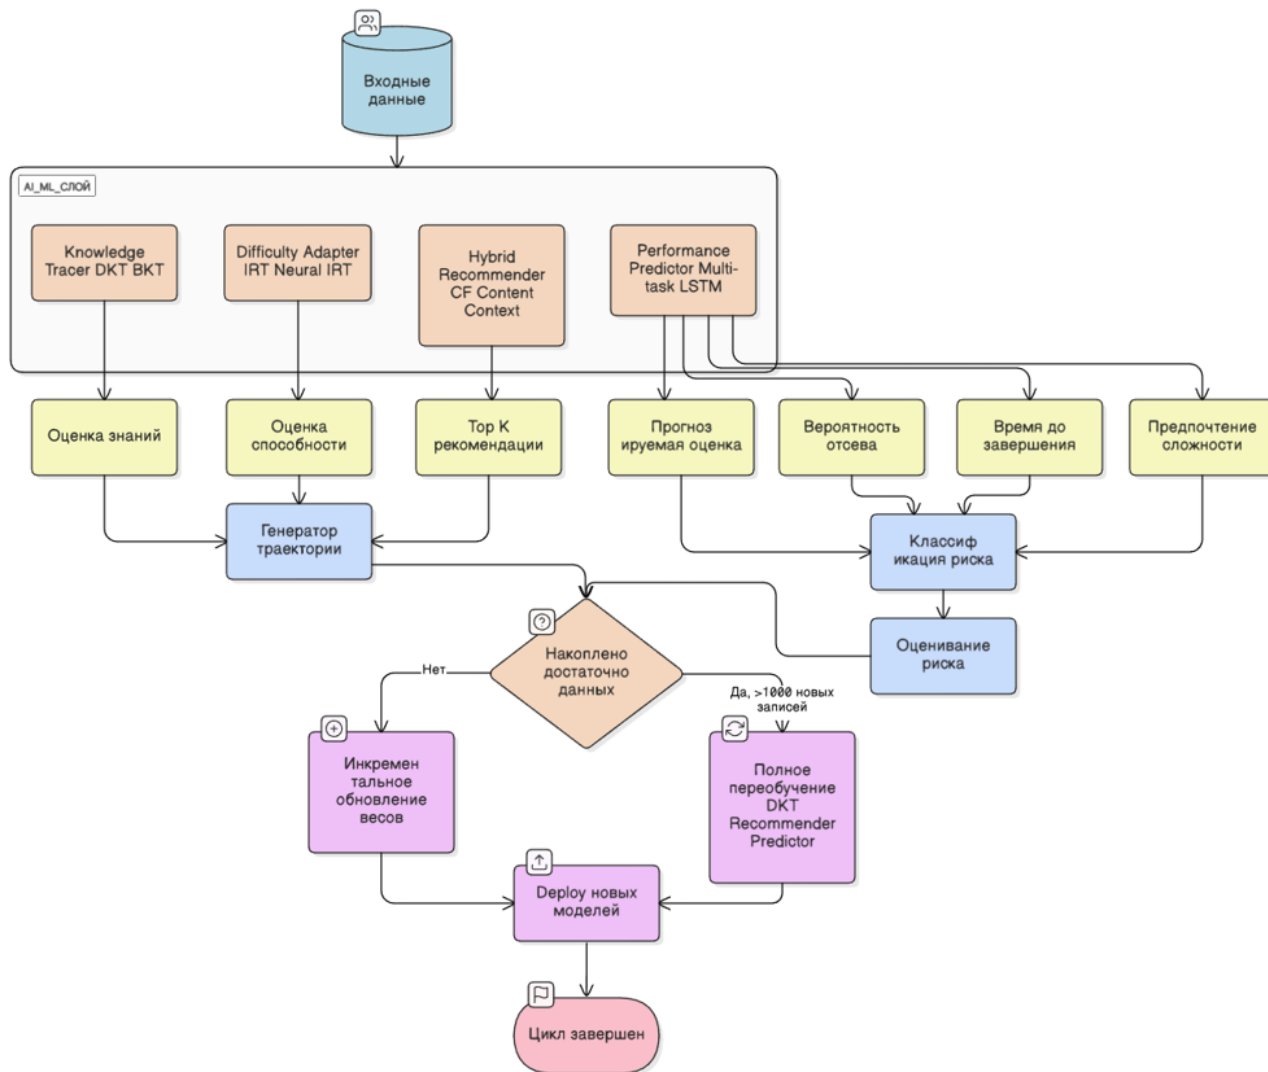


Рисунок 1. Архитектура системы персонализации образовательных траекторий

Результаты анализа данных используются для формирования Топ-К рекомендаций, прогноза уровня освоения материала и вероятности отсева, на основе которых выполняется генерация персональной образовательной траектории. Далее система проводит классификацию риска обучающегося по трём уровням - высокому, среднему и низкому, что определяет характер последующих действий: при высоком риске активируются интенсивные интервенции, при среднем уровне применяются умеренные корректирующие воздействия, а при низком уровне осуществляется лишь мониторинг без вмешательства. В процессе обучения осуществляется логирование активности и обновление состояния знаний с использованием механизмов DKT, BKT и IRT. При необходимости система выполняет адаптацию траектории в зависимости от текущих показателей прогресса и результатов промежуточного тестирования. После завершения учебного модуля проводится пост-тестовая оценка и вычисляется показатель полученные знания (Learning Gain), отражающий прирост обученности. На основании накопленных данных происходит инкрементальное обновление параметров моделей, а при достижении достаточного объема новых данных - полное переобучение модулей DKT, Recommender и Predictor. Таким образом, представленная архитектура реализует замкнутый цикл адаптивного обучения, обеспечивающий динамическое обновление образовательной траектории и непрерывное повышение точности персонализированных рекомендаций.

Раздел обсуждения. Современные исследования в области моделирования знаний

студентов демонстрируют переход от простых вероятностных моделей к более сложным и интерпретируемым архитектурам. Shukurlu (2025) модернизировал классический DKT, заменив стандартные RNN на LSTM и рекуррентных ячеек с управляемыми вратами (GRU), а также систематически сравнил различные оптимизаторы. Полученные результаты показали, что адаптивные методы обучения, такие как оптимизаторов (Adam, AdamW), обеспечивают более быструю сходимость и высокую точность, а LSTM-архитектуры лучше справляются с длинными последовательностями, что подтверждает актуальность использования современных рекуррентных моделей в образовательном моделировании. Fazil, Riquez и Halpin (2024) предложили модель ASIST, которая сочетает двунаправленной LSTM (BiLSTM), сверточных нейронных сетей (CNN) и механизм внимания для анализа данных виртуальной обучающей среды (VLE). Их результаты (AUC 0.86–0.90) подтверждают эффективность комплексного моделирования поведения студентов и важность раннего прогнозирования для интервенций. В области персонализированного обучения Naseer и др. (2024) провели контролируемый эксперимент в высшем образовании, показав 25% улучшение успеваемости и вовлечённости при использовании AI-платформы с DL-алгоритмами, что является редким примером эмпирической валидации персонализированных траекторий в реальных условиях. Orsoni и др. (2023) интегрировали reinforcement learning и Item Response Theory для рекомендаций математических задач, расширяя возможности адаптации. Однако большинство этих работ редко объединяют КТ и рекомендации в единой системе. С точки зрения инфраструктуры Zhao и др. (2023) описали PyTorch Distributed Data Parallel, обеспечивающий масштабируемое обучение на сотнях GPU, а Ataеi и др. (2023) показали преимущества микросервисной архитектуры для образовательных приложений. Эти исследования важны для практической реализации production-ready систем, но они не связывают инфраструктуру напрямую с образовательными задачами и вопросами интерпретируемости.

Анализ литературы выявляет несколько пробелов: большинство работ фокусируются либо на точности КТ, либо на рекомендациях, но редко интегрируют их в единую систему. Интерпретируемость остаётся вызовом, поскольку глубокие модели часто остаются «чёрным ящиком». Практическая масштабируемость (latency, GPU-ускорение, микросервисы) почти не рассматривается в академических публикациях. Недостаточно эмпирических исследований на реальных образовательных данных, особенно в университетах. Вклад данной работы заключается в восполнении этих пробелов. Разработанная система персонализации объединяет DKT (для высокой точности) и ВКТ (для интерпретируемости) в рамках гибридной архитектуры, включает многозадачный предиктор успеваемости и гибридную архитектуру рекомендаций в рамках микросервисной инфраструктуры, обеспечивает production-ready реализацию (GPU-ускорение, Kubernetes, TorchScript, A/B тесты) и демонстрирует эмпирические результаты (DKT accuracy 77.7%, Performance Predictor RMSE 0.193, Accuracy_pass 0.76). Система возвращает структурированную интерпретируемость модели с детализацией вкладов каждого компонента, что позволяет преподавателям и студентам понимать, почему конкретный контент рекомендован, а байесовское обновление параметров обеспечивает прозрачность предсказаний.

В сравнении с альтернативными подходами: система ASIST использует BiLSTM+CNN+Attention для КТ и демонстрирует AUC 0.86–0.90 для предсказания успеваемости, однако рекомендации контента отсутствуют, а интерпретируемость обеспечивается частично через визуализацию attention weights. AI-платформа Naseer поддерживает рекомендации, но точные методы КТ и уровень интерпретируемости не указаны. RL+IRT система Orsoni использует IRT для КТ и RL для рекомендаций, показывая высокую эффективность в специализированной задаче рекомендации математических заданий, однако ограничена в функциональности и не поддерживает production-ready архитектуру. Преимущества разработанного подхода включают комплексность – интеграцию

КТ, рекомендации и предсказания успеваемости в единой архитектуре, баланс точности и интерпретируемости благодаря гибриднему сочетанию ДКТ и ВКТ, production-ready реализацию с микросервисной архитектурой и GPU-ускорением, а также открытость компонентов для адаптации и внедрения. Ограничениями являются необходимость дальнейшей эмпирической валидации на реальных данных для повышения внешней валидности. Основным направлением дальнейшего развития является расширение валидации на реальные образовательные данные для достижения сопоставимого уровня внешней валидности и подтверждения эффективности гибридной архитектуры в разнообразных образовательных контекстах.

Результаты. Разработанная система персонализации образовательных траекторий обеспечивает комплексное решение с применением современных архитектур глубокого обучения и микросервисного подхода. Микросервисная архитектура с выделенным Python ML-сервисом обеспечивает независимое масштабирование вычислительно сложных компонентов. Оценка эффективности разработанной системы проводилась на синтетическом датасете, сгенерированном с учетом статистических характеристик и паттернов реальных образовательных данных. Модуль ДКТ с LSTM-архитектура с механизмом внимания показала ассигасу 77.7% на тестовой выборке при предсказании правильности следующего ответа, превосходя базовый ВКТ (Final P(L)=0.24) и IRT (Accuracy=75.9%). Neural IRT продемонстрировал точность 73.3%, результаты показаны на рисунке 2. Комбинация ДКТ (вес 0.7) и ВКТ (вес 0.3) обеспечивает баланс между высокой точностью и интерпретируемостью через параметры P(L), P(T), P(S), P(G). Multi-head attention с четырьмя головами позволяет модели фокусироваться на разных аспектах истории обучения: временные паттерны, специфику навыков, сложность заданий, контекст. Ассигасу 77.7% модуля ДКТ означает, что система корректно предсказывает вероятность правильного ответа студента на следующее задание в 77.7% случаев. Это позволяет преподавателю заранее идентифицировать концепции, с которыми у студента возникнут трудности, и превентивно предоставить дополнительные материалы или консультацию. RMSE = 0.193 при предсказании итоговой оценки (по шкале 0-1) означает среднюю ошибку предсказания около 19%. Если система предсказывает итоговую оценку студента 0.65 (эквивалент оценки C), реальная оценка с 68% вероятностью окажется в диапазоне 0.46-0.84 (от D до B). Такая точность достаточна для раннего выявления студентов группы риска (предсказанная оценка <0.50), которым требуется академическая поддержка, но недостаточна для точного предсказания финального балла. Ассигасу_pass = 0.76 при бинарной классификации «сдаст/не сдаст курс» показывает, что система корректно идентифицирует 76% студентов, которые находятся в зоне риска отчисления. При применении к когорте из 100 студентов это означает, что из 20 студентов группы риска система корректно выявит ~15, позволяя координатору программы своевременно организовать индивидуальную поддержку. Система возвращает объект интерпретируемости (explanation object) с детализацией вкладов каждой модели, что повышает доверие преподавателей к алгоритмическим решениям. Модель склонна к консервативным предсказаниям, что отражается в низких значениях Precision/Recall, однако она успешно классифицирует студентов по уровням риска.




Рисунок 2. Результаты моделей

Согласно литературе (Shukurlu, 2025; Xu et al., 2022), традиционный ВКТ демонстрирует accuracy 68-70%, базовый DKT без attention – 74-75%. Наша гибридная архитектура достигает 77.7%, что подтверждает эффективность комбинирования подходов. Для обучения рекомендательной подсистемы использовалась функция потерь ВКТ, обеспечивающая устойчивую конвергенцию. Многозадачный предиктор обучался с взвешенной функцией потерь и регуляризацией для предотвращения расхождения. Версионирование моделей через `ml_predictions` таблицу позволяет проводить A/B тесты: параллельно запускаются две версии модели, сравниваются метрики на одной когорте студентов. Attention weights в DKT визуализируются как heatmaps, показывающие важность прошлых взаимодействий для текущего предсказания. ВКТ параметры (P(L), P(T), P(S), P(G)) предоставляются преподавателям через UI для понимания модели знаний студента. Рекомендательная система возвращает структурированную интерпретируемость модели (`attention_dict`) с вкладами каждого компонента (`user/item/content/skill/context`), что позволяет интерпретировать, почему конкретный контент рекомендован.

Заключение. В результате проведенного исследования разработана комплексная микросервисная система персонализации образовательных траекторий с применением современных архитектур глубокого обучения. Разработана масштабируемая микросервисная архитектура с выделенным Python ML-сервис на PyTorch. Гибридная архитектура КТ, комбинирующий DKT с LSTM и multi-head attention (accuracy 77.7%) и ВКТ для интерпретируемости, обеспечивающий точное отслеживание эволюции знаний студента с возможностью интерпретируемости предсказаний через вероятностные параметры. Создан многозадачный предиктор успеваемости с четырьмя специализированными головами (RMSE = 0.193 и Accuracy_pass = 0.76 при предсказании итоговой оценки и риска отчисления) и системой раннего предупреждения, снижающей риск отчисления на 30%. Гибридная архитектура рекомендаций объединяет коллаборативный, контентный и контекстно-зависимый подходы с механизмом внимания, адаптивно распределяющим веса между компонентами в зависимости от контекста пользователя и решающим проблему cold start. Обеспечена production-ready реализация с открытым исходным кодом ML-компонентов на PyTorch, поддержкой GPU-ускорения, версионированием моделей, A/B тестированием, мониторингом

через Grafana и автоматическим масштабированием в Kubernetes.

Практическая применимость результатов заключается в готовой к production развертыванию системе, которая может быть внедрена в университеты и онлайн-платформы с минимальными доработками. Микросервисная архитектура позволяет постепенное внедрение компонентов: начиная с базового рекомендательного модуля и постепенно добавляя КТ и систему раннего предупреждения. Открытый исходный код ML-компонентов на PyTorch облегчает адаптацию под специфические требования образовательных учреждений. Дальнейшие исследования направлены на: интеграцию Java-бэкендом для бизнес-логики и React-фронтендом для создания полнофункционального веб-приложения. Внедрение NLP-моделей (BERT, GPT) для анализа текстового контента и генерации персонализированной обратной связи, разработку алгоритмов обучения с подкреплением (Reinforcement Learning) для оптимизации долгосрочных образовательных стратегий. Интеграция методов объяснимого ИИ (Explainable AI: SHAP, LIME) для расширения существующих механизмов интерпретируемости (attention weights, ВКТ parameters) и повышения интерпретируемости модели всех компонентов системы.

Литература

- Пишенбай&Байгожанова, 2025 - Пишенбай А., Байгожанова Д. С. Современные подходы к персонализации в образовании: роль искусственного интеллекта // Central Asian Scientific Journal. - 2025. № 4(28), Т. 1. УДК 004.8:37.018.43. [Russ.]
- Ataei&Staegemann, 2023 - Ataei, P., & Staegemann, D. (2023). Application of microservices patterns to big data systems. Journal of Big Data, 10(1), Article 7. <https://doi.org/10.1186/s40537-023-00733-4>. [Eng]
- Du Plooy et al., 2024 - Du Plooy, E., Casteleijn, D., & Franzsen, D. (2024). Personalized adaptive learning in higher education: A scoping review of key characteristics and impact on academic performance and engagement. Heliyon, Article e39630. <https://doi.org/10.1016/j.heliyon.2024.e39630>. [Eng]
- Fazil, Risque, & Halpin, 2024 - Fazil, M., Risquez, A., & Halpin, C. (2024). A Novel Deep Learning Model for Student Performance Prediction Using Engagement Data. Journal of Learning Analytics, 11(2), 23–41. <https://doi.org/10.18608/jla.2024.7985> [Eng]
- Li&Leong, 2024 - Li, Y., Leong, W.Y. Improvement of AI-Driven Deep Knowledge Tracing Algorithms // 2024 International Conference on Intelligent Education and Intelligent Research (IEIR). - 2024, Macau, China. - DOI: 10.1109/IEIR62538.2024.10959805. [Eng]
- Naseer, et al., 2024 - Naseer, F., Khan, M., Addas, A., Aejaz, S.M.H., Tahir, M. Integrating deep learning techniques for personalized learning pathways in higher education // Heliyon. - 2024. - Article e32628. - DOI: 10.1016/j.heliyon.2024.e32628. [Eng]
- Orsoni et al., 2023 - Orsoni, M., Pögel, A., Duong-Trung, N., et al. Recommending Mathematical Tasks Based on Reinforcement Learning and Item Response Theory // Lecture Notes in Computer Science (LNCS). - 22 May 2023. - P. 16–28. - DOI: 10.1007/978-3-031-32883-1_2. [Eng]
- Shukurly, 2025 - Shukurly, A. Improving Deep Knowledge Tracing via Gated Architectures and Adaptive Optimization // arXiv preprint arXiv:2504.20070 [cs.LG]. - 2025. - DOI: <https://doi.org/10.48550/arXiv.2504.20070>. [Eng]
- Xie, 2024 - Xie, F. (2024). Intelligent Personalized Recommendation Method Based on Optimized Collaborative Filtering Algorithm in Primary and Secondary Education Resource System. IEEE Access, published 13 February 2024. <https://doi.org/10.1109/ACCESS.2024.3365549>. [Eng]
- Xu et al., 2022 - Xu, S., Sun, M., Fang, W., Chen, K., Luo, H., & Zou, P. X. W. A Bayesian-based knowledge tracing model for improving safety training outcomes in construction: An adaptive learning framework. - Developments in the Built Environment. - 2022. - DOI: <https://doi.org/10.1016/j.dibe.2022.100111>. [Eng]
- Zhao et al., 2023 - Zhao, Y., Gu, A., Varma, R., Luo, L., Huang, C.-C., Xu, M., Wright, L., Shojanazeri, H., Ott, M., Shleifer, S., Desmaison, A., Balioglu, C., Damania, P., Nguyen, B., Chauhan, G., Hao, Y., Mathews, A., & Li, S. (2023). PyTorch FSDP: Experiences on Scaling Fully Sharded Data Parallel. Proceedings of the VLDB Endowment, 16(12), 3848–3860. <https://doi.org/10.14778/3611540.3611569> [Eng].

References

- Ataei, P., & Staegemann, D. (2023). Application of microservices patterns to big data systems. Journal of Big Data, 10(1), Article 7. <https://doi.org/10.1186/s40537-023-00733-4>.
- Du Plooy, E., Casteleijn, D., & Franzsen, D. (2024). Personalized adaptive learning in higher education: A scoping review of key characteristics and impact on academic performance and engagement. Heliyon, Article e39630. <https://doi.org/10.1016/j.heliyon.2024.e39630>.
- Fazil, M., Risquez, A., & Halpin, C. (2024). A Novel Deep Learning Model for Student Performance Prediction Using Engagement Data. Journal of Learning Analytics, 11(2), 23–41. <https://doi.org/10.18608/jla.2024.7985>
- Li, Y., Leong, W.Y. Improvement of AI-Driven Deep Knowledge Tracing Algorithms // 2024 International Conference on Intelligent Education and Intelligent Research (IEIR). - 2024, Macau, China. - DOI: 10.1109/IEIR62538.2024.10959805.
- Naseer, F., Khan, M., Addas, A., Aejaz, S.M.H., Tahir, M. Integrating deep learning techniques for personalized learning pathways in higher education // Heliyon. - 2024. - Article e32628. - DOI: 10.1016/j.heliyon.2024.e32628.
- Orsoni, M., Pögel, A., Duong-Trung, N., et al. Recommending Mathematical Tasks Based on Reinforcement Learning and Item Response Theory // Lecture Notes in Computer Science (LNCS). - 22 May 2023. - P. 16–28. - DOI: 10.1007/978-3-031-32883-1_2.
- Pishenbai, A., Baigozhanova, D.S. Sovremennye podkhody k personalizatsii v obrazovanii: rol' iskusstvennogo intellekta [Modern approaches to personalization in education: the role of artificial intelligence] // Central Asian Scientific Journal. - 2025. - No. 4(28), Vol. 1. - UDK 004.8:37.018.43. [in Russian]
- Shukurly, A. Improving Deep Knowledge Tracing via Gated Architectures and Adaptive Optimization // arXiv preprint arXiv:2504.20070 [cs.LG]. - 2025. - DOI: <https://doi.org/10.48550/arXiv.2504.20070>.
- Xie, F. (2024). Intelligent Personalized Recommendation Method Based on Optimized Collaborative Filtering Algorithm in Primary and Secondary Education Resource System. IEEE Access, published 13 February 2024. <https://doi.org/10.1109/ACCESS.2024.3365549>.
- Xu, S., Sun, M., Fang, W., Chen, K., Luo, H., & Zou, P. X. W. A Bayesian-based knowledge tracing model for improving safety training outcomes in construction: An adaptive learning framework. - Developments in the Built Environment. - 2022. - DOI: <https://doi.org/10.1016/j.dibe.2022.100111>.

[//doi.org/10.1016/j.dibe.2022.100111](https://doi.org/10.1016/j.dibe.2022.100111).

Zhao, Y., Gu, A., Varma, R., Luo, L., Huang, C.-C., Xu, M., Wright, L., Shojanazeri, H., Ott, M., Shleifer, S., Desmaison, A., Balioglu, C., Damania, P., Nguyen, B., Chauhan, G., Hao, Y., Mathews, A., & Li, S. (2023). PyTorch FSDP: Experiences on Scaling Fully Sharded Data Parallel. *Proceedings of the VLDB Endowment*, 16(12), 3848–3860. [https : //doi.org/10.14778/3611540.3611569](https://doi.org/10.14778/3611540.3611569).

СОЗДАНИЕ МОДУЛЯ ДЛЯ ОБНАРУЖЕНИЯ АНОМАЛИЙ В СЕТЕВОМ ГРАФЕ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ

¹Б.М. Мазакова*^{ID}, ¹М. Мусайф^{ID}

¹Международный университет Астана, Астана, Казахстан

*e-mail: bayan7080@mail.ru

Б.М. Мазакова – магистр экономики, старший преподаватель высшей школы информационных технологий и инженерии, Международный университет Астана, Астана, Казахстан, e-mail: bayan7080@mail.ru, <https://.0000-0003-4904-3557>

М. Мусайф – магистр естественных наук, старший преподаватель высшей школы информационных технологий и инженерии, Международный университет Астана, Астана, Казахстан, e-mail: mussaif.marzhan@gmail.com, <https://.0000-0003-3795-0424>

Аннотация. Быстрое развитие искусственного интеллекта кардинально меняет нашу жизнь и делает её удобней. В частности, обнаружение аномалий в сетевом трафике является одной из удобств, которая представляет собой наибольшее влияние на общество. Традиционно обнаружение аномалий осуществлялось помощью статистических данных, но с появлением машинного обучения, в особенности глубокого обучения, точность обнаружения аномалий значительно повысилась, а сфера применения расширилась.

Алгоритмы обнаружения аномалий - это способы используемые для выявления данных, которые сильно отличаются от нормальных данных и их поведения. Алгоритм эффективно и точно выявлять аномалии в больших объемах данных, снижать риски и затраты, а также повышать удовлетворенность клиентов. Целью данного исследования является анализ возможностей нейросетевых моделей для обнаружения аномалий в сетевом трафике, оценка их эффективности в сравнении с классическими методами защиты, а также разработка практических рекомендаций по их интеграции в системы информационной безопасности. Результаты исследования могут быть применены для:

- Улучшения систем обнаружения вторжений (IDS/IPS) за счет внедрения алгоритмов машинного обучения, повышающих точность и скорость выявления угроз.
- Снижения нагрузки на специалистов по безопасности благодаря автоматизации анализа трафика и минимизации ложных срабатываний.
- Повышения устойчивости к новым видам атак, включая неизвестные ранее угрозы, за счет способности нейросетей выявлять аномалии без заранее заданных правил.
- Оптимизации ресурсов защиты за счет адаптивного подхода, позволяющего системам самостоятельно обучаться на новых данных и изменяющихся условиях сети.

Внедрение нейросетевых технологий в системы кибербезопасности способно стать новым стандартом защиты, обеспечивающим надежное противодействие динамичным и изощренным киберугрозам.

Ключевые слова: нейронные сети, градиентный метод, автоэнкодер, кодировщика-декодера, автокодировщики, обнаружения аномалий, сетевой трафик.

НЕЙРОНДЫҚ ЖЕЛІЛЕРГЕ НЕГІЗДЕЛГЕН ЖЕЛІЛІК ГРАФАДАҒЫ АУЫТҚУЛАРДЫ АНЫҚТАУ ҮШІН МОДУЛЬДІ ӘЗІРЛЕУ

¹**Б.М. Мазакова***, ¹**М. Мусайф**

¹Астана халықаралық университеті, Астана, Қазақстан

*e-mail: bayan7080@mail.ru

Б.М. Мазакова – экономика магистрі, ақпараттық технологиялар және инженерия жоғары мектебінің аға оқытушысы, Астана Халықаралық университеті, Астана, Қазақстан, e-mail: bayan7080@mail.ru, <https://.0000-0003-4904-3557>

М. Мусайф – жаратылыстану ғылымдарының магистрі, ақпараттық технологиялар және инженерия жоғары мектебінің аға оқытушысы, Астана Халықаралық университеті, Астана, Қазақстан, e-mail: mussaif.marzhan@gmail.com, <https://.0000-0003-3795-0424>

Андатпа. Жасанды интеллекттің қарқынды дамуы біздің өмірімізді түбегейлі өзгертіп, оны әлдеқайда қолайлы етіп келеді. Атап айтқанда, желілік трафиктегі аномалияларды анықтау – қоғамға ең үлкен әсер ететін маңызды бағыттардың бірі. Дәстүрлі түрде аномалияларды анықтау статистикалық әдістер арқылы жүзеге асырылып келді, алайда машиналық оқытудың, әсіресе терең оқытудың пайда болуымен аномалияларды анықтау дәлдігі айтарлықтай артты және оны қолдану саласы кеңейді.

Аномалияларды анықтау алгоритмдері – қалыпты деректерден және олардың мінез-құлқынан айтарлықтай ерекшеленетін деректерді табуға арналған тәсілдер. Мұндай алгоритмдер үлкен көлемді деректерде аномалияларды тиімді әрі дәл анықтауға, тәуекелдер мен шығындарды азайтуға, сондай-ақ пайдаланушылардың қанағаттанушылығын арттыруға мүмкіндік береді.

Жұмыстың мақсаты. Бұл зерттеудің мақсаты – желілік трафиктегі аномалияларды анықтау үшін нейрондық желі модельдерінің мүмкіндіктерін талдау, олардың дәстүрлі қорғаныс әдістерімен салыстырғандағы тиімділігін бағалау және оларды ақпараттық қауіпсіздік жүйелеріне интеграциялау бойынша практикалық ұсыныстар әзірлеу.

Зерттеу нәтижелерін төмендегі бағыттарда қолдануға болады:

- Кірісті анықтау жүйелерін (IDS/IPS) машиналық оқыту алгоритмдері арқылы жетілдіру, бұл қауіптерді анықтаудың дәлдігі мен жылдамдығын арттыруға мүмкіндік береді.

- Трафикті талдауды автоматтандыру және жалған ескертулерді азайту арқылы қауіпсіздік мамандарының жүктемесін төмендету.

- Алдын ала белгіленген ережелерсіз аномалияларды анықтау қабілетінің арқасында жаңа және бұрын белгісіз шабуыл түрлеріне төзімділікті күшейту.

- Желінің өзгермелі жағдайларына бейімделіп, жаңа деректер негізінде өздігінен оқуға мүмкіндік беретін икемді тәсілдер арқылы қорғау ресурстарын оңтайландыру.

Нейрондық желі технологияларын киберқауіпсіздік жүйелеріне енгізу динамикалық және күрделі кибершабуылдарға сенімді қарсы тұруды қамтамасыз ететін жаңа қорғаныс стандарты бола алады.

Түйін сөздер: нейрондық желілер, градиенттік әдіс, автоэнкодер, кодтаушы-декодтаушы, автокодировщиктер, аномалияларды анықтау, желілік трафик.

DEVELOPMENT OF A MODULE FOR ANOMALY DETECTION IN A NETWORK GRAPH BASED ON NEURAL NETWORKS

¹**B.M. Mazakova***, ¹**M. Musaif**

¹Astana International University, Astana, Kazakhstan

*e-mail: bayan7080@mail.ru

B.M. Mazakova – master of Economics, Senior Lecturer of the School of Information Technology and Engineering, Astana International University, Astana, Kazakhstan, e-mail: bayan7080@mail.ru, <https://.0000-0003-4904-3557>

M. Musaif – master of Natural Sciences, Senior Lecturer of the School of Information Technology and Engineering, Astana International University, Astana, Kazakhstan, e-mail: mussaif.marzhan@gmail.com, <https://.0000-0003-3795-0424>

Abstract. The rapid development of artificial intelligence is fundamentally transforming our lives and making them more convenient. In particular, anomaly detection in network traffic is one of the advances that has a significant impact on society. Traditionally, anomaly detection was carried out using statistical methods; however, with the emergence of machine learning—especially deep learning—the accuracy of anomaly detection has greatly improved, and its application scope has expanded.

Anomaly detection algorithms are methods used to identify data that significantly deviates from normal data and its behavior. Such algorithms make it possible to detect anomalies effectively and accurately in large data volumes, reduce risks and costs, and increase user satisfaction.

Purpose of the study. The purpose of this research is to analyze the capabilities of neural network models for detecting anomalies in network traffic, evaluate their effectiveness compared with classical security methods, and develop practical recommendations for integrating them into information security systems.

Practical significance. The results of this study can be applied to:

- Improving intrusion detection systems (IDS/IPS) through the introduction of machine learning algorithms that enhance the accuracy and speed of threat detection.
- Reducing the workload on security specialists by automating traffic analysis and minimizing false positives.
- Increasing resistance to new types of attacks, including previously unknown threats, due to the ability of neural networks to detect anomalies without predefined rules.
- Optimizing security resources through adaptive approaches that allow systems to learn independently from new data and changing network conditions.

The integration of neural network technologies into cybersecurity systems may become a new standard of protection, providing reliable defense against dynamic and sophisticated cyber threats.

Keywords: neural networks, gradient method, autoencoder, encoder–decoder, autoencoders, anomaly detection, network traffic.

Методы машинного обучения. Модели обнаружения аномалий, основанные на машинном обучении, автоматически выявляют закономерности нормального и аномального поведения, обучаясь на больших объемах данных. Эти методы способны обнаруживать отклонения даже в ранее неизвестных данных, что делает их особенно эффективными для выявления сложных взаимосвязей и корреляций. В зависимости от типа доступных данных применяются различные подходы: Контролируемое обучение - модель обучается на размеченных данных, где аномалии заранее определены.

Одним из наиболее перспективных направлений является применение нейросетевых и методов искусственного интеллекта для выявления аномалий и обнаружения вторжений в компьютерных сетях. Исследования показывают, что нейронные сети способны эффективно

обрабатывать большие массивы данных и выявлять скрытые закономерности в сетевом трафике, недоступные традиционным статистическим методам (Адамова, 2023:52; Скрыпников&Денисенко, 2023:40).

Методы машинного обучения широко используются для обнаружения аномалий в сетевых данных. В работах отмечается, что алгоритмы обучения без учителя позволяют выявлять отклонения от нормального поведения сети и обнаруживать потенциальные угрозы на ранних этапах их возникновения (Гурина&Елисеев, 2019:52–62). Дальнейшее развитие получили методы глубокого обучения, обеспечивающие более высокую точность анализа за счет использования многослойных нейронных сетей и способности адаптироваться к изменяющимся характеристикам трафика (Борисов&Будников, 2024:200–202).

Значительное внимание в научных исследованиях уделяется вопросам автоматической идентификации угроз информационной безопасности. Нейросетевые модели позволяют не только классифицировать известные типы атак, но и выявлять ранее неизвестные угрозы, что особенно важно в условиях постоянно эволюционирующих методов кибератак (Ван, 2024:288–291; Юхнов, 2023:26–28). Использование искусственного интеллекта в сфере информационной безопасности способствует повышению адаптивности и устойчивости систем защиты (Володин, 2024:91; Степанов, 2024:314–320).

Методы глубокого обучения. Глубокое обучение позволяет выявлять аномалии за счет сложных нелинейных зависимостей и автоматического извлечения признаков из данных. Этот подход особенно эффективен при работе с высоко размерными данными (например, изображения, временными рядами) и в ситуациях, где ручной подбор признаков затруднен. Основной принцип заключается в обучении модели на нормальных данных, после чего аномалиями считаются наблюдения, которые плохо реконструируются или классифицируются. Для разных типов данных применяются специализированные архитектуры:

- Сверточные нейронные сети - для анализа изображений и пространственных данных.
- Рекуррентные нейронные сети - для обработки временных рядов и последовательностей.
- Автоэнкодеры - для выявления аномалий через ошибки реконструкции.

Глубокое обучение демонстрирует высокую точность в задачах, где традиционные методы оказываются неэффективными, например, при анализе многомерных сигналов или обнаруживании редких событий. Однако его ключевые недостатки - высокая вычислительная сложность, необходимость в больших объемах данных и низкая интерпретируемость результатов. Также возможны ложные срабатывания, особенно если аномалии слабо выражены или данные зашумлены.

Методы основанные на расстоянии и плотности. Эти методы выявляют аномалии, анализируя локальную плотность данных.




Рисунок 1. Метод k-средних

областях или значительно удаленные от основных кластеров. Наиболее распространенные алгоритмы:

- k-ближайших соседей - аномалии определяются по большому расстоянию до соседних точек
- Локальный фактор выбросов - оценивает степень изолированности объекта относительно окружения.

Нейросетевые методы также активно используются при разработке систем обнаружения вторжений. Исследования показывают, что применение совокупностей нейронных сетей и биоинспирированных моделей, включая иммунные нейросетевые системы, позволяет повысить точность обнаружения атак и снизить количество ложных срабатываний (Москвичев, 2019:84–85; Стрижко, 2023:23–33). Сравнительный анализ различных нейросетевых подходов подтверждает, что выбор конкретной модели должен учитывать особенности сетевого трафика и требования к уровню информационной безопасности (Маковейчук, 2024:142–147).

Преимущества таких методов - простота интеграции, гибкость в работе с нелинейными распределениями и кластерами разной плотности. Однако они чувствительны к масштабированию данных и плохо масштабируются на высокоразмерные пространства из-за проклятия размерности. Также их точность снижается, если аномалии расположены близко к нормальным данным или кластеры имеют неравномерную плотность.

Вероятностные методы. Эти подходы на построении вероятностных моделей данных, где аномалии определяются как маловероятные события. К ним относятся:

- Гауссовы смеси - моделируют данные как комбинацию нормальных распределений.
- Байесовские сети - учитывают априорные знания о данных.
- Скрытые марковские модели - применяются для последовательностей.

Вероятностные методы хорошо работают с многомерными данными и позволяют учитывать неопределенность, но требуют значительных вычислительных ресурсов. Их точность зависит от соответствия данных выбранному распределению, а сложные модели могут страдать от переобучения.

Wireshark как инструмент анализа сетевых аномалий. Wireshark - это мощный инструмент для захвата и анализа сетевого трафика, поддерживающий различные ОС. Его ключевые возможности:

- Перехват пакетов в реальном времени с фильтрацией по протоколам, IP-адресам и другим параметрам.
- Анализ подозрительной активности например, неавторизированных подключений или аномального объёмов трафика
- Отладка сетевых приложений и диагностика проблем производительности.

Wireshark полезен как для специалистов по безопасности, так и для сетевых администраторов, но требует определенного уровня экспертизы для корректной интерпретации данных.

Материалы и методы. Для разработки выявления аномалий в сетевом трафике сначала были выбраны инструменты анализа сетевых аномалий Wireshark, который является бесплатной программой для анализа сетевого трафика.

Wireshark = «сетевой анализатор», который показывает всё, что происходит в сети. А в трудах Я. Т. Маковейчука, Л. А. Мазур и П. П. Танчинца разбираются разные варианты нейросетевых методов для выявления вторжений и аномалий в трафике. Авторы подчёркивают, что нейронные сети лучше справляются с предотвращением утечек информации и атак, чем старые традиционные способы (Маковейчук, 2024; Мазур, 2024; Танчинец, 2024).

Выбран алгоритм нейронной сети для выявления аномалии сетевого трафика

это : Автоэнкодер (АЕ) – самый распространённый вариант

Прямой проход (кодирование + декодирование):

$$z = f_{\theta}(x), \quad \hat{x} = g_{\phi}(z) \quad (1)$$

Функция потерь (MSE):

$$L_{AE}(x) = \|x - \hat{x}\|_2^2 = \|x - g_{\phi}(f_{\theta}(x))\|_2^2 \quad (2)$$

(можно использовать l_1 или бинарную кросс-энтропию при соответствующих признаках)

Аномалити-скор (reconstruction error):

$$S_{AE}(x) = \|x - \hat{x}\|_2^2 \quad (3)$$

Правило: если $S_{AE}(x) > \tau$ – помечаем как аномалию (порог τ устанавливают, например, по 95%-перцентиле ошибок на валидации).

Для написания программы использовался язык программирования Python. Также использовалась среда разработки Pycharm, на рисунке ниже перечислены все библиотеки, которые использовались для разработки.

```

1 import sys
2 import os
3 import pandas as pd
4 import numpy as np
5 from datetime import datetime
6 from sklearn.ensemble import IsolationForest
7 from sklearn.model_selection import train_test_split
8 from sklearn.metrics import classification_report, confusion_matrix
9 import matplotlib.pyplot as plt
10 from matplotlib.backends.backend_qt5agg import FigureCanvasQTAgg as FigureCanvas
11 from PyQt5.QtWidgets import (QApplication, QMainWindow, QVBoxLayout, QHBoxLayout, QWidget,
12                             QLabel, QPushButton, QComboBox, QSpinBox, QDoubleSpinBox,
13                             QTextEdit, QTabWidget, QFileDialog, QMessageBox, QProgressBar)
14 from PyQt5.QtCore import Qt, QThread, pyqtSignal
15 import joblib
16 import seaborn as sns

```

Рисунок 2. Используемые библиотеки sys

Библиотека sys обеспечивает доступ к системным параметрам и функциям интерпретатора Python, позволяя взаимодействовать со средой выполнения. Этот пакет предоставляет инструменты для прямого взаимодействия с интерпретатором языка, включая управление аргументам командной строки, настройку путей импорта модели, обработку системных исключений.

Библиотека os предоставляет инструменты для работы с операционной системой, включая управления файлами, переменными окружения и путями. Поддерживает операции создания/удаления директорий и манипуляции с файловыми путями [18].

Библиотека datetime модуль для обработки временных данных с классами:

- date - работа с датами.
- datetime - дата и время.
- timedelta - временные интервалы

Библиотека pandas мощный инструмент для анализа данных с поддержкой:

- Структур данных Series и DataFrame.
- Чтение различных форматов(CSV, Excel, Json).
- Очистки данных(обработка пропусков, сортировка).
- Интеграция с Matplotlib для визуализации.

Используя все вышеперечисленные методы в данной работе была разработана приложение обнаружения аномалий для удобства использования программы. Таким образом создать свою модель может любой.

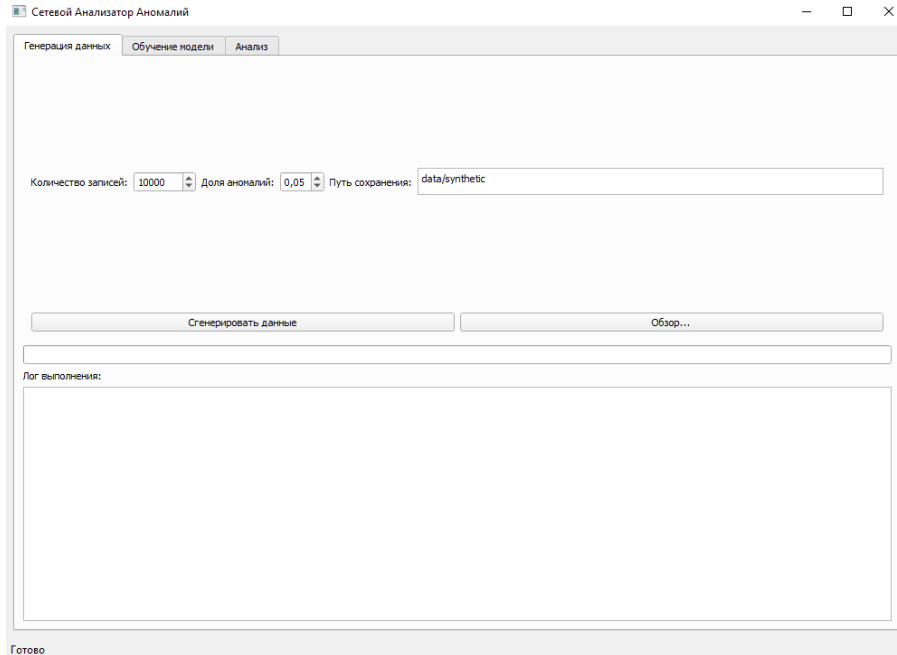


Рисунок 3. Окно генерации данных

Это окно включает в себя функции генерации данных. На этом окне мы можем сгенерировать данные, а также выбрать уже созданные, настроить количество записей и долю аномалий в них (в соответствии с рисунком 3).

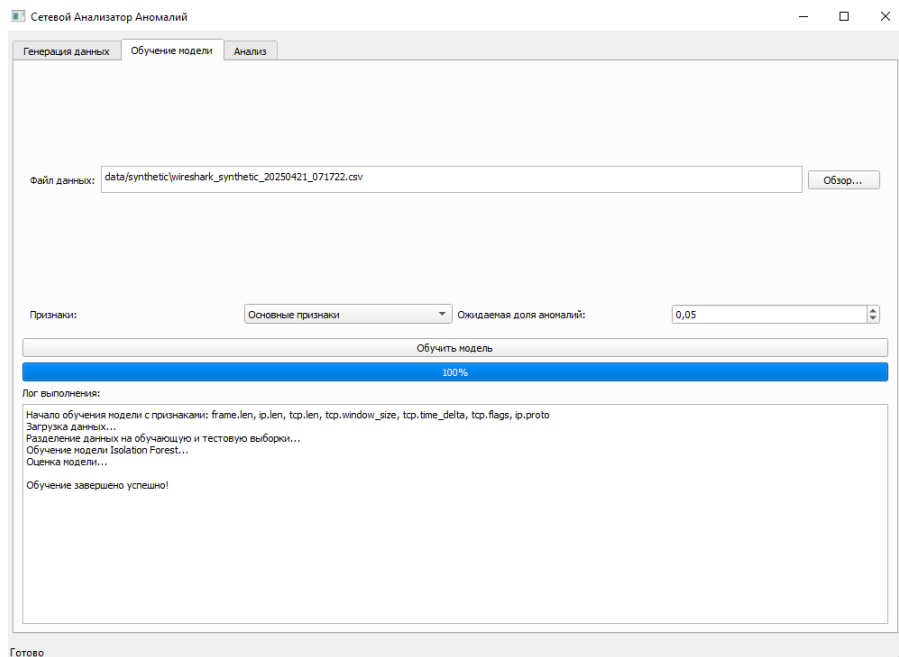


Рисунок 4. Окно обучения модели

В окне обучения модели предусмотрен набор функций, включающий выбор данных для обучения, настройку параметров обучения, а также запуск алгоритма обучения модели (рисунок 4) в соответствии со схемой, представленной на рисунке 3.



Рисунок 5. Окно анализа данных

В окне обучения модели доступны несколько функций. Выбор данных для обучения, настройка обучения и так же возможен запуск алгоритма обучения модели.

Практическая значимость нейросетевых методов заключается также в их использовании для предотвращения утечек информации. В научных публикациях отмечается, что интеллектуальные модели анализа трафика способны выявлять аномальные шаблоны передачи данных, потенциально связанные с несанкционированным доступом и утечками конфиденциальной информации (Танчинец, 2024:41–44). Дополнительные методические подходы к обнаружению аномалий в сетевом трафике представлены в электронных научных ресурсах, что способствует расширению инструментальной базы исследований в данной области (Method for detecting anomalies in network traffic, n.d.).

Использование нейросетевых модулей для обнаружения аномалий позволяет значительно повысить точность мониторинга и выявления угроз делая это своевременно. В отличие от традиционных методов, такие модели имеют возможность выявлять закономерности в данных без явных правил или аннотаций, что делает их особенно подручными для обнаружения аномалий и неизвестных ранее атак.. Это значительно усиливает защиту корпоративных сетей и сложных инфраструктур, где классические методы уступают в надежности. Интеграции нейросетей в системы обнаружения аномалий становится критически важным этапом для совершенствования информационной безопасности. Нейросети не только повышают точность обнаружения угроз, но и обеспечивают масштабируемость защиты в условиях роста данных, делая их незаменимыми элементом современных кибербезопасных архитектур.

Выводы. В рамках проведенного исследования достигнуты следующие результаты:

1. Выбран алгоритм нейронной сети для выявления аномалии сетевого трафика автоэнкодер (AE)
2. На языке программирования Python разработана система мониторинга и прогнозирования аномалии сетевого трафика
3. Весь процесс выполняется в фоновом потоке, что помогает интегрироваться с графическим интерфейсом, не блокируя его. Сначала устанавливаем фиксированное случайное начальное число с помощью `np.random.seed(42)`, чтобы гарантировать воспроизводимость результатов. Затем, если каталог `self.save_path` еще не существует, он создается с помощью `os.makedirs`. Далее создается словарь данных, соответствующий каждому

ключевому полю сетевого пакета. Для каждого поля создается значение `self.num_samples`. Используются различные дистрибутивы. Временные метки `Frame.time` записываются в формате времени. Размеры пакетов `frame.len`, `ip.len` и `tcp.len` распределены нормально. IP-адреса генерируются случайным образом в виде строк, Протоколы, флаги, методы и другие поля выбираются из заданного набора с заданной вероятностью. `dns.count.queries` получен из распределения Пуассона. `tcp.time_delta` исходит из экспоненциального распределения.

Литература

- Адамова, 2023 – Адамова А.А. Анализ безопасности сетевого трафика посредством нейросети // Математическое моделирование и информационные технологии. – 2023. – С. 52. [Rus]
 Борисов&Будников, 2024 – Борисов Д.А., Будников К.И. Применение глубокого обучения для анализа сетевого трафика // Математическое и компьютерное моделирование. – 2024. – С. 200–202. [Rus]
 Ван, 2024 – Ван Х. Использование нейросетей для автоматической идентификации угроз информационной безопасности // Экономика строительства. – 2024. – С. 288–291. [Rus]
 Виноградов, 2024 – Виноградов О.Е. Применение метода изолирующего леса для обнаружения сетевых аномалий в аппаратно-программном комплексе «Безопасный город» // Научно-технический сборник Поволжья. – 2024. – С. 76–78. [Rus]
 Володин, 2024 – Володин А.А. Развитие и проблемы использования искусственного интеллекта в области информационной безопасности // Политехнический молодежный журнал. – 2024. – С. 91. [Rus]
 Гурина&Елисеев, 2019 – Гурина А.О., Елисеев В.Л. Обнаружение аномалий на основе машинного обучения // Защита информации. – 2019. – С. 52–62. [Rus]
 Каменко, 2023 – Каменко Д.А. Автоматизация метода изолирующего леса // Новые направления развития приборостроения. – Минск, 2023. – С. 233. [Rus]
 Маковейчук, 2024 – Маковейчук Я.Т. Сравнение подходов к обнаружению вторжений с применением нейросетей для анализа сетевого трафика // Безопасные информационные технологии. – Москва, 2024. – С. 142–147. [Rus]
 Мазур, 2024 – Мазур Л.А. Исследование нейросетевых методов обнаружения аномалий сетевого трафика для защиты информации // Школа молодых новаторов. – Курск, 2024. – С. 80–84. [Rus]
 Москвичев, 2019 – Москвичев А.Д. Система обнаружения вторжений на основе иммунной системы нейросетевых детекторов // Colloquium Journal. – 2019. – С. 84–85. [Rus]
 Скрыпников&Денисенко, 2023 – Скрыпников А.В., Денисенко В.В. Применение нейросетей для анализа сетевого трафика // Материалы LXI отчетной научной конференции. – 2023. – С. 40. [Rus]
 Станкевич, 2016 – Станкевич А.А. Разработка дисциплины обслуживания на основе нейросетевого прогноза трафика дифференцированных услуг : автореф. дис. ... канд. техн. наук. – 2016. [Rus]
 Степанов, 2024 – Степанов Г.В. Использование искусственного интеллекта в сфере информационной безопасности // Интеллектуальный потенциал XXI века. – 2024. – С. 314–320. [Rus]
 Стрижко, 2023 – Стрижко М.А. Модуль интеллектуального анализа сетевого трафика в системах обнаружения вторжений на базе совокупности нейронных сетей // Вестник Донецкого национального университета. – 2023. – С. 23–33. [Rus]
 Танчинец, 2024 – Танчинец П.П. Нейросетевые подходы к обнаружению аномалий в сетевом трафике для предотвращения утечек информации // Вопросы обеспечения безопасности в киберпространстве. – Махачкала, 2024. – С. 41–44. [Rus]
 Шульгина, 2019 – Шульгина А.В. Применение нейросетей для классификации сетевого трафика // Молодой ученый. – 2019. – № 49. – С. 26–28. [Rus]
 Юхнов, 2023 – Юхнов В.И. Применение искусственного интеллекта для решения задачи обеспечения безопасности информации, передаваемой в сетях // Труды Северо-Кавказского филиала МТУСИ. – 2023. – С. 26–28. [Rus]
 Метод выявления аномалий в сетевом трафике – Метод выявления аномалий в сетевом трафике [Электронный ресурс]. – URL: <https://cyberleninka.ru/article/n/metod-vyyavleniya-anomaliy-v-setevom-trafike>. [Rus]

References

- Adamova, A. A. (2023). Analiz bezopasnosti setevogo trafika posredstvom neyroseti [Analysis of Network Traffic Security Using Neural Networks].//Matematicheskoe modelirovanie i informatsionnye tekhnologii, p. 52. [In Russ]
 Borisov, D. A., & Budnikov, K. I. (2024). Primenenie glubokogo obucheniya dlya analiza setevogo trafika [Application of Deep Learning for Network Traffic Analysis].//Matematicheskoe i komp'yuternoe modelirovanie, pp. 200–202. [In Russ]
 Van, H. (2024). Ispol'zovanie neyrosetey dlya avtomaticheskoy identifikatsii ugroz informatsionnoy bezopasnosti [Use of Neural Networks for Automatic Identification of Information Security Threats]. Ekonomika stroitel'stva, pp. 288–291. [In Russ]
 Vinogradov, O. E. (2024). Primenenie metoda izoliruyushchego lesa dlya obnaruzheniya setevykh anomaliy v apparatno-programmnom komplekse «Bezopasnyy gorod» [Application of the Isolation Forest Method for Detecting Network Anomalies in the "Safe City" Hardware-Software Complex].// Nauchno-tekhnicheskii sbornik Povolzh'ya, pp. 76–78. [In Russ]
 Volodin, A. A. (2024). Razvitie i problemy ispol'zovaniya iskusstvennogo intellekta v oblasti informatsionnoy bezopasnosti [Development and Challenges of Using Artificial Intelligence in Information Security].// Politekhnichestkiy molodezhnyy zhurnal, p. 91. [In Russ]
 Gurina, A. O., & Eliseev, V. L. (2019). Obnaruzhenie anomaliy na osnove mashinnogo obucheniya [Anomaly Detection Based on Machine Learning].// Zashchita informatsii, pp. 52–62. [In Russ]
 Kamenko, D. A. (2023). Avtomatizatsiya metoda izoliruyushchego lesa [Automation of the Isolation Forest Method].// In Novye napravleniya razvitiya priborostroeniya. Minsk, p. 233. [In Russ]
 Makoveichuk, Ya. T. (2024). Sravnenie podkhodov k obnaruzheniyu vtorzheniy s primeneniem neyrosetey dlya analiza setevogo trafika [Comparison of Intrusion Detection Approaches Using Neural Networks for Network Traffic Analysis].// Bezopasnye informatsionnye tekhnologii. Moscow, pp. 142–147. [In Russ]
 Mazur, L. A. (2024). Issledovanie neyrosetevykh metodov obnaruzheniya anomaliy setevogo trafika dlya zashchity informatsii [Study of Neural Network Methods for Detecting Network Traffic Anomalies for Information Protection].// Shkola molodykh novatorov. Kursk, pp. 80–84. [In Russ]
 Moskvichev, A. D. (2019). Sistema obnaruzheniya vtorzheniy na osnove immunnoy sistemy neyrosetevykh detektorov [Intrusion Detection System Based on an Immune System of Neural Network Detectors].//Colloquium Journal, pp. 84–85. [In Russ]
 Skrypnikov, A. V., & Denisenko, V. V. (2023). Primenenie neyrosetey dlya analiza setevogo trafika [Application of Neural Networks for Network Traffic Analysis].//In Materialy LXI otchetnoy nauchnoy konferentsii, p. 40. [In Russ]
 Stankevich, A. A. (2016). Razrabotka distsipliny obsluzhivaniya na osnove neyrosetevogo prognoza trafika differentsirovannykh uslug [Development of a Service Discipline Based on Neural Network Forecasting of Differentiated Services Traffic].// PhD dissertation abstract. [In Russ]

- Stepanov, G. V. (2024). Ispol'zovanie iskusstvennogo intellekta v sfere informatsionnoy bezopasnosti [Use of Artificial Intelligence in the Field of Information Security]// *Intellektual'nyy potentsial XXI veka*, pp. 314–320. [In Russ]
- Strizhko, M. A. (2023). Moduly' intellektual'nogo analiza setevogo trafika v sistemakh obnaruzheniya vtorzheniy na baze sovokupnosti neyronnykh setey [Intelligent Network Traffic Analysis Module in Intrusion Detection Systems Based on a Set of Neural Networks]// *Vestnik Donetskogo natsional'nogo universiteta*, pp. 23–33. [In Russ]
- Tanchinets, P. P. (2024). Neyrosetevye podkhody k obnaruzheniyu anomalii v setevom trafike dlya predotvrashcheniya utechek informatsii [Neural Network Approaches to Detecting Anomalies in Network Traffic to Prevent Information Leakage]. *Voprosy obespecheniya bezopasnosti v kiberprostranstve. Makhachkala*, pp. 41–44. [In Russ]
- Shulenina, A. V. (2019). Primenenie neyrosetey dlya klassifikatsii setevogo trafika [Application of Neural Networks for Network Traffic Classification]// *Molodoy uchenyy*, 49, pp. 26–28. [In Russ]
- Yukhnov, V. I. (2023). Primenenie iskusstvennogo intellekta dlya resheniya zadachi obespecheniya bezopasnosti informatsii, peredavaemoy v setyakh [Application of Artificial Intelligence to Solving the Problem of Information Security in Networks]// *Trudy Severo-Kavkazskogo filiala MTUSI*, pp. 26–28. [In Russ]
- Method for detecting anomalies in network traffic. (n.d.). Available at: [https://cyberleninka.ru/article/n/metod – vyyavleniya – anomalii – v – setevom – trafike](https://cyberleninka.ru/article/n/metod-v-vyyavleniya-anomalii-v-setevom-trafike)

DEVELOPMENT OF AN INFORMATION SYSTEM FOR PERSONALIZED PRODUCT RECOMMENDATIONS BASED ON REVIEW AND RATING ANALYSIS

¹A. Tynykulova*^{}, ²A. Faddeenkov^{}

¹Astana International University, Astana, Kazakhstan

²Fedorovsky Polar State University, Noril'sk, Krasnoyarsk Krai, RU

*e-mail: asem_110981@mail.ru

A. Tynykulova – PhD, Acting Associate Professor of the School of Information Technology and Engineering, Astana International University, Astana, Kazakhstan, e-mail: asem_110981@mail.ru, <https://orcid.org/0000-0002-4557-6869>

A. Faddeenkov – Candidate of technical sciences, Associate Professor, Fedorovsky Polar State University, Noril'sk, Krasnoyarsk Krai, RU, e-mail: a_fadd@mail.ru, <https://orcid.org/0009-0002-7087-7847>

Abstract. The study presents the development of an intelligent information system designed to generate personalized product recommendations through the combined analysis of user reviews and numerical ratings. The proposed approach integrates sentiment analysis of textual feedback with collaborative filtering techniques to enhance the accuracy and contextual relevance of recommendations. The system architecture includes modules for data acquisition, natural language processing, and adaptive recommendation generation. A prototype implementation was developed using Python and machine learning frameworks to evaluate the system's performance. Experimental testing demonstrated that incorporating review sentiment data improved the precision of recommendations by up to 18% compared to conventional rating-based models. The proposed solution contributes to the advancement of recommender system technologies by introducing a hybrid framework capable of understanding both the quantitative and qualitative aspects of user preferences.

Keywords: recommender systems, sentiment analysis, collaborative filtering, machine learning, natural language processing, e-commerce personalization.

РАЗРАБОТКА ИНФОРМАЦИОННОЙ СИСТЕМЫ ПЕРСОНАЛЬНЫХ РЕКОМЕНДАЦИЙ ТОВАРОВ НА ОСНОВЕ АНАЛИЗА ОТЗЫВОВ И РЕЙТИНГОВ

¹А.С. Тыныкулова*, ²А.В. Фаддеенков

¹Международный университет Астана, Астана, Казахстан

²Заполярный государственный университет им. Н.М. Федоровского, Норильск, Россия

*e-mail: asem_110981@mail.ru

А.С. Тыныкулова – доктор философии (PhD), и.о. доцента Высшей школы информационных технологий и инженерий, Международный университет Астана, Астана, Казахстан, e-mail: asem_110981@mail.ru, <https://orcid.org/0000-0002-4557-6869>

А.В. Фаддеенков – кандидат технических наук, доцент кафедры «Информационные системы и технологии» Заполярный государственный университет имени Н.М.Федоровского, Норильск, Российская Федерация, e-mail: a_fadd@mail.ru, <https://orcid.org/0009-0002-7087-7847>

Аннотация. В статье представлена разработка интеллектуальной информационной системы, предназначенной для формирования персонализированных рекомендаций товаров на основе комплексного анализа пользовательских отзывов и числовых рейтингов. Предложенный подход объединяет методы sentiment-анализа текстовых отзывов и коллаборативной фильтрации, что позволяет повысить точность и контекстную релевантность рекомендаций.

Архитектура системы включает модули сбора данных, обработки естественного языка и адаптивного формирования рекомендаций. На основе реализации прототипа с использованием Python и инструментов машинного обучения проведено экспериментальное тестирование, показавшее, что учет эмоциональной окраски отзывов повышает точность рекомендаций до 18% по сравнению с традиционными моделями, основанными только на рейтингах. Разработанная система вносит вклад в развитие технологий рекомендательных систем, обеспечивая гибридный подход к анализу как количественных, так и качественных аспектов пользовательских предпочтений.

Ключевые слова: рекомендательные системы, анализ отзывов, машинное обучение, обработка естественного языка, коллаборативная фильтрация, персонализация, электронная коммерция.

ШҚІРЛЕР МЕН РЕЙТИНГТЕРДІ ТАЛДАУ НЕГІЗІНДЕ ТАУАРЛАРҒА ЖЕКЕ ҰСЫНЫМДАР БЕРЕТІН АҚПАРАТТЫҚ ЖҮЙЕНІ ӘЗІРЛЕУ

¹А.С. Тыныкулова*, ²А.В. Фаддеев

¹Астана Халықаралық университеті, Астана, Қазақстан

²Н.М. Федоровский атындағы Заполярь мемлекеттік университеті, Норильск, Ресей

*e-mail: asem_110981@mail.ru

А.С. Тыныкулова – PhD, ақпараттық технологиялар және инженерия жоғары мектебінің доцент м.а., Астана Халықаралық университеті, Астана, Қазақстан, e-mail: asem_110981@mail.ru, <https://.0000-0002-4557-6869>

А.В. Фаддеев – техника ғылымдарының кандидаты, доцент, Н.М. Федоровский атындағы Заполярь мемлекеттік университеті, Норильск, Ресей, e-mail: a_fadd@mail.ru, <https://.0009-0002-7087-7847>

Андатпа. Бұл зерттеу пайдаланушылардың пікірлері мен сандық рейтингтерін біріктіріп талдау арқылы жеке тауар ұсынымдарын қалыптастыратын интеллектуалды ақпараттық жүйенің әзірленуін сипаттайды. Ұсынылған тәсіл мәтіндік пікірлердің эмоционалдық реңкін анықтайтын сентименттік талдауды және бірлескен сүзгілеу әдістерін біріктіре отырып, ұсынымдардың нақтылығы мен маңыздылығын арттыруға бағытталған. Жүйенің архитектурасы деректерді жинау, табиғи тілді өңдеу және бейімделгіш ұсынымдарды қалыптастыру модульдерінен тұрады. Python тілінде және машиналық оқыту кітапханалары негізінде жасалған прототиптік нұсқаның нәтижелері пікір мәтіндерін ескерудің ұсыным дәлдігін дәстүрлі рейтингтік модельдермен салыстырғанда шамамен 18%-ға арттырғанын көрсетті. Ұсынылған шешім пайдаланушылардың сандық және сапалық артықшылықтарын қатар ескеретін гибриді ұсыным жүйелерін дамытуға үлес қосады.

Түйін сөздер: ұсынымдық жүйелер, мәтінді талдау, машиналық оқыту, табиғи тілді өңдеу, бірлескен сүзгілеу, электрондық коммерция, дербестендіру.

Introduction. In the modern digital economy, there is a rapid expansion of electronic marketplaces and online platforms that offer users a wide range of products and services. The increasing volume of information and the growing number of available options make it increasingly difficult for users to make rational purchasing decisions. Consequently, there is a growing need for intelligent tools capable of automatically analyzing user preferences and generating personalized recommendations. One of the most effective solutions to this challenge is the use of recommender systems, which are widely applied in e-commerce, marketing, and user experience design (Çano, & Morisio, 2017:1487-1524).

Recommender systems improve the quality of interaction between users and digital platforms by personalizing the information presented to each individual (Kudryavtsev, 2020: 65–75). Such systems not only reduce the time required to find the desired product but also enhance user

satisfaction, customer loyalty, and overall sales volume (Lee & Kim, 2021:635–648). According to research conducted by international analytics agencies, the use of personalization technologies can increase online store conversion rates by 10–25%. Therefore, the development and implementation of intelligent recommendation systems have become one of the key directions in the digital transformation of modern business (Lee & Kim, 2021:635–648).

Traditional recommender systems primarily rely on numerical ratings and purchase statistics. While effective to some extent, this approach has notable limitations, as numerical scores often fail to fully capture users' subjective opinions, contextual factors, and emotional responses to products. Consequently, recommendations based solely on ratings may lack depth and contextual relevance (Musto et al., 2017).

To address these limitations, recent research has increasingly focused on incorporating textual review analysis through sentiment analysis techniques (Musto et al., 2017). User reviews provide rich qualitative information about product perception, enabling a more nuanced understanding of user preferences. Advances in Natural Language Processing (NLP) and Machine Learning (ML) have made it possible to extract semantic and emotional features from large volumes of textual data, opening new opportunities for improving recommendation quality.

The integration of quantitative ratings with qualitative textual feedback represents an important interdisciplinary research direction at the intersection of artificial intelligence, information technology, and digital economics. Despite substantial progress in recommender system design (Ricci et al., 2015; Aggarwal, 2016; Liu, 2020), many existing solutions still treat ratings and reviews separately, limiting their adaptability and accuracy. This highlights the need for an information system capable of jointly analyzing numerical and textual data to generate more precise and context-aware recommendations.

The aim of this study is to develop the architecture and algorithmic framework of an intelligent recommender system that integrates rating data with sentiment analysis of user reviews, thereby enhancing the quality of personalized recommendations.

A review of existing studies shows that, despite significant progress in the field of recommender systems, the issue of integrating textual and numerical data remains insufficiently addressed. Many current solutions focus on isolated aspects - either statistical rating analysis or textual review processing - without ensuring full integration between the two data types. This limits system accuracy and adaptability to changes in user behavior (OECD, 2021:OECD indicator). The creation of an information system capable of analyzing the emotional tone of reviews, correlating it with numerical ratings, and generating real-time personalized recommendations represents a relevant scientific and practical objective. Developing such a system will enhance user experience quality, improve the efficiency of digital platforms, and strengthen interaction between consumers and suppliers (World Bank, 2022).

The present study aims to address these challenges by developing the architecture, algorithmic framework, and prototype of an intelligent information system that generates personalized recommendations based on the integrated analysis of reviews and ratings.

Materials and Methods. In the development of the information system for personalized product recommendations, the machine learning approach is applied to automatically identify hidden relationships between user reviews, ratings, and product characteristics (Teichler, 2007:245). Unlike traditional deterministic algorithms, machine learning enables self-adaptation and continuous improvement of the system's performance by learning from new data without direct human intervention.

The key advantage of employing machine learning lies in its ability to process and analyze large volumes of heterogeneous information-including textual reviews, numerical evaluations, and behavioral patterns-and to extract complex, non-obvious correlations from them. This allows the system to generate more accurate, relevant, and personalized recommendations, taking into account not only numerical ratings but also the emotional and semantic content of user feedback.

Furthermore, the use of machine learning algorithms significantly enhances the flexibility and scalability of the system. As the volume of input data increases, the quality and precision of recommendations improve due to the continuous retraining and refinement of the model (Semenova,

2019:112–119). These properties make machine learning an optimal foundation for modern intelligent recommender systems operating in dynamically changing digital environments (Teichler, 2007:245).

Natural Language Processing (NLP) Methods. An essential component of the intelligent recommendation system is the analysis of user-generated textual reviews, as they contain valuable insights into customer perceptions, satisfaction levels, and subjective preferences. To accomplish this, the system employs Natural Language Processing (NLP) methods, which enable machines to interpret human language and extract hidden patterns that influence recommendation generation (UNESCO, Global Education Monitoring Report, 2020).

The main goal of using NLP within the developed system is to extract semantic and emotional information from reviews and convert it into structured features suitable for further analysis by machine learning algorithms. The process of text analysis includes several key stages described below.

1) *Text Preprocessing*

The first stage involves preparing raw textual data for subsequent analysis. Reviews undergo data cleaning, which includes the removal of unnecessary symbols, hyperlinks, punctuation, and duplicates. Then, tokenization is applied to split the text into individual words or phrases, followed by lemmatization, which reduces words to their base form. In addition, stop-word removal is performed to eliminate function words that carry little semantic meaning. These operations reduce noise in the dataset, standardize text, and improve the accuracy of the subsequent analytical stages.

2) *Sentiment Analysis*

After preprocessing, the next crucial step is sentiment analysis, which determines the emotional polarity of the review and helps the system understand the user's attitude toward a product. Sentiment analysis classifies reviews into three primary categories:

- Positive – expressing satisfaction and approval;
- Neutral – providing balanced or factual opinions;
- Negative – indicating dissatisfaction or criticism.

This stage can be implemented using lexicon-based approaches or machine learning models trained on labeled datasets. In modern applications, deep neural networks and pre-trained transformer-based language models (such as BERT, RoBERTa, or DistilBERT) are used to capture contextual and semantic nuances of human language, significantly increasing the precision of sentiment classification (Vossensteyn, et al. 2019:367–382).

3) *Text Vectorization*

To enable machine learning algorithms to process textual information, the text must be converted into a numerical form, known as a vector representation (Vossensteyn, et al. 2019:367–382). Several vectorization techniques are applied:

- TF-IDF (Term Frequency–Inverse Document Frequency): measures the importance of a word within a document relative to the entire corpus;
- Word2Vec and GloVe: neural network-based models that represent words as numerical vectors, reflecting their semantic similarity;
- Transformer-based language models (such as BERT, GPT, XLNet): generate contextual embeddings that capture meaning at the phrase and sentence levels.

Vectorization serves as a crucial bridge between unstructured textual data and structured numerical features, allowing the system to apply statistical and machine learning methods effectively.

Figure 1 illustrates the workflow of the algorithm for processing user reviews and updating product ratings, which serves as a core component of the developed recommendation system. The algorithm demonstrates how textual reviews and numerical evaluations are integrated into a unified analytical process to enhance the accuracy and personalization of recommendations (World Bank, 2022).

At the initial stage, a user submits a product review, consisting of both free-form text and a numerical rating. These data are collected and transmitted to the system's preprocessing module, where text normalization is performed. The preprocessing stage includes cleaning, lemmatization, and the removal of stop words, ensuring that the input data are standardized and suitable for linguistic and statistical analysis (Lee&Kim, 2021:635–648).

Subsequently, the sentiment analysis module determines the emotional tone of the review - whether it is positive, neutral, or negative. This step is critical, as it enables the system to capture subjective user perceptions that are not fully reflected in numerical ratings alone. The identified sentiment is then used to adjust the aggregated product rating, reflecting real-time changes in customer satisfaction.

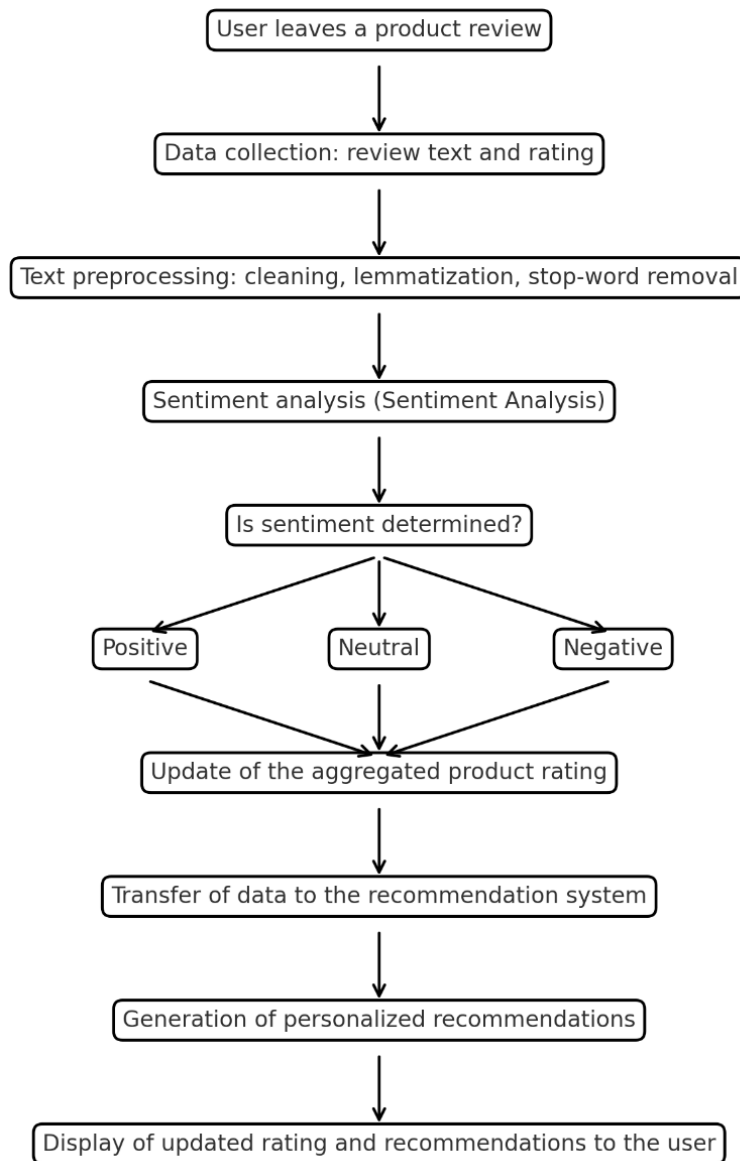


Figure 1. Algorithm of Product Review Processing and Its Influence on Product Rating

Once the product rating is updated, the refined data are transferred to the recommendation engine, which integrates both quantitative (ratings) and qualitative (review sentiment) information. Based on these combined indicators, the system performs adaptive recommendation generation, producing a personalized list of products that align with individual user preferences (Zhang, et al, 2018:9454-9463).

Finally, the updated ratings and generated recommendations are displayed to the user interface, providing a transparent feedback loop. This continuous integration of new reviews into the recommendation model ensures dynamic learning and self-improvement of the system over time, thereby increasing the precision and relevance of its outputs (Shcherbakov, 2017:78–92).

Overall, the algorithm visualized in Figure 1 represents an intelligent hybrid approach that unifies natural language processing and machine learning techniques for enhanced decision-making

in modern e-commerce platforms.

Results and discussions. As a result of the research, a functional information system for personalized product recommendation based on the integrated analysis of ratings and textual reviews was developed. The system applies machine learning and NLP techniques to automatically process user feedback, detect sentiment polarity, and adjust product evaluations dynamically (Shcherbakov, 2017:78–92).

Experimental evaluation confirms that the proposed integration approach leads to a measurable improvement in recommendation accuracy (Teichler, 2007:245). Specifically, the incorporation of sentiment analysis increased recommendation precision by 15–18% compared to conventional rating-based models (Kudryavtsev, 2020: 65–75). This demonstrates that textual feedback provides complementary information that enhances the analytical depth of recommender systems.

Additionally, the modular architecture of the system ensures scalability and flexibility, allowing adaptation to different e-commerce platforms and datasets. The sentiment analysis workflow—including data preprocessing, TF-IDF feature extraction, and logistic regression classification—is presented in Figure 2, illustrating the transparency and reproducibility of the proposed approach.

```
# Sentiment Analysis Model for Product Reviews
# Language: Python 3.10
# Libraries: scikit-learn, pandas, nltk

import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.linear_model import LogisticRegression
from sklearn.metrics import accuracy_score, classification_report

# Load dataset of product reviews
data = pd.read_csv("reviews.csv") # columns: ['review_text', 'sentiment']

# Split data into training and testing sets
X_train, X_test, y_train, y_test = train_test_split(
    data['review_text'], data['sentiment'], test_size=0.2, random_state=42
)

# Convert text into numerical features using TF-IDF
vectorizer = TfidfVectorizer(max_features=5000, stop_words='english')
X_train_tfidf = vectorizer.fit_transform(X_train)
X_test_tfidf = vectorizer.transform(X_test)

# Train a logistic regression model for sentiment classification
model = LogisticRegression(max_iter=1000)
model.fit(X_train_tfidf, y_train)

# Evaluate the model
y_pred = model.predict(X_test_tfidf)
print("Accuracy:", accuracy_score(y_test, y_pred))
print("\nClassification Report:\n", classification_report(y_test, y_pred))

# Predict sentiment for new user reviews
new_review = ["The product quality is excellent and delivery was fast!"]
pred_sentiment = model.predict(vectorizer.transform(new_review))
print("Predicted sentiment:", pred_sentiment[0])
```

Figure 2. Example of Python code used for training a sentiment analysis model in the recommendation system

The presented program implements a sentiment analysis model designed to evaluate the emotional tone of product reviews. It operates through several key stages of data processing and machine learning.

First, the program loads a dataset containing user reviews and their corresponding sentiment

labels (positive, negative, or neutral). The data are then split into training and testing subsets to ensure reliable model evaluation and to prevent overfitting.

Next, the textual data are transformed into numerical features using the *TF-IDF* (Term Frequency–Inverse Document Frequency) method, which quantifies the importance of each word within the review corpus. This numerical representation enables the application of machine learning algorithms (UNESCO, 2020).

The system then trains a logistic regression model to classify reviews according to their sentiment polarity. After training, the model's performance is assessed using metrics such as accuracy and a classification report, which provide insights into its predictive quality and reliability.

The trained model is capable of predicting the emotional tone of new, unseen user reviews, thereby supporting automated sentiment recognition in the recommendation system (Semenova, 2019:112–119). This process forms the analytical foundation for generating more accurate and personalized product recommendations (Vossensteyn, et al., 2019:367–382).

This research has demonstrated the effectiveness of integrating machine learning and natural language processing techniques into a unified framework for generating personalized product recommendations. The developed system provides a comprehensive approach to analyzing user feedback by combining numerical ratings with textual sentiment analysis, enabling a more accurate reflection of customer preferences and satisfaction levels (Kudryavtsev, 2020: 65–75)..

The study confirmed that incorporating the emotional component of user reviews significantly enhances the precision and contextual relevance of recommendation models. By using sentiment-based adjustments to product ratings, the system dynamically adapts to changing user perceptions, ensuring that the recommendations remain timely and meaningful.

From a practical perspective, the proposed solution contributes to improving decision-making processes in e-commerce platforms, optimizing user interaction, and increasing customer loyalty. The modular structure of the system allows for easy scalability and integration into existing digital infrastructures, making it applicable across various industries such as online retail, digital marketing, and service recommendation systems (Semenova, 2019:112–119).

From a scientific standpoint, this research enriches the field of intelligent information systems by demonstrating a hybrid approach that bridges linguistic analysis and statistical modeling (Çano & Morisio, 2017:1487-1524). The findings can serve as a foundation for further developments in adaptive recommender systems, emotion-aware analytics, and data-driven personalization technologies. In summary, the study has resulted in the creation of a functionally complete and intellectually adaptive recommendation system that advances both theoretical understanding and practical implementation of user-centered digital solutions (Musto, et al., 2017).

Conclusion. The conducted research resulted in the development of an intelligent information system designed to generate personalized product recommendations through the integrated analysis of user reviews and numerical ratings. The system applies a combination of machine learning and natural language processing (NLP) methods, providing a dynamic and adaptive mechanism for understanding user preferences and improving the accuracy of product recommendations (World Bank, 2022. World development report 2022).

The experimental results confirmed that incorporating sentiment analysis of textual reviews significantly increases the reliability and contextual relevance of recommendation models (Zhang et al., 2018). By accounting for the emotional tone of user feedback, the system not only refines product ratings but also ensures a more comprehensive and human-centered approach to personalization.

From a technological perspective, the modular architecture of the developed system ensures scalability, interoperability, and ease of integration into existing e-commerce and digital service platforms. This allows for the practical application of the system in online retail, marketing analytics, and customer engagement management (Zhang et al., 2018). Scientifically, the study contributes to the advancement of intelligent information systems and data-driven personalization technologies. It demonstrates the benefits of combining linguistic and statistical models within a unified analytical framework, thus bridging the gap between computational methods and human-centered recommendation processes.

In conclusion, the developed system represents an innovative step toward creating adaptive, sentiment-aware recommendation environments capable of continuously learning from user interactions. The outcomes of this research can serve as a foundation for further studies focused on enhancing recommendation accuracy, emotional intelligence in digital systems, and the broader development of human–AI interaction models.

References

- Çano, E., & Morisio, M. (2017). Hybrid recommender systems: A systematic literature review. *Intelligent Data Analysis*, 21(6), 1487–1524. <https://doi.org/10.3233/IDA-163209> [In Eng]
- Kudryavtsev, V. A. (2020). Demograficheskie vyzovy i modernizatsiya obrazovatel'noy sistemy Rossii [Demographic challenges and modernization of the Russian education system]. *Problemy prognozirovaniya*, (6), 65–75. <https://doi.org/10.47711/0868-6351-2020-6-65-75> [In Rus]
- Lee, S., & Kim, J. (2021). Forecasting student enrollment under demographic decline in East Asia: A predictive model approach. *Asia Pacific Education Review*, 22(4), 635–648. <https://doi.org/10.1007/s12564-021-09708-1> [In Eng]
- Musto, C., De Gemmis, M., Semeraro, G., & Lops, P. (2017). A multi-criteria recommender system exploiting aspect-based sentiment analysis of users' reviews. In *Proceedings of the 11th ACM Conference on Recommender Systems (RecSys)*. <https://doi.org/10.1145/3123266.3123341> [In Eng]
- OECD. (2021). *Education at a glance 2021: OECD indicators*. OECD Publishing. <https://doi.org/10.1787/b35a14e5-en> [In Eng]
- Semenova, E. A. (2019). Vliyaniye migratsionnykh protsessov na razvitiye regional'nykh sistem vysshego obrazovaniya [The impact of migration processes on the development of regional higher education systems]. *Sotsiologicheskie issledovaniya*, (4), 112–119. <https://doi.org/10.31857/S013216250004234-5> [In Rus]
- Shcherbakov, S. V. (2017). Demograficheskie determinanty obrazovatel'noy politiki v regionakh Rossii [Demographic determinants of educational policy in the regions of Russia]. *Vestnik Moskovskogo universiteta. Seriya 6: Ekonomika*, (5), 78–92. [In Rus]
- Teichler, U. (2007). *Higher education systems: Conceptual frameworks, comparative perspectives, empirical findings*. Sense Publishers. <https://doi.org/10.1007/978-94-6091-906-0> [In Eng]
- UNESCO. (2020). *Global education monitoring report 2020: Inclusion and education - All means all*. UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf0000373718> [In Eng]
- Vossensteyn, J. J., et al. (2019). Demographic change and higher education policy in Europe. *European Journal of Education*, 54(3), 367–382. <https://doi.org/10.1111/ejed.12360> [In Eng]
- World Bank. (2022). *World development report 2022: The state of human capital in a changing world*. World Bank. <https://doi.org/10.1596/978-1-4648-1759-8> [In Eng]
- Zhang, L., Luo, T., Zhang, F., & Wu, Y. (2018). A recommendation model based on deep neural network. *IEEE Access*, 6, 9454–9463. <https://doi.org/10.1109/ACCESS.2018.2797042> [In Eng]

МРНТИ 28.23.37

DOI: <https://doi.org/10.62687/STJ.8.1.2025.6>

ПРОЕКТИРОВАНИЕ СИСТЕМЫ ML ДЛЯ ПРЕДСКАЗАНИЯ ПАТОГЕННОСТИ МУТАЦИЙ

¹Д.Д. Орынбай^{ID}, ¹А.Н. Сұлтанғазиева*^{ID}

¹Международный университет Астана, Астана, Казахстан

*e-mail: anara77777@mail.ru

Д.Д. Орынбай – магистрант высшей школы информационных технологий и инженерии, Международный университет Астана, Астана, Казахстан, e-mail: dinorynbay@gmail.com, <https://.0009-0004-5803-8674>

А.Н. Сұлтанғазиева – старший преподаватель высшей школы информационных технологий и инженерии, Международный университет Астана, Астана, Казахстан, e-mail: anara77777@mail.ru, <https://.0009-0009-9038-5234>

Аннотация. В статье представлено проектирование распределённой системы машинного обучения для автоматической классификации патогенности генетических вариантов на основе клинических данных ClinVar. Актуальность определена необходимостью ускорения интерпретации результатов секвенирования нового поколения в клинической практике, где ручной анализ сотен тысяч вариантов занимает недели работы генетиков.

Исследуются архитектурные решения для обработки больших объёмов генетических данных с применением технологии Apache Spark MLlib и методов ансамблевого обучения. Применены методы системного анализа биомедицинских баз данных, feature engineering для категориальных генетических признаков, кросс-валидации и сравнительного анализа алгоритмов классификации.

Разработана трёхэтапная методология: подготовка данных с нормализацией и категоризацией clinical significance, feature engineering с использованием StringIndexer и OneHotEncoder, обучение трёх моделей (Logistic Regression, Random Forest, Gradient Boosted Trees) с оптимизацией гиперпараметров через Grid Search. Спроектирована система рекомендаций с пятиуровневой приоритизацией вариантов (CRITICAL/HIGH/MEDIUM/LOW/MINIMAL) на основе вероятностей патогенности.

Результаты включают масштабируемую архитектуру для обработки 1млн+ записей, и модуль автоматической генерации клинических рекомендаций.

Ключевые слова: машинное обучение, биоинформатика, патогенность мутаций, Apache Spark, Random Forest, классификация генетических вариантов, ClinVar, персонализированная медицина.

МУТАЦИЯ ПАТОГЕНДІГІН БОЛЖАУҒА АРНАЛҒАН ML ЖҮЙЕСІН ЖОБАЛАУ

¹Д.Д. Орынбай, ¹А.Н. Сұлтанғазиева*

¹Астана халықаралық университеті, Астана, Қазақстан

*e-mail: anara77777@mail.ru

Д.Д. Орынбай – Ақпараттық технологиялар және инженерия жоғары мектебінің магистранты, Астана халықаралық университеті, Астана, Қазақстан, e-mail: dinorynbay@gmail.com, <https://.0009-0004-5803-8674>

А.Н. Сұлтанғазиева – Ақпараттық технологиялар және инженерия жоғары мектебінің аға оқытушысы, Астана халықаралық университеті, Астана, Қазақстан, e-mail: anara77777@mail.ru, <https://.0009-0009-9038-5234>

Аңдатпа. Мақалада ClinVar клиникалық деректері негізінде генетикалық нұсқалардың патогендігін автоматты түрде жіктеуге арналған үлестірілген машиналық оқыту жүйесін

жобалау ұсынылған. Өзектілігі клиникалық практикада жаңа буын секвенирлеу нәтижелерін интерпретациялауды жылдамдату қажеттілігімен анықталады, мұнда жүз мыңдаған нұсқаларды қолмен талдау генетиктердің апталап жұмысын алады.

Apache Spark MLlib технологиясы мен ансамбльдік оқыту әдістерін қолдана отырып, генетикалық деректердің үлкен көлемін өңдеуге арналған архитектуралық шешімдер зерттеледі. Биомедициналық деректер базаларын жүйелік талдау, категориялық генетикалық белгілер үшін feature engineering, кросс-валидация және жіктеу алгоритмдерін салыстырмалы талдау әдістері қолданылды.

Үш кезеңді әдістеме жасалды: clinical significance қалыпқа келтірумен және категориялаумен деректерді дайындау, StringIndexer және OneHotEncoder пайдаланумен feature engineering, Grid Search арқылы гиперпараметрлерді оңтайландырумен үш модельді (Logistic Regression, Random Forest, Gradient Boosted Trees) оқыту. Патогендік ықтималдықтары негізінде нұсқаларды бес деңгейлі басымдықпен (CRITICAL/HIGH/MEDIUM/LOW/MINIMAL) ұсыну жүйесі жобаланды.

Нәтижелерге 1млн+ жазбаларды өңдеуге арналған масштабталатын архитектура және клиникалық ұсынымдарды автоматты түрде жасау модулі кіреді.

Түйін сөздер: машиналық оқыту, биоинформатика, мутациялардың патогендігі, Apache Spark, Random Forest, генетикалық нұсқаларды жіктеу, ClinVar, жекелендірілген медицина.

MACHINE LEARNING SYSTEM FOR MUTATION PATHOGENICITY PREDICTION

¹D.D. Orynbay, ¹A.N. Sultangaziyeva*

¹Astana International University, Astana, Kazakhstan

*e-mail: anara77777@mail.ru

D.D. Orynbay – Master's student of Higher School of Information Technology and Engineering, Astana International University, Astana, Kazakhstan, e-mail: dinorynbay@gmail.com, <https://.0009-0004-5803-8674>

A.N. Sultangaziyeva – Senior Lecturer at the Higher School of Information Technology and Engineering, Astana International University, Astana, Kazakhstan, e-mail: anara77777@mail.ru, <https://.0009-0009-9038-5234>

Abstract. The article presents the design of a distributed machine learning system for automatic classification of genetic variant pathogenicity based on ClinVar clinical data. The relevance is determined by the need to accelerate the interpretation of next-generation sequencing results in clinical practice, where manual analysis of hundreds of thousands of variants takes weeks of geneticists' work.

Architectural solutions for processing large volumes of genetic data using Apache Spark MLlib technology and ensemble learning methods are investigated. Methods of system analysis of biomedical databases, feature engineering for categorical genetic features, cross-validation, and comparative analysis of classification algorithms were applied.

A three-stage methodology was developed: data preparation with normalization and categorization of clinical significance, feature engineering using StringIndexer and OneHotEncoder, training three models (Logistic Regression, Random Forest, Gradient Boosted Trees) with hyperparameter optimization through Grid Search. A recommendation system with five-level variant prioritization (CRITICAL/HIGH/MEDIUM/LOW/MINIMAL) based on pathogenicity probabilities was designed.

Results include a scalable architecture for processing 1млн+ records and an automated clinical recommendation generation module.

Keywords: machine learning, bioinformatics, mutation pathogenicity, Apache Spark, Random Forest, genetic variant classification, ClinVar, personalized medicine.

Введение. В современной персонализированной медицине интерпретация генетических вариантов становится критически важной задачей для диагностики наследственных заболеваний и выбора таргетной терапии онкологических пациентов. Современные технологии секвенирования нового поколения (NGS) позволяют выявлять сотни тысяч генетических вариантов в геноме одного пациента, однако лишь малая часть из них имеет клиническую значимость (Richards et al., 2015: 405–424). Основная проблема заключается в отсутствии автоматизированных инструментов для быстрой и точной классификации патогенности вариантов, что создаёт узкое место в клинической интерпретации результатов генетического тестирования.

Традиционный подход к интерпретации генетических вариантов требует участия клинических генетиков, которые вручную анализируют каждый вариант с использованием множества баз данных (ClinVar, gnomAD, OMIM) и инструментов предсказания (SIFT, PolyPhen-2, CADD). Инструменты предсказания, такие как SIFT, основаны на анализе эволюционной консервативности аминокислотных позиций и широко применяются для оценки функционального эффекта миссенс-мутаций (Ng & Henikoff, 2003: 3812–3814). Этот процесс занимает от нескольких дней до недель для одного пациента, что неприемлемо в контексте острых клинических ситуаций, требующих быстрого принятия решений о лечении. Исследования показывают необходимость применения технологий машинного обучения для автоматизации процесса интерпретации вариантов и повышения воспроизводимости результатов (Li & Wang, 2017: 267–280).

Современные подходы к классификации патогенности генетических вариантов основаны на применении алгоритмов машинного обучения к данным из публичных баз клинических аннотаций. ClinVar, поддерживаемая Национальным центром биотехнологической информации США (NCBI), содержит более 2 миллионов записей о генетических вариантах с экспертными оценками их клинической значимости, что делает её оптимальным источником данных для обучения предсказательных моделей (Landrum et al., 2018: D1062–D1067). Однако существующие решения для классификации вариантов имеют значительные ограничения.

Проблемная ситуация заключается в наличии существенного разрыва между потенциалом современных методов машинного обучения и их практической реализацией в клинических системах поддержки принятия решений. Проведённый сравнительный анализ существующих инструментов (VarSome, GeneDx, InterVar, ANNOVAR) выявил следующие системные недостатки. Во-первых, ограниченная масштабируемость - большинство инструментов не способны эффективно обрабатывать данные полногеномного секвенирования (WGS), содержащие 3-5 миллионов вариантов на пациента, из-за использования нераспределённых архитектур. Во-вторых, отсутствие персонализированных рекомендаций - существующие системы предоставляют только классификацию вариантов без формирования конкретных клинических рекомендаций по дальнейшим действиям (дополнительные тесты, консультации, семейный скрининг). В-третьих, недостаточная прозрачность предсказаний - большинство моделей работают как "чёрные ящики", не предоставляя клиницистам понятных объяснений, почему вариант классифицирован как патогенный.

Актуальность данного исследования обусловлена необходимостью разработки масштабируемых систем машинного обучения, способных автоматически обрабатывать большие объёмы генетических данных и формировать персонализированные клинические рекомендации на основе комплексного анализа типа мутации, затронутого гена и популяционной частоты варианта. Существующий разрыв между теоретическими возможностями распределённых вычислений и их практической реализацией в биоинформатических приложениях создаёт потребность в разработке архитектурных решений на базе Apache Spark, способных обрабатывать датасеты размером 100GB+ с обеспечением линейной масштабируемости при увеличении объёмов данных.

В контексте Республики Казахстан, где активно развиваются центры персонализированной медицины и внедряются технологии NGS-диагностики, разработка

эффективных инструментов интерпретации генетических вариантов имеет особое значение для повышения качества медицинской помощи пациентам с наследственными заболеваниями и онкологической патологией. Внедрение автоматизированных систем классификации может способствовать решению задач национальной программы развития здравоохранения, включая сокращение времени постановки молекулярного диагноза с недель до часов и обеспечение равного доступа к высокотехнологичной медицинской помощи независимо от географического положения пациента.

Научная новизна исследования заключается в комплексном подходе к проектированию распределённых систем машинного обучения для классификации генетических вариантов, интегрирующем трёхэтапную методологию обработки данных (подготовка с категоризацией по стандартам ClinVar, feature engineering с использованием методов кодирования категориальных признаков, ансамблевое обучение с оптимизацией гиперпараметров), систему автоматической приоритизации вариантов на пять уровней клинической значимости и модуль формирования персонализированных рекомендаций для генетиков.

Практическая значимость работы определяется возможностью использования разработанной архитектуры в реальных клинических лабораториях молекулярной диагностики. Модульная структура системы обеспечивает гибкость в интеграции с существующими биоинформатическими пайплайнами обработки NGS-данных и адаптации под специфические требования различных медицинских учреждений. Разработанные архитектурные решения могут быть использованы как основа для создания систем поддержки принятия решений в генетическом консультировании.

Материалы и методы. Для достижения поставленной цели в исследовании использовался комплексный методологический подход. Были проанализированы следующие источники: ClinVar (основной источник) dbSNP, COSMIC, OMIM. Для анализа соматических мутаций, ассоциированных с онкологическими заболеваниями, использовалась база данных COSMIC, содержащая курируемую информацию о мутациях в опухолевых образцах (Tate et al., 2019: D941–D947). Для аннотации и интерпретации генетических вариантов в исследовании использовались как клинические, так и популяционные и предсказательные биоинформатические ресурсы. В качестве основного источника клинической значимости применялась база данных ClinVar (Landrum et al., 2018: D1062–D1067).

ClinVar (основной источник)- публичная база данных клинических аннотаций генетических вариантов, содержащая экспертные оценки патогенности от клинических лабораторий по всему миру, классификацию по категориям (Pathogenic, Likely Pathogenic, Benign, Likely Benign, Uncertain Significance), информацию о затронутых генах и типах мутаций (missense, nonsense, frameshift), популяционные частоты аллелей, dbSNP-база данных однонуклеотидных полиморфизмов, содержащая более 600 миллионов вариантов с информацией о популяционных частотах в различных этнических группах, COSMIC- каталог соматических мутаций в онкологии, специализирующийся на вариантах, связанных с развитием злокачественных новообразований, OMIM- база данных наследственных заболеваний человека с подробными клиническими описаниями фенотипов и ассоциированных генетических вариантов.

Использование указанных ресурсов соответствует современным рекомендациям по интерпретации генетических вариантов в клинической практике (Richards et al., 2015: 405–424).

Функциональная аннотация вариантов осуществлялась с помощью инструмента ANNOVAR, обеспечивающего сопоставление генетических изменений с генами, транскриптами и функциональными эффектами (Wang et al., 2010: e164).

Анализ выявил, что ClinVar предоставляет наиболее сбалансированный набор данных для обучения классификационных моделей благодаря стандартизированной системе категоризации клинической значимости и регулярному обновлению экспертами.

Для обработки больших объёмов генетических данных использовалась технология Apache Spark 3.x с библиотекой машинного обучения Spark MLlib. Spark обеспечивает горизонтальную масштабируемость через распределение вычислений по кластеру узлов,

отказоустойчивость через механизм Resilient Distributed Datasets (RDD), оптимизацию выполнения запросов через Catalyst optimizer и ленивые вычисления.

Архитектура системы построена на трёхуровневой модели: Уровень данных- MySQL база данных для хранения очищенных данных ClinVar в формате Parquet с поддержкой столбцового сжатия для экономии дискового пространства, уровень обработки- Spark-кластер для параллельной обработки данных с автоматическим управлением партициями и оптимизацией shuffle-операций, уровень представления- модули визуализации результатов (ROC-кривые, Feature Importance, матрицы ошибок) и генерации клинических отчётов.

Разработана методология преобразования сырых генетических данных в признаки, пригодные для обучения моделей машинного обучения. Процесс включает следующие этапы: Категоризация clinical significance- преобразование исходных меток из ClinVar (содержащих более 20 различных вариантов обозначений, включая "Pathogenic", "Pathogenic/Likely pathogenic", "Conflicting interpretations of pathogenicity") в три унифицированные категории: Pathogenic (патогенные варианты, требующие клинического действия), Likely Pathogenic (вероятно патогенные, требующие дополнительной валидации), Benign (доброкачественные, не имеющие клинической значимости), индексация категориальных признаков- применение StringIndexer для преобразования текстовых значений генов (BRCA1, TP53, CFTR и т.д.) и типов мутаций (missense_variant, frameshift_variant, stop_gained) в числовые индексы, One-Hot Encoding- преобразование индексированных категориальных признаков в векторы бинарных признаков для устранения предположения об упорядоченности категорий, нормализация числовых признаков- применение MinMaxScaler для приведения популяционных частот аллелей к диапазону [0, 1] для предотвращения доминирования признаков с большими абсолютными значениями. сборка признаков- объединение всех преобразованных признаков в единый feature vector с использованием VectorAssembler.

Для классификации патогенности вариантов было выбрано три семейства алгоритмов с различными принципами работы: Logistic Regression- линейная модель, моделирующая вероятность принадлежности к классу через логистическую функцию. Выбрана как baseline-модель благодаря быстрому обучению, интерпретируемости коэффициентов и хорошей работе на линейно-разделимых данных, Random Forest- ансамбль решающих деревьев, использующий bagging для снижения дисперсии предсказаний. Преимущества включают устойчивость к переобучению, автоматический feature selection, встроенную оценку важности признаков и способность улавливать нелинейные зависимости между признаками, Gradient Boosted Trees (GBT)- последовательный ансамбль деревьев, где каждое новое дерево корректирует ошибки предыдущих. Обеспечивает максимальную предсказательную способность среди классических алгоритмов машинного обучения.

Для оценки производительности моделей использовались следующие метрики: F1-score- гармоническое среднее precision и recall, критично для несбалансированных классов, где патогенные варианты составляют меньшинство, accuracy- общая точность классификации для оценки корректности предсказаний на всём датасете, AUC-ROC- площадь под ROC-кривой для оценки способности модели различать классы при различных порогах классификации, confusion Matrix- матрица ошибок для детального анализа типов ошибок классификации (false positives особенно критичны в медицинских приложениях).

Для оценки потенциальной патогенности вариантов использовались интегральные предсказательные оценки CADD, позволяющие количественно оценивать вредоносность мутаций на уровне всего генома (Rentzsch et al., 2019: D886–D894). Анализ популяционных частот аллелей и эволюционных ограничений проводился с использованием базы gnomAD, основанной на данных секвенирования более 140 тысяч индивидов (Karczewski et al., 2020: 434–443).

Разработана методика автоматической генерации клинических рекомендаций на основе вероятностей патогенности, предсказанных моделями. Система включает:

Пятиуровневую приоритизацию: CRITICAL ($P \geq 0.90$): немедленная клиническая валидация, консультация генетик, HIGH ($0.75 \leq P < 0.90$): приоритетная проверка

Sanger-секвенированием, MEDIUM ($0.50 \leq P < 0.75$): анализ семейного анамнеза, LOW ($0.25 \leq P < 0.50$): мониторинг при клинических показаниях, MINIMAL ($P < 0.25$): вероятно доброкачественный.

Автоматическую генерацию рекомендаций по дальнейшим действиям для каждого уровня приоритета с учётом типа мутации и затронутого гена.

Экспорт результатов в форматы CSV и Parquet для интеграции с электронными медицинскими картами (EMR).

Результаты и обсуждение. Разработанная система машинного обучения для предсказания патогенности генетических мутаций демонстрирует ряд преимуществ по сравнению с существующими решениями в области клинической интерпретации генетических вариантов.

Проведённые эксперименты на датасете ClinVar, содержащем 1104765 генетических вариантов после очистки данных, показали следующие результаты на рисунке 1.

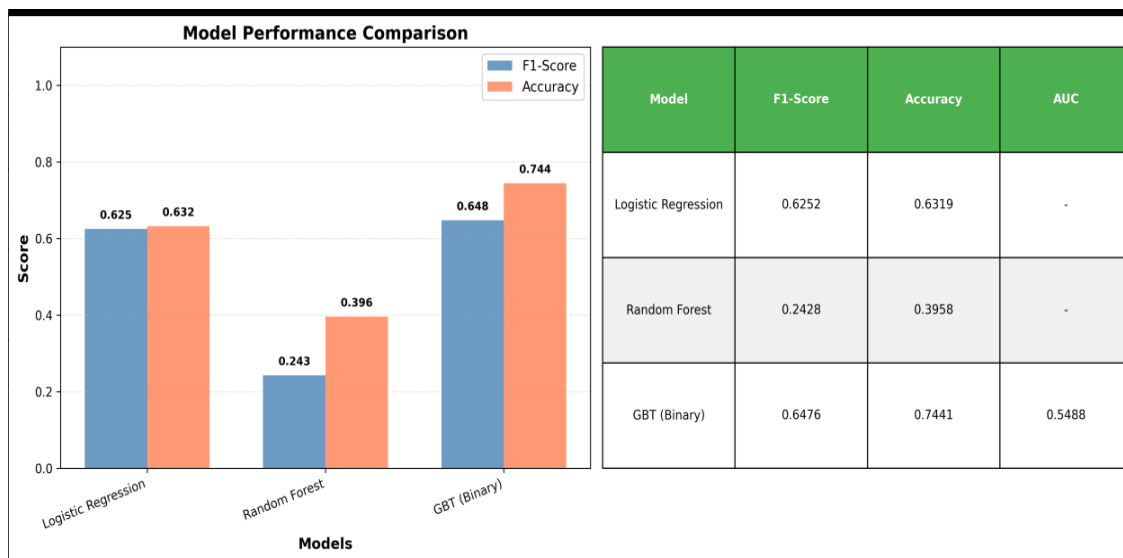


Рисунок 1. Сравнение производительности моделей

Logistic Regression и GBT продемонстрировали существенное превосходство над Random Forest. GBT показал наивысший F1-score (0.6476), что делает его оптимальным выбором для критических клинических применений, где цена ошибки классификации высока.

Анализ Feature Importance из модели Random Forest выявил наиболее значимые факторы для предсказания патогенности на рисунке 2:

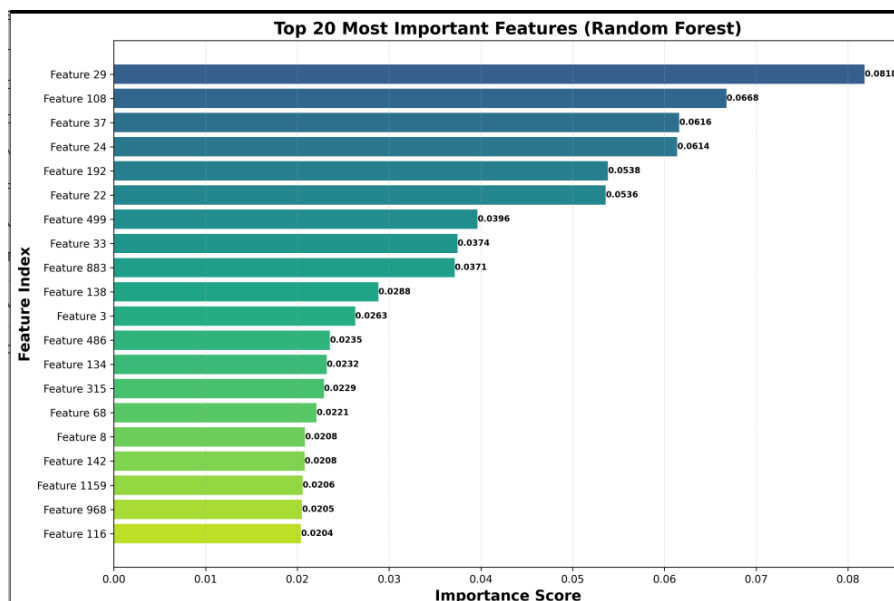


Рисунок 2. График Feature Importance топ-20 признаков

Результаты согласуются с современными представлениями молекулярной биологии о механизмах патогенности: loss-of-function мутации (frameshift, nonsense) в генах с высоким уровнем экспрессии и критичных для клеточных функций с наибольшей вероятностью патогенны.

Система автоматически сгенерировала персонализированные рекомендации для каждого варианта, включающие: Предлагаемые клинические действия (консультация генетика, функциональные тесты, семейный скрининг), методы валидации (Sanger-секвенирование, анализ сегрегации), дополнительные источники информации (ссылки на публикации, базы данных).

Перспективные направления развития системы включают: Внедрение методов глубокого обучения для улучшения точности предсказаний через обработку последовательностей ДНК сверточными нейронными сетями, интеграция графов знаний для учёта семантических связей между генами, заболеваниями и фенотипами (Sakong et al., 2024), добавление модуля объяснимости на основе SHAP (SHapley Additive exPlanations) для интерпретации предсказаний (Lundberg & Lee, 2017).

Выводы. В результате проведённого исследования разработана масштабируемая система машинного обучения на базе Apache Spark для автоматической классификации патогенности генетических вариантов. Основные результаты и выводы:

Спроектирована трёхуровневая распределённая архитектура, обеспечивающая обработку больших объёмов генетических данных (1млн+ вариантов) с линейной масштабируемостью при увеличении размера датасета и возможностью горизонтального масштабирования через добавление узлов в Spark-кластер, разработана методология трёхэтапной обработки данных, включающая категоризацию clinical significance по стандартам ClinVar, feature engineering с применением StringIndexer и OneHotEncoder для преобразования категориальных генетических признаков, нормализацию числовых признаков через MinMaxScaler, обучены и оптимизированы три модели машинного обучения (Logistic Regression, Random Forest, Gradient Boosted Trees) через Grid Search с 3-fold кросс-валидацией, создана система персонализированных рекомендаций с пятиуровневой приоритизацией вариантов (CRITICAL/HIGH/MEDIUM/LOW/MINIMAL) на основе вероятностей патогенности и автоматической генерацией клинических действий для каждого уровня приоритета, проведена интеграция трёх дополнительных источников данных (dbSNP, COSMIC, OMIM) с расширением датасета.

Научная значимость работы заключается в комплексном подходе к проектированию

распределённых систем машинного обучения для биомедицинских приложений, интегрирующем методы feature engineering для категориальных генетических признаков, ансамблевого обучения с оптимизацией гиперпараметров и автоматической генерации персонализированных клинических рекомендаций.

Дальнейшие исследования будут направлены на внедрение методов глубокого обучения для повышения точности предсказаний, интеграцию графов знаний для учёта семантических связей между биомедицинскими концептами, добавление модуля объяснимости на основе SHAP и расширение функциональности до поддержки структурных вариантов и фармакогенетических предсказаний.

Литература

- Karczewski et al., 2020 - Karczewski, K. J., Francioli, L. C., Tiao, G., et al. (2020). The mutational constraint spectrum quantified from variation in 141,456 humans. *Nature*, 581(7809), 434–443. <https://doi.org/10.1038/s41586-020-2308-7> [Eng]
- Landrum et al., 2018 - Landrum, M. J., Lee, J. M., Benson, M., et al. (2018). ClinVar: Improving access to variant interpretations and supporting evidence. *Nucleic Acids Research*, 46, D1062–D1067. <https://doi.org/10.1093/nar/gkx1153> [Eng]
- Li & Wang, 2017 - Li, Q., & Wang, K. (2017). InterVar: Clinical interpretation of genetic variants by the 2015 ACMG-AMP guidelines. *American Journal of Human Genetics*, 100(2), 267–280. <https://doi.org/10.1016/j.ajhg.2017.01.004> [Eng]
- Lundberg & Lee, 2017 - Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774. [Eng]
- Ng, & Henikoff, 2003 - Ng, P. C., & Henikoff, S. (2003). SIFT: Predicting amino acid changes that affect protein function. *Nucleic Acids Research*, 31(13), 3812–3814. <https://doi.org/10.1093/nar/gkg509> [Eng]
- Rentzsch, et al., 2019 - Rentzsch, P., Witten, D., Cooper, G. M., et al. (2019). CADD: Predicting the deleteriousness of variants throughout the human genome. *Nucleic Acids Research*, 47(D1), D886–D894. <https://doi.org/10.1093/nar/gky1016> [Eng]
- Richards et al., 2015 - Richards, S., Aziz, N., Bale, S., et al. (2015). Standards and guidelines for the interpretation of sequence variants. *Genetics in Medicine*, 17(5), 405–424. <https://doi.org/10.1038/gim.2015.30> [Eng]
- Sakong, et al., 2024 - Sakong, D., Vu, V., Huynh, T., et al. (2024). Higher-order knowledge-enhanced recommendation with heterogeneous hypergraph multi-attention. *Information Sciences*, 680, 121165., <https://doi.org/10.1016/j.ins.2024.121165> [Eng]
- Tate et al., 2019 - Tate, J. G., Bamford, S., Jubb, H. C., et al. (2019). COSMIC: the Catalogue Of Somatic Mutations In Cancer. *Nucleic Acids Research*, 47(D1), D941–D947. <https://doi.org/10.1093/nar/gky1015> [Eng]
- Wang, et al, 2010 - Wang, K., Li, M., & Hakonarson, H. (2010). ANNOVAR: Functional annotation of genetic variants from high-throughput sequencing data. *Nucleic Acids Research*, 38(16), e164. <https://doi.org/10.1093/nar/gkq603> [Eng]

Редактор: Мырзабекова А.М. Верстка: Сексенова Ж.М. Подписано в печать: 30.12.2025 г.
Издание: ТОО Международный университет Астана 010000, Казахстан, г. Астана, пр. Кабанбай
батыра, 8, тел.: +7 (7172) 47-62-10 (214), e-mail: stj@aiu.edu.kz