TASHENEV
UNIVERSITY

ТӘШЕНЕВ ХАБАРШЫСЫ
ВЕСТНИК ТАШЕНЕВА
BULLETIN OF TASHENEV

2026

№2(9) 2026

TASHENEV
UNIVERSITY

ЖҰМАБЕК АХМЕТҰЛЫ ТАШЕНЕВ АТЫНДАҒЫ УНИВЕРСИТЕТ	УНИВЕРСИТЕТ ИМЕНИ ЖУМАБЕКА АХМЕТОВИЧА ТАШЕНЕВА	ZHUMABEK AKHMETOVICH TASHENEV UNIVERSITY

ТӘШЕНЕВ ХАБАРШЫСЫ

ВЕСТНИК ТАШЕНЕВА

BULLETIN OF TASHENEV

Ғылыми журнал

№2 (9) 2026

Шымкент
2026

УДК 001
ББК 72
Т29

Бас редактор:
Рысбекова Ж.К. – заң ғылымдарының кандидаты, университет ректоры

Жауапты редактор:
Парманкулова П.Ж. – философия докторы (PhD)
Техникалық редактор:
Сыдықбай М.Д.

Редакция алқасы:
1. Агавелян Рубен Оганесович – псих.ғ.к., доцент, Новосібір мемлекеттік педагогикалық университеті
2. Займоглу Омер – философия докторы (PhD), профессор, Акдениз университеті
3. Сайфуллаева Р.Р. – ф.ғ.д., профессор., Мирзо Ұлықбек атындағы Өзбекстан ұлттық университеті
4. Курбанов М. – ф.ғ.д., профессор., Мирзо Ұлықбек атындағы Өзбекстан ұлттық университеті
5. Хамраева Х.Х. – ф.ғ.д., профессор м.а., Өзбекстан мемлекеттік хореография академиясы
6. Йулдашев И. – ф.ғ.д., профессор, Низами атындағы Өзбекстан ұлттық университеті
7. Сапарниязова М. – ф.ғ.д., профессор, Алфраганус университеті
8. Мамажанов М.Ю. – ф.ғ.д., профессор, Ферғана мемлекеттік университеті
9. Каримов С.А. – ф.ғ.д., профессор, Ш.Рашидов атындағы Самарқанд мемлекеттік университеті
10. Мустафа Демирчи – т.ғ.д., профессор, Сельжук университеті
11. Эржан Алкайя – ф.ғ.д., профессор, Фырат университеті
12. Иманкулова Л.Б. – философия докторы (PhD), Қазақ Ұлттық қыздар университеті
13. Байжуманова Б.Б. – псих.ғ.к., қауымдастырылған профессор, Л.Гумилев атындағы Еуразия Ұлттық университеті
14. Жолдасбекова С.А. – п.ғ.д., профессор, М.Әуезов атындағы Оңтүстік Қазақстан университеті
15. Байболов К.С. – т.ғ.к., професор, Ж.А.Тәшенев атындағы университет
16. Байнеева П.Т. –э.ғ.к., қауымдастырылған профессор, Ж.А.Тәшенев атындағы университет
17. Оралбекова А.К. – философия докторы (PhD), Ж.А.Тәшенев атындағы университет
18. Муминова Ш.С. – философия докторы (PhD), Ж.А.Тәшенев атындағы университет
19. Ботаева С.Б. – т.ғ.к., қауымдастырылған профессор, Ж.А.Тәшенев атындағы университет
20. Бакирова Ш.А. – ф.ғ.к., Ж.А.Тәшенев атындағы университет
21. Апашева С.Н. – тар.ғ.к., қауымдастырылған профессор, Ж.А.Тәшенев атындағы университет
22. Артыкбаева Ф.И. – философия докторы (PhD), Ж.А.Тәшенев атындағы университет
23. Бижан Н.Р. – з.ғ.к.., Ж.А.Тәшенев атындағы университет
24. Конакбаева У.Ж. – философия докторы (PhD), Ж.А.Тәшенев атындағы университет
25. Наралиева Ш.Д – философия докторы (PhD), Ж.А.Тәшенев атындағы университет

ISBN 978-601-08-5173-3

Журналға Қазақстан Республикасы Ақпарат және Қоғамдық даму министрлігі Ақпарат комитетіне есепке қою туралы **09.11.2023 ж. №KZ26VPY00081526 куәлігі берілген.**

Меншік иесі: «Жұмабек Ахметұлы Ташенев атындағы университеті» АҚ

Журнал 2024 жылдың сәуір айынан бастап шыға бастады. Жылына 4 рет жарық көреді.

Мақала авторларының пікірлері редакция көзқарасын білдірмейді. Мақалада баяндалған мәліметтердің шынайылығына авторлар жауап береді.

Редакцияның мекенжайы:
Шымкент қаласы, Қонаев к-сі, №21
e-mail: vestnik.tashenev@mail.ru

THE ROLE OF ARTIFICIAL INTELLIGENCE IN ENHANCING ENGLISH LANGUAGE TEACHING AND LEARNING: OPPORTUNITIES, CHALLENGES AND FUTURE PERSPECTIVES

[1]Iztileuova Akerke Zhaksylykovna
[2]Yeszhanova Gaukhar Dosmakhambetovna
[1]Senior lecturer of the department «World languages», JSC «Zhumabek Akhmetuly Tashenev University», D.Konaev avenue 21, Shymkent
e-mail: iztileuova.akerke@mail.ru
ORCID: https://orcid.org/0009-0000-9143-0935
[2]Senior lecturer of the department «World languages», JSC «Zhumabek Akhmetuly Tashenev University», D.Konaev avenue 21, Shymkent
e-mail: ms_gaukhare@mail.ru
ORCID: https://orcid.org/0009-0004-4094-9090

Abstract. English language education has experienced considerable changes due to the integration of AI-powered technologies that provide new opportunities for personalized learning, automated assessment, interactive communication, and innovative teaching strategies. This article explores the role of artificial intelligence in enhancing English language teaching and learning, focusing on its potential benefits, challenges, and future perspectives. The study analyzes current applications of AI in English language classrooms, including intelligent tutoring systems, automated feedback tools, speech recognition technologies, and generative AI platforms. The findings demonstrate that AI can support both teachers and learners by creating individualized learning experiences, improving students' motivation, and providing immediate feedback. At the same time, the integration of AI raises important issues related to digital competence, academic integrity, data privacy, and the changing role of teachers.

Key words: artificial intelligence, English language teaching, digital education, technology integration, language learning, personalized learning, teacher development.

Introduction

English has become one of the most important languages in the modern globalized world. It functions not only as a means of international communication but also as a key instrument for academic mobility, professional development, scientific cooperation, and access to global information resources. As a result, improving the effectiveness of English language teaching has become a major priority in educational systems worldwide. Over the past decades, approaches to English language teaching have undergone significant transformations. Traditional teacher-centered methods have gradually shifted toward learner-centered approaches that emphasize communication, interaction, creativity, and independent learning. The emergence of digital technologies has accelerated these changes by introducing new opportunities for language practice and educational innovation.

One of the most influential technological developments of recent years is artificial intelligence (AI). Artificial intelligence refers to computer systems capable of performing tasks that normally require human intelligence, including learning, problem-solving, language processing, and decision-making. In education, AI technologies are increasingly used to analyze learner performance, provide personalized recommendations, generate educational content, and facilitate communication between students and digital learning systems. The field of English language teaching has particularly benefited from AI applications. Language learning requires continuous practice, immediate feedback, and opportunities for meaningful communication. AI-powered tools can provide learners with additional opportunities to practice vocabulary, grammar, pronunciation, and speaking skills beyond the traditional classroom environment. Applications such as intelligent tutoring systems, automated writing assistants, speech recognition programs, and conversational AI platforms have created new possibilities for improving language competence.

Generative artificial intelligence, especially advanced language models, has attracted considerable attention among educators and researchers. Tools based on natural language processing technologies can assist students in writing, vocabulary development, translation, conversation practice, and critical thinking activities. For teachers, AI can support lesson planning, material development, assessment design, and classroom management. Despite its advantages, the integration of AI into English language education also presents several challenges. Concerns have been raised regarding students' overdependence on technology, academic dishonesty, ethical issues, and the need for teachers to develop new digital competencies. The effective use of AI requires not only technological resources but also appropriate pedagogical strategies [1].

The purpose of this article is to examine the role of artificial intelligence in enhancing English language teaching and learning. The article aims to explore the opportunities provided by AI technologies, identify potential challenges, and discuss future directions for AI-supported language education. The objectives of the study are:

1. To analyze the impact of artificial intelligence on English language teaching practices.
2. To examine the main applications of AI technologies in language learning.
3. To identify the benefits and limitations of AI integration in English education.
4. To discuss the changing role of English language teachers in the era of artificial intelligence.
5. To suggest future perspectives for effective AI implementation in language education.

Literature Review

The relationship between technology and language education has been studied extensively for several decades. The development of computer-assisted language learning (CALL) marked an important stage in the integration of digital technologies into foreign language education. CALL systems allowed learners to practice language skills through computer-based exercises, multimedia resources, and interactive activities. Technology-supported language learning can provide meaningful interaction, learner autonomy, and opportunities for communication. But early CALL systems were mainly based on programmed activities and lacked the ability to adapt to individual learner needs.

The emergence of artificial intelligence has introduced a new stage in technology-enhanced language learning. Unlike traditional digital tools, AI systems can analyze large amounts of learner data and provide adaptive responses. This allows educational platforms to create personalized learning experiences based on students' abilities, progress, and learning preferences.

Research conducted by Luckin (2018) emphasizes that AI has the potential to transform education by supporting personalized instruction and improving learning outcomes. AI technologies can identify students' strengths and weaknesses and recommend appropriate learning activities. In language education, this capability is particularly valuable because learners often have different levels of vocabulary knowledge, grammatical competence, and communication skills [2].

Recent studies have also highlighted the role of AI-powered conversational systems in foreign language learning. Chatbots and virtual assistants provide learners with opportunities to practice authentic communication in a low-pressure environment. These systems can simulate conversations, correct errors, and encourage students to use English more actively. Scholars emphasize that technology alone cannot guarantee successful learning outcomes. According to Richards and Rodgers (2014), effective language teaching requires appropriate methodology, meaningful interaction, and consideration of learners' social and cultural contexts. Therefore, AI should be integrated into language education through carefully designed pedagogical approaches.

The literature demonstrates that artificial intelligence represents a significant opportunity for improving English language education. Nevertheless, further research is required to understand how AI can be effectively combined with traditional teaching methods and how teachers can be prepared for this technological transformation [3].

Research methodology

The integration of artificial intelligence into English language teaching is based on several important educational theories and methodological approaches. Understanding these theoretical foundations is essential for effective implementation of AI technologies in the language classroom.

Constructivism is one of the influential theories that supports modern approaches to foreign language education. According to constructivist theory, learners actively construct knowledge through experience, interaction, and reflection rather than simply receiving information from teachers. In English language teaching, this approach emphasizes the importance of communication, collaboration, problem-solving, and authentic learning experiences. AI technologies can support constructivist learning by providing students with interactive environments where they can experiment with language, receive feedback, and independently explore new materials.

Communicative Language Teaching (CLT) has become one of the most widely used approaches in English language education. The main principle of CLT is that language should be learned through communication rather than only through the study of grammatical structures. Artificial intelligence supports communicative approaches by creating additional opportunities for interaction. AI chatbots and virtual assistants can act as conversation partners, allowing learners to practice speaking skills at any time. This is especially valuable for students who may feel anxious when speaking English in front of classmates [4].

Modern education increasingly focuses on individual learner needs. The learner-centered approach recognizes that students have different abilities, interests, learning speeds, and educational goals. Traditional classroom environments often make it difficult for teachers to provide individual attention to every student. AI technologies can help solve this problem by analyzing learner performance and creating personalized educational pathways [5].

AI systems can identify: vocabulary areas requiring improvement, frequently repeated grammatical errors, pronunciation difficulties, gaps in reading or listening comprehension. Based on this information, AI platforms can recommend appropriate exercises and learning materials. This personalized approach helps students progress according to their own learning pace.

One of the most significant advantages of AI in education is its ability to personalize learning experiences. Every student has unique learning needs, and effective language instruction requires consideration of individual differences. Personalized learning contributes to greater student engagement because learners work with materials that match their current level. It also helps prevent frustration caused by tasks that are either too difficult or too easy.

Results and discussion

Speaking is often considered one of the most challenging skills for English learners. Many students understand grammar and vocabulary but experience difficulties expressing their thoughts orally. Limited classroom time and fear of making mistakes can reduce opportunities for speaking practice. AI technologies provide innovative solutions to this problem through speech recognition and conversational systems. Virtual conversation partners allow students to practice English without social pressure. Unlike traditional classroom situations where students may hesitate to speak, AI systems create a safe environment for experimentation and learning from mistakes. Such activities increase speaking confidence and help learners develop practical communication skills [6].

Vocabulary knowledge is a fundamental component of successful language learning. AI technologies can improve vocabulary acquisition through adaptive practice and contextual learning.

Assessment is an important part of English language education. Traditional assessment methods often require significant teacher time and may not always provide immediate feedback.

Artificial intelligence does not replace teachers; instead, it can reduce routine tasks and allow educators to focus on more important pedagogical responsibilities. By saving time on administrative tasks, teachers can devote more attention to student interaction and individualized support. AI technologies make English learning more accessible to different groups of learners. This is particularly important for learners who have limited access to traditional language courses. AI-supported education can also support inclusive learning by providing additional assistance for students with different educational needs [7].

The effective implementation of AI in English language education depends greatly on teachers' technological knowledge and professional readiness. Many teachers may experience difficulties because they lack sufficient digital skills or understanding of AI-based educational tools. Technology itself cannot improve teaching quality unless educators know how to integrate it into appropriate teaching strategies.

Professional development programs should provide teachers with practical training on AI applications. Teacher education institutions should include digital literacy and AI pedagogy in their curricula. The role of the teacher is not reduced by AI; rather, it becomes more complex. Teachers must combine linguistic expertise, pedagogical knowledge, and technological competence to create effective learning environments.

Another important challenge is unequal access to technology. Not all students have the same opportunities to use AI-based learning tools. This digital divide can create educational inequality between different groups of learners. To ensure fair access, governments and educational institutions should invest in digital infrastructure and provide support for students who lack technological resources.AI should become a tool for educational inclusion rather than a factor that increases existing inequalities.

The emergence of artificial intelligence is transforming the traditional role of English language teachers. In the past, teachers were primarily viewed as sources of knowledge and providers of information. Today, unlimited information is available through digital technologies, and the teacher's role has become more focused on guidance, facilitation, and learning design. Teachers help students navigate educational resources, choose effective learning strategies, and develop independent learning skills. AI can provide information and feedback, but teachers provide emotional support, motivation, and human interaction.

Language learning involves psychological and emotional factors. Students often experience anxiety, lack of confidence, or fear of making mistakes. AI systems cannot fully replace human encouragement and empathy. Teachers remain responsible for creating supportive classroom environments where students feel motivated to communicate. The future of English language teaching should be based on cooperation between teachers and artificial intelligence rather than competition. The development of artificial intelligence will continue to influence English language teaching in the coming years. Future AI applications may provide even more advanced opportunities for language education.

One possible future direction is the development of AI-based virtual language tutors that can provide individualized instruction. Virtual tutors may become valuable assistants, especially for independent learners. Artificial intelligence provides significant opportunities for improving English language education, its implementation also involves several challenges. Successful integration of AI requires not only technological infrastructure but also careful consideration of pedagogical, ethical, and social factors. One of the most important concerns related to artificial intelligence in education is academic integrity. The availability of generative AI tools has created new possibilities for students to produce written assignments, essays, and other academic materials with minimal personal effort. Students may use AI systems to:

- write essays without developing their own ideas;
- complete homework assignments automatically;
- translate texts without understanding the meaning;
- avoid independent language practice.

Such practices may negatively influence students' learning outcomes because language acquisition requires active participation, practice, and personal effort. Educators need to develop clear guidelines for responsible AI use. Instead of completely prohibiting AI technologies, teachers should encourage students to use them as learning assistants. Students can use AI tools to receive feedback, improve drafts, generate ideas, and analyze mistakes while maintaining responsibility for their final work.

Academic institutions should also focus on developing AI literacy among students. Learners need to understand both the advantages and limitations of artificial intelligence and use these technologies ethically.

The effective implementation of AI in English language education depends greatly on teachers' technological knowledge and professional readiness. Many teachers may experience difficulties because they lack sufficient digital skills or understanding of AI-based educational tools. Technology itself cannot improve teaching quality unless educators know how to integrate it into appropriate teaching strategies. Modern English language teachers need competencies in the following areas:

- understanding AI principles and functions;
- selecting appropriate digital tools;
- evaluating the reliability of AI-generated information;
- designing AI-supported learning activities;
- maintaining ethical standards in technology use.

Professional development programs should provide teachers with practical training on AI applications. Teacher education institutions should include digital literacy and AI pedagogy in their curricula. The role of the teacher is not reduced by AI; rather, it becomes more complex. Teachers must combine linguistic expertise, pedagogical knowledge, and technological competence to create effective learning environments.

AI educational systems often collect and process large amounts of learner data. This information may include learning progress, assessment results, personal profiles, communication records, learning behavior patterns. While this data helps AI systems provide personalized learning experiences, it also creates concerns about privacy and security.

Educational institutions must ensure that AI platforms follow ethical standards regarding data collection and protection. Students and teachers should be informed about:

- what data is collected;
- how information is stored;
- who can access the data;
- how personal information is protected.

Data security should become an essential component of digital education policies.

Another important challenge is unequal access to technology. Not all students have the same opportunities to use AI-based learning tools. This digital divide can create educational inequality between different groups of learners. To ensure fair access, governments and educational institutions should invest in digital infrastructure and provide support for students who lack technological resources. AI should become a tool for educational inclusion rather than a factor that increases existing inequalities.

The emergence of artificial intelligence is transforming the traditional role of English language teachers. In the past, teachers were primarily viewed as sources of knowledge and providers of information. Today, unlimited information is available through digital technologies, and the teacher's role has become more focused on guidance, facilitation, and learning design.

Teachers help students navigate educational resources, choose effective learning strategies, and develop independent learning skills. AI can provide information and feedback, but teachers provide emotional support, motivation, and human interaction [8].

Modern teachers need to design learning activities that combine traditional methods with technological tools. A teacher may create a lesson where students:

1. use AI tools to research vocabulary;
2. participate in classroom discussions;
3. analyze AI-generated texts;
4. develop their own creative responses.

Such activities encourage critical thinking and meaningful language use.

Language learning involves psychological and emotional factors. Students often experience anxiety, lack of confidence, or fear of making mistakes. AI systems cannot fully replace human

encouragement and empathy. Teachers remain responsible for creating supportive classroom environments where students feel motivated to communicate. The future of English language teaching should be based on cooperation between teachers and artificial intelligence rather than competition.

The development of artificial intelligence will continue to influence English language teaching in the coming years. Future AI applications may provide even more advanced opportunities for language education.

One possible future direction is the development of AI-based virtual language tutors that can provide individualized instruction. Such systems may analyze students' learning styles, create personalized courses, conduct speaking practice, monitor progress, recommend learning strategies. Virtual tutors may become valuable assistants, especially for independent learners [9].

he combination of AI and virtual reality (VR) may create immersive language learning environments. Students could practice English in simulated real-world situations, such as:

- visiting foreign countries;
- participating in business meetings;
- attending international conferences;
- communicating with virtual characters.

In the future, AI literacy will become an essential competence for both teachers and students. English language education should not only teach students how to use AI tools but also how to think critically about technology. Learners should develop skills such as:

- evaluating AI-generated information;
- using technology responsibly;
- understanding ethical issues;
- combining human creativity with technological support.

Conclusion

Artificial intelligence has become an important factor influencing the development of modern English language education. AI technologies provide significant opportunities for improving teaching and learning processes through personalization, automated feedback, interactive communication, and increased accessibility. The use of AI-powered tools can support students in developing all major language skills, including speaking, writing, reading, and vocabulary acquisition. For teachers, artificial intelligence offers valuable assistance in lesson planning, assessment, and educational material development. AI integration also presents challenges related to academic integrity, teacher preparation, data privacy, and digital inequality. These issues require thoughtful educational policies and responsible approaches to technology implementation [10].

The future of English language teaching will not be determined by technology alone. The most effective educational model will combine artificial intelligence with professional teaching expertise, creativity, and human interaction. Teachers will continue to play a central role as mentors, facilitators, and designers of meaningful learning experiences. Artificial intelligence should be viewed not as a replacement for English language teachers but as a powerful tool that enhances their ability to support learners. Through balanced integration of technology and pedagogy, AI can contribute to creating more effective, inclusive, and innovative English language education.

References:

1. UNESCO. (2023). Guidance for Generative AI in Education and Research. Paris: United Nations Educational, Scientific and Cultural Organization.
https://unesdoc.unesco.org/ark:/48223/pf0000386693

2. Wei, L. (2023). Artificial intelligence in language instruction: Impact on English learning achievement, L2 motivation, and self-regulated learning. Frontiers in Psychology, 14, Article 1261955.
https://doi.org/10.3389/fpsyg.2023.1261955

3. Law, L. (2024). Application of Generative Artificial Intelligence (GenAI) in Language Teaching and Learning: A Scoping Literature Review.

4. Tlili, A., Shehata, B., Burgos, D., et al. (2023). What if the devil is my guardian angel: ChatGPT as a case study of using chatbots in education. Smart Learning Environments, 10, Article 15. https://doi.org/10.1186/s40561-023-00237-x

5. Lim, W. M., Gunasekara, A., Pallant, J. L., Pallant, J. I., & Pechenkina, E. (2023). Generative AI and the future of education: Ragnarök or reformation?

A paradoxical perspective from management educators. International Journal of Management Education, 21(2), 100790.

6. Kasneci, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., et al. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. Learning and Individual Differences, 103, 102274. https://doi.org/10.1016/j.lindif.2023.102274

7. Zhai, X. (2022). ChatGPT user experience: Implications for education.

Social Science Research Network (SSRN). https://doi.org/10.2139/ssrn.4312418

8. Su, J., & Yang, W. (2023). Unlocking the power of ChatGPT: A framework for applying generative AI in education. Computers and Education: Artificial Intelligence, 5, 100144.

9. Chan, C. K. Y., & Hu, W. (2023). Students' voices on generative AI: Perceptions, benefits, and challenges in higher education. International Journal of Educational Technology in Higher Education, 20, Article 43. https://doi.org/10.1186/s41239-023-00411-8

10. Kohnke, L., Moorhouse, B. L., & Zou, D. (2023). ChatGPT for language teaching and learning. RELC Journal, 54(2), 537–550. https://doi.org/10.1177/00336882231162868

АҒЫЛШЫН ТІЛІН ОҚЫТУ МЕН ОҚУДЫ ЖЕТІЛДІРУДЕГІ ЖАСАНДЫ ИНТЕЛЛЕКТТІҢ РӨЛІ: МҮМКІНДІКТЕР, ҚИЫНДЫҚТАР ЖӘНЕ БОЛАШАҚ ПЕРСПЕКТИВАЛАР

[1]Изтилеуова Ақерке Жақсылыққызы
[2]Есжанова Гаухар Досмахамбетовна
[1]«Әлем тілдері» кафедрасының аға оқытушысы,
«Ж.А.Тәшенев атындағы университет» АҚ, Д.Қонаев даңғылы 21, Шымкент
e-mail: iztileuova.akerke@mail.ru
ORCID: https://orcid.org/0009-0000-9143-0935
[2]«Әлем тілдері» кафедрасының аға оқытушысы,
«Ж.А.Тәшенев атындағы университет» АҚ, Д.Қонаев даңғылы 21, Шымкент
e-mail: ms_gaukhare@mail.ru
ORCID: https://orcid.org/0009-0004-4094-9090

Андатпа. Ағылшын тілінде білім беру жекелендірілген оқыту, автоматтандырылған бағалау, интерактивті коммуникация және оқытудың инновациялық стратегиялары үшін жаңа мүмкіндіктер беретін жасанды интеллектке негізделген технологияларды біріктіру арқылы айтарлықтай өзгерістерге ұшырады. Бұл мақалада жасанды интеллекттің ағылшын тілін оқыту және оқытуды жетілдірудегі рөлі зерттеліп, оның әлеуетті артықшылықтарына, қиындықтарына және болашақ перспективаларына назар аударылады. Зерттеу интеллектуалды репетиторлық жүйелерді, автоматтандырылған кері байланыс құралдарын, сөйлеуді тану технологияларын және жасанды интеллект генеративті платформаларын қоса алғанда, ағылшын тілі кабинеттеріндегі жасанды интеллекттің ағымдағы қолданбаларын талдайды. Нәтижелер жасанды интеллект мұғалімдерге де, оқушыларға да жеке оқу тәжірибесін жасау, оқушылардың мотивациясын жақсарту және дереу кері байланыс беру арқылы қолдау көрсете алатынын көрсетеді. сонымен қатар, жасанды интеллекттің интеграциясы цифрлық құзыреттілікке, академиялық адалдыққа, деректердің құпиялылығына және мұғалімдердің рөлінің өзгеруіне байланысты маңызды мәселелерді көтереді.

Кілт сөздер: жасанды интеллект, ағылшын тілін оқыту, цифрлық білім беру, технологияларды интеграциялау, тілдерді оқыту, дербестендірілген оқыту, мұғалімдерді дамыту.

РОЛЬ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В СОВЕРШЕНСТВОВАНИИ ПРЕПОДАВАНИЯ АНГЛИЙСКОГО ЯЗЫКА: ВОЗМОЖНОСТИ, ПРОБЛЕМЫ И ПЕРСПЕКТИВЫ НА БУДУЩЕЕ

[1]Изтилеуова Акерке Жаксылыковна
[2]Есжанова Гаухар Досмахамбетовна
[1]Старший преподаватель кафедры «Мировые языки»,
АО «Университет имени Жумабека Ахметовича Ташенева»,
проспект Д.Қонаева 21, г.Шымкент, e-mail: iztileuova.akerke@mail.ru
ORCID: https://orcid.org/0009-0000-9143-0935
[2]Старший преподаватель кафедры «Мировые языки»,
АО «Университет имени Жумабека Ахметовича Ташенева»,
проспект Д.Қонаева 21, г.Шымкент, e-mail: ms_gaukhare@mail.ru
ORCID: https://orcid.org/0009-0004-4094-9090

Аннотация. Обучение английскому языку претерпело значительные изменения благодаря интеграции технологий, основанных на ИИ, которые предоставляют новые возможности для персонализированного обучения, автоматизированной оценки, интерактивного общения и инновационных стратегий преподавания. В этой статье исследуется роль искусственного интеллекта в совершенствовании преподавания английского языка, особое внимание уделяется его потенциальным преимуществам, проблемам и перспективам на будущее. В исследовании анализируется текущее применение ИИ на уроках английского языка, включая интеллектуальные системы обучения, автоматизированные инструменты обратной связи, технологии распознавания речи и генерирующие платформы ИИ. Результаты показывают, что ИИ может поддерживать как преподавателей, так и учащихся, создавая индивидуальный опыт обучения, повышая мотивацию учащихся и обеспечивая немедленную обратную связь. В то же время интеграция искусственного интеллекта поднимает важные вопросы, связанные с цифровой компетентностью, академической честностью, конфиденциальностью данных и меняющейся ролью преподавателей.

Ключевые слова: искусственный интеллект, преподавание английского языка, цифровое образование, интеграция технологий, изучение языка, персонализированное обучение, повышение квалификации преподавателей.

ӘОЖ 004.738.5

ҚАЗАҚСТАН ЖОҒАРЫ ОҚУ ОРЫНДАРЫ ВЕБ-САЙТТАРЫНЫҢ ЖҮКТЕЛУ ЖЫЛДАМДЫҒЫНА ӘСЕР ЕТЕТІН ФАКТОРЛАР: ЭМПИРИКАЛЫҚ ТАЛДАУ

[1]Сматұлла Т.Б., [2]Изханова Б.Е., [3]Сейтханова Ә.Б.
[1]IT және цифрлық технологиялар кафедрасының оқытушысы, магистр
Ж.А.Тәшенев атындағы университет, Шымкент қ
smatulla.t@gmail.com , https://orcid.org/0009-0009-1446-159X
[2]IT және цифрлық технологиялар кафедрасының аға оқытушысы, магистр
Ж.А.Тәшенев атындағы университет, Шымкент қ.
izkhanova@list.ru, https://orcid.org/0009-0008-0688-6224
[3]IT және цифрлық технологиялар кафедрасының аға оқытушысы, магистр
Ж.А.Тәшенев атындағы университет, Шымкент қ.
sejthanovaajgerim1@gmail.com, https://orcid.org/0009-0005-6541-1737

Аңдатпа. Мақалада Қазақстан жоғары оқу орындары басты беттерінің жүктелу жылдамдығы мен оған әсер ететін құрылымдық факторлар эмпирикалық тұрғыдан талданады. Деректер 13 университет сайты бойынша Lighthouse 13.5.0 негізіндегі PageSpeed Insights API арқылы мобильді құрылғыны эмуляциялау режимінде жиналды; әр сайт үшін екі немесе үш тәуелсіз өлшемнің медианасы алынды. LCP (Largest Contentful Paint) көрсеткішінің медианасы 20,9 с болды, 2,5 секундтық «жақсы» шектен тек бір сайт өтті. Беттің жалпы көлемі мен LCP арасындағы байланыс логарифмдік шкалада күшті болды (β = 0,61; 95% СИ 0,50–0,72; R^2 = 0,81): көлем екі есе артқанда LCP шамамен 53%-ға ұлғайды. Алайда көлемі 4,7 МБ-тан асатын 11 сайтта бұл байланыс әлсіз (R^2 = 0,29), ал CDN әсерін көлемнен ажырату мүмкін болмады, өйткені CDN анықталған екі сайт — іріктемедегі ең жеңіл беттер. Іріктеме шағын және кездейсоқ емес, дизайн корреляциялық, сондықтан нәтижелер себеп-салдарлық тұжырымға негіз бола алмайды.

Кілт сөздер: веб-сайт, жүктелу жылдамдығы, Core Web Vitals, LCP, Lighthouse, регрессиялық талдау, жоғары оқу орны, CDN.

Кіріспе

Жоғары оқу орнының ресми сайты — талапкер мен оның ата-анасы үшін университет туралы алғашқы, көп жағдайда жалғыз ақпарат көзі. Қабылдау ережелері, білім беру бағдарламаларының тізімі, оқу ақысы, құжат тапсыру мерзімдері сияқты шешімге тікелей әсер ететін мәліметтер дәл осы арқылы қаралады. Сайт баяу ашылса, бұл тек ыңғайсыздық емес: пайдаланушы керек ақпаратқа жетпей-ақ кетіп қалуы мүмкін, ал мұндай шығын әдетте байқалмай қалады, өйткені кетіп қалғандар туралы сайт иесінде дерек болмайды. Қазақстанда мобильді интернеттің таралуы жоғары екенін ескерсек [stat.gov.kz], талапкерлердің едәуір бөлігі сайтқа смартфоннан, көбіне өткізу қабілеті шектеулі желі арқылы кіреді деп болжауға болады; бұл жылдамдық мәселесін өткірлей түседі.

Адам мен компьютер арасындағы диалогта жауап беру уақытының шектері бұрыннан зерттеліп келеді: шамамен 0,1, 1 және 10 секундтық шектерді Миллер (1968) ұсынып, Нильсен (1993) жүйелеген. Веб-ортаға қатысты Нах (2004) пайдаланушылардың күту уақытына шыдамдылығын, ал Галлетта және т.б. (2004) сайт кідірісінің пайдаланушы жұмысы мен сайтқа қатынасына әсерін эксперименттік жолмен зерттеді. Олардың нақты сандық шектері сол кездегі желі мен құрылғыларға байланысты, сондықтан бүгінгі жағдайға тікелей көшірілмейді; ал негізгі қорытынды — кідіріс ұлғайған сайын пайдаланушының қанағаттануы төмендейді — кейінгі жұмыстарда да қайталанып келеді.

Қазіргі веб-инженерияда жүктелу тәжірибесін өлшеу үшін Google ұсынған Core Web Vitals метрикалар жинағы кеңінен қолданылады. Оның құрамына LCP, INP және CLS кіреді.

LCP — көрінетін аймақтағы ең үлкен элементтің (көбіне сурет не мәтін блогы) бейнеленуіне дейінгі уақыт; әзірлеушілер құжаттамасы бойынша 2,5 секундқа дейінгі мән жақсы, 4 секундтан асқаны нашар деп есептеледі (Web Vitals, web.dev). INP өрістік деректерді қажет ететіндіктен, зертханалық өлшеуде оның орнына TBT (Total Blocking Time) — негізгі ағынның бұғатталу уақыты пайдаланылады; CLS беттің көрнекі тұрақсыздығын сипаттайды. Біз негізгі назарды LCP-ға аударамыз, өйткені талапкер үшін «бет ашылды» деген сезім көбіне негізгі мазмұнның пайда болуымен байланысты.

Зерттеудің мақсаты — Қазақстан жоғары оқу орындары басты беттерінің LCP көрсеткішінің беттің құрылымдық сипаттамаларымен байланысын сандық бағалау. Негізгі гипотеза (H1): беттің жалпы көлемі мен LCP арасында оң байланыс бар, ол көлем логарифмінің LCP логарифміне оң регрессия коэффициентімен өрнектеледі. Қосымша, зерттеушілік сипаттағы екі сұрақ қойылады: HTTP-сұраныстар саны көлемнен тыс қосымша ақпарат бере ме және CDN қолданатын сайттар ерекшеленеді ме. Бастапқы жоспарда суреттерді оңтайландыру резервінің үлесі де тексерілмек болды, бірақ бұл айнымалыны жинау мүмкін болмады (Әдістер бөлімін қараңыз).

Әдістер

Зерттеу дизайны

Зерттеу көлденең (cross-sectional) дизайнда жүргізілді: әр сайт бір күн ішінде, бір қысқа уақыт терезесінде өлшенді. Мұндай дизайн факторлар арасындағы байланысты көрсетеді, бірақ себеп-салдарлық қатынасты дәлелдемейді.

Іріктеме

Бастапқы тізім негізінде құрылған 17 университет сайтынан тұрды. Тізім ұлттық және ірі университеттерден басталады. Нәтижелерді тізімнің қалған бөлігіне, әсіресе өңірлік және жеке меншік университеттерге тарату дұрыс болмайды.

Өлшенген 17 сайттың төртеуі талдаудан шығарылды. Екі сайт (kaznpu.kz және ukgu.kz) үшін PageSpeed Insights FAILED_DOCUMENT_REQUEST қатесін қайтарды, яғни қызмет бетті сенімді жүктей алмады. buketov.edu.kz сайтынан алынған жауап 814 байт көлемде және бір ғана сұраныстан тұрды; бұл сайттың нақты мазмұнын емес, қорғаныс беті немесе қарапайым жауап-хабарламасы сияқты нәрсені көрсетеді деп есептелді. Төртінші сайтта (kazatu.edu.kz) өлшеу тоқтатылғанға дейін тек бір сәтті өлшем жиналды, ал медиана үшін кемінде екі өлшем қажет. Талдауға 13 сайт енді.

Өлшеу құралы мен жағдайы

Метрикалар Lighthouse негізінде жұмыс істейтін PageSpeed Insights API (v5) арқылы жиналды (Lighthouse нұсқасы 13.5.0; Lighthouse overview; PageSpeed Insights API v5). Мобильді құрылғыны эмуляциялау режимі (strategy=mobile) таңдалды; бұл режимде желі мен процессордың баяулауы имитацияланады, сондықтан өлшемдер нақты пайдаланушы тәжірибесін емес, стандартталған зертханалық сценарийді көрсетеді. Өлшеу Google серверлерінен жүргізілді, яғни Қазақстаннан тыс нүктеден. Мобильді режимнің имитациялық сипатын нақтылау қажет. Lighthouse-тың әдепкі мобильді профилі шамамен 1,6 Мбит/с жүктеу жылдамдығы мен 150 мс кідірісі бар баяу 4G желісін және процессордың төрт есе баяулауын модельдейді. Мұндай өткізу қабілетінде 10 МБ-қа жуық бетті толық тасымалдаудың өзі 50 секундқа жуық уақыт алады, сондықтан мақалада келтірілген LCP мәндерінің 20–60 секундқа жетуі күтпеген құбылыс емес, ал абсолюттік мәндерді нақты пайдаланушылардың уақытымен тікелей салыстыруға болмайды.

Деректерді тазалау

Алғашқы нәтижелерді тексергенде PageSpeed Insights қызметі бір адреске жақын уақытта жіберілген қайталама сұраныстарға жаңа өлшем емес, кэштелген нәтиже қайтаратыны анықталды: бір сайттың екі прогонында өлшеу уақыты мен барлық метрика толық сәйкес келді. Мұндай қайталамалар (бірдей адрес пен бірдей өлшеу уақыты) алынып тасталды. Нәтижесінде жеті сайт үшін екі, алты сайт үшін үш тәуелсіз өлшем қалды. Әр сайт үшін

метрикалардың медианасы есептелді; екі өлшем болғанда медиана олардың орташа мәніне тең.

Айнымалылар

Тәуелді айнымалы — LCP-ның (секундпен) натурал логарифмі. Жүктелу уақытының үлестірімі әдетте оңға қарай қиғаш келеді, ал логарифмдеу қалдықтардың қалыптылығы мен дисперсия біртектілігі шарттарын жақсартады. Негізгі түсіндіруші айнымалы — беттің жалпы көлемінің (мегабайтпен) натурал логарифмі. Мұндай екі жақты логарифмдік модельде коэффициент серпімділік ретінде оқылады: көлем 1%-ға өскенде LCP шамамен β%-ға өзгереді (Wooldridge, 2020). Зерттеушілік модельдерге HTTP-сұраныстар саны және CDN бары (1) не жоғы (0) белгісі енгізілді. CMS түрі де тіркелді, бірақ көп сайт үшін анықталмағандықтан («unknown») және санаттар аз болғандықтан талдауға енгізілмеді. TBT мен CLS сипаттамалық түрде ғана беріледі.

Статистикалық талдау

Параметрлер қарапайым ең кіші квадраттар әдісімен бағаланды. 13 бақылауда сенімді бағалауға болатын предиктор саны өте аз (шамамен әр он бақылауға бір предиктор), сондықтан негізгі модель бір предикторлы: $\ln(LCP) = \beta_0 + \beta_1 \cdot \ln(көлем) + \varepsilon$. Шағын іріктемеде гетероскедастикаға тұрақты стандартты қателер (HC3; Лонг және Эрвин, 2000) және t-үлестірімі (n − k еркіндік дәрежесі) қолданылды. Қалдықтардың қалыптылығы Шапиро–Уилк, дисперсия біртектілігі Бройш–Паган критерийімен тексерілді. Тұрақтылықты бағалау үшін (а) әр сайтты кезекпен алып тастап модель қайта бағаланды, (ә) CDN анықталған сайттарсыз модель бағаланды, (б) Спирмен рангтік корреляциясы есептелді. Зерттеушілік модельдерде мультиколлинеарлық корреляциямен және дисперсияның инфляция факторымен (VIF; Kutner және т.б., 2005) бағаланды. Есептелген модельдердің бәрі баяндалады, олардың арасынан таңдау жасалған жоқ. Бірнеше салыстыру үшін түзету енгізілмеді, сондықтан зерттеушілік нәтижелердің p-мәндері ақпараттық ретінде оқылуы тиіс. Мәнділік деңгейі $\alpha = 0{,}05$. Есептеулер Python (pandas, numpy, scipy) ортасында орындалды; HC3 мен диагностикалық критерийлер матрицалық формулалармен жүзеге асырылды.

Нәтижелер

Сипаттамалық статистика

Талдауға 13 сайт енді; олардың жетеуі үшін екі, алтауы үшін үш тәуелсіз өлшем болды. LCP медианасы 20,9 с (квартильаралық ауқым 14,0–30,3 с), мәндер 2,0-ден 63,0 секундқа дейін өзгерді (1-кесте). 2,5 секундтан аспайтын «жақсы» көрсеткішті тек бір сайт (kaznau.kz — 2,0 с) көрсетті, ал 4 секундтан жоғары «нашар» мән 13 сайттың 12-сінде тіркелді. Беттің жалпы көлемінің медианасы 10,7 МБ (6,6–11,9 МБ), HTTP-сұраныстар санының медианасы — 115 (66–140,5). Ең жеңіл бет 0,16 МБ, ең ауыры 18,9 МБ болды, яғни көлем бойынша айырмашылық екі ретке жуық. TBT мен CLS сайттар арасында қатты ерекшеленді (TBT медианасы 148,5 мс, ең көбі 1638,5 мс; CLS медианасы 0,075, ең көбі 1,37).

Бір сайттың өлшемдері арасындағы шашырау да елеулі. Вариация коэффициентінің медианасы 0,07 болғанымен, бес сайтта ол 0,3-тен асты (nu.edu.kz үшін 0,88), сондықтан жеке сайттың LCP мәнін дәл сан ретінде емес, ауқым ретінде қабылдаған жөн.

Жеке сайттарға қысқаша тоқталсақ (А1-кесте): ең жылдам сайт (kaznau.kz, 2,0 с) бір мезгілде ең жеңіл әрі сұраныс саны ең аз сайт болды (0,16 МБ; 23 сұраныс). Ең баяу сайт (kstu.kz, 63,0 с) көлемі бойынша ең ауыры емес (11,45 МБ) және сұраныс саны салыстырмалы түрде аз (83). Керісінше, tou.edu.kz сайты ең көп сұраныспен (222) 43,8 с көрсетті. Ал satbayev.university көлемі 11,95 МБ болғанда LCP-сы 19,3 с болды, бірақ TBT (1638,5 мс) мен CLS (1,37) бойынша осы екі көрсеткіштің ең нашар мәнін көрсетті. Яғни LCP-ның жақсы болуы интерактивтілік пен көрнекі тұрақтылықтың жақсы екенін автоматты түрде білдірмейді.

1-кесте. Негізгі көрсеткіштердің сипаттамалық статистикасы (n = 13 сайт)

Көрсеткіш	Орташа	Медиана	Мин.	Макс.	СКО
LCP, с	24,85	20,86	1,97	62,97	16,39

Көрсеткіш	Орташа	Медиана	Мин.	Макс.	СКО
TBT, мс	271,3	148,5	0,0	1638,5	431,9
CLS	0,248	0,075	0,000	1,373	0,390
Көлем, МБ	9,35	10,69	0,16	18,86	5,30
Сұраныс саны	107,7	115,0	23	222	61,1

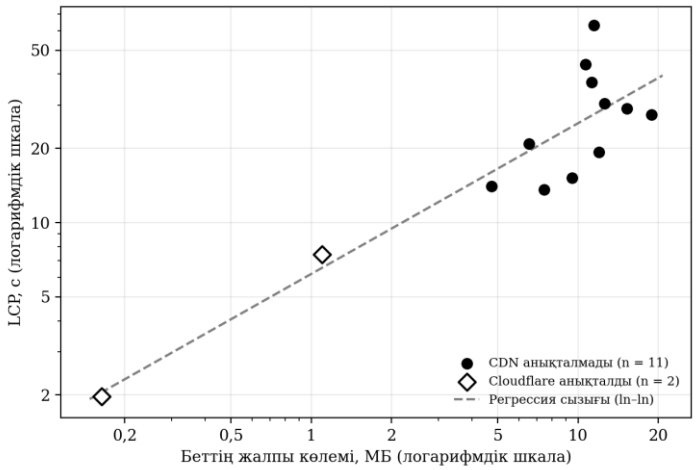
Беттің көлемі және LCP

Негізгі модельде ln(LCP)-ның ln(көлем)-ге регрессиясы 0,611 коэффициентін берді (HC3 стандартты қатесі 0,051; 95% СИ 0,498–0,724; p < 0,001; 2-кесте). Модель LCP логарифмінің дисперсиясының 81,3%-ын түсіндіреді (түзетілген $R^2 = 0,796$). Коэффициенттің бірден аз екені маңызды: көлемнің 10%-ға артуы LCP-ның шамамен 6,0%-ға, ал екі есе артуы шамамен 53%-ға ұлғаюымен қатар жүреді. Қалдықтар қалыптылықтан (Шапиро–Уилк, p = 0,47) және дисперсия біртектілігінен (Бройш–Паган, p = 0,27) елеулі ауытқымады, бірақ 13 бақылауда бұл критерийлердің қуаты төмен. Спирмен корреляциясы да оң байланысты растайды (ρ = 0,68; p = 0,010). 1-суретте нүктелердің екі топқа бөлінгені көрінеді: 11 сайт 4,7–18,9 МБ аралығында шоғырланған, ал екі сайт 1,1 МБ-тан аспайтын көлеммен бөлек орналасқан.

2-кесте. ln(LCP)-ның ln(көлем)-ге регрессиясы (n = 13; HC3 стандартты қателері)

Айнымалы	β	Станд. қате	t	p	95% СИ
Тұрақты (β_0)	1,823	0,087	21,04	< 0,001	1,633; 2,014
ln(көлем)	0,611	0,051	11,89	< 0,001	0,498; 0,724

$R^2 = 0,813$; түзетілген $R^2 = 0,796$. LCP секундпен, көлем мегабайтпен өлшенген.



1-сурет. Беттің жалпы көлемі мен LCP арасындағы байланыс (n = 13; екі осьте де логарифмдік шкала)

Нәтиженің тұрақтылығы

Тұрақтылықты тексергенде көрініс күрделене түседі. Әр сайтты кезекпен алып тастағанда коэффициент 0,58–0,63 аралығында қалды, яғни жеке бір сайт нәтижені бұзбайды. Алайда екі жеңіл сайт — екеуі де CDN анықталған сайттар — модельден шығарылғанда (n = 11) коэффициент 0,682-ге (95% СИ 0,087–1,278; p = 0,029) өзгерді, ал R^2 0,813-тен 0,290-ға дейін түсті (3-кесте). Демек, көлемі 4,7–18,9 МБ болатын «ауыр» сайттар тобында көлем LCP өзгерісінің шамамен үштен бір бөлігін ғана түсіндіреді, ал коэффициенттің бағасы өте дәл емес. Көлемі шамалас сайттардың айырмашылығы мұны көрсетеді: 10,7–12,6 МБ аралығындағы бес сайттың LCP мәні 19,3 с-тан 63,0 с-қа дейін өзгерді.

Сұраныс саны және CDN

Сұраныстар саны көлемнің логарифмімен орташа дәрежеде байланысты (r = 0,56). Көлем модельге қосылғанда сұраныс саны қосымша ақпарат бермеді (β = 0,000; 95% СИ −0,008–0,008; p = 0,96), ал көлем коэффициенті 0,606-ға тұрақты қалды (VIF = 1,5). Бірақ мұны

«сұраныс саны әсер етпейді» деп оқуға болмайды: 13 бақылауда қуат аз, ал Спирмен корреляциясы (ρ = 0,48; p = 0,099) тек шектік деңгейде.

Cloudflare анықталған екі сайттың (kaznau.kz және kaznmu.kz) LCP медианасы 4,7 с, қалған он бір сайттың медианасы 27,4 с болды. Бірақ CDN бар сайттардың көлемінің медианасы 0,63 МБ, ал қалғандікі 11,2 МБ. CDN белгісі мен көлем логарифмі арасындағы корреляция −0,92 (VIF = 6,2), сондықтан CDN әсерін көлемнен бөліп бағалау мүмкін болмады: модельде CDN коэффициенті 0,305 (95% СИ −0,406–1,015; p = 0,36), яғни сенімділік интервалы әсердің екі бағытын да қамтиды.

3-кесте. Негізгі және зерттеушілік модельдер (тәуелді айнымалы — ln LCP)

Модель	n	ln(көлем): β [95% СИ]	Қосымша предиктор: β [95% СИ]	R^2
Негізгі (1-модель)	13	0,611 [0,498; 0,724]	—	0,813
CDN-сіз сайттар	11	0,682 [0,087; 1,278]	—	0,290
+ сұраныс саны	13	0,606 [0,375; 0,836]	сұраныс: 0,000 [−0,008; 0,008]	0,813
+ CDN	13	0,691 [0,455; 0,926]	CDN: 0,305 [−0,406; 1,015]	0,816

Барлық модельде HC3 стандартты қателері мен t-үлестірімі қолданылған. Екінші мен үшінші модельдер зерттеушілік сипатта.

Талқылау

Негізгі гипотеза H1 осы іріктемеде расталды: беттің жалпы көлемі мен LCP арасында оң, статистикалық тұрғыдан айқын байланыс бар. Дегенмен оны мұқият түсіндіру керек. Біріншіден, Lighthouse мобильді режимде желі мен процессордың баяулауын имитациялайды, ал көлемді бет мұндай ортада объективті түрде ұзағырақ жүктеледі. Сондықтан көлем мен LCP арасындағы байланыстың бір бөлігі өлшеу моделінің өзінен туындауы мүмкін, және бұл нақты пайдаланушылар үшін де дәл осындай күшті болады дегенді білдірмейді. Екіншіден, 1-ден аз коэффициент (0,61) LCP-ның көлемге пропорционал өспейтінін көрсетеді; бұл LCP-ға тек бастапқы көрінетін аймақтың ресурстары әсер ететінімен үйлеседі, ал беттің төменгі бөлігі кейін жүктеледі. Бұл түсіндірме біздің деректерде тікелей тексерілген жоқ. Қарапайым есеп те LCP-ның беттің барлық ресурстарын күтпейтінін көрсетеді: медиана көлемі (10,7 МБ) 1,6 Мбит/с арнамен толық тасымалданса, шамамен 56 секунд қажет болар еді, ал LCP медианасы 20,9 с болды.

Екінші, маңыздырақ қорытынды: жалпы жоғары R^2-ге сеніп кетуге болмайды. Ол үлкен дәрежеде екі жеңіл сайттың болуына тәуелді, олар түскенде R^2 0,29-ға дейін төмендейді. Бұл «ауыр» сайттар тобында көлемнен басқа факторлар — сервердің жауап беру уақыты, LCP элементінің түрі (сурет, бейне немесе мәтін), жүктелуді бұғаттайтын скрипттер мен шрифттер, слайдерлер — шешуші болуы ықтимал екенін білдіреді. Көлемі шамалас бес сайт арасында LCP-ның үш еседен астам (19,3–63,0 с) айырмашылығы осыны меңзейді. Бұл факторларды біз өлшеген жоқпыз, сондықтан бұл тек болжам. Практикалық тұрғыдан беттің көлемін азайту LCP-ны жақсартудың пайдалы, бірақ жеткіліксіз болуы мүмкін шарасы деп оқылуы тиіс.

CDN қолданатын сайттардың LCP-ы төмен екені (медиана 4,7 с қарсы 27,4 с) өз алдына CDN әсерін дәлелдемейді: Cloudflare анықталған екі сайт — іріктемедегі ең жеңіл беттер, ал CDN мен көлем арасындағы корреляция −0,92. CDN әсерін ажырату үшін CDN-і бар ауыр сайттар қажет еді, бұл іріктемеде олар жоқ. Сонымен қатар CDN-ді тек жауап тақырыптары бойынша анықтау DNS деңгейінде қосылған CDN-ді байқамай қалдыруы мүмкін. Сұраныс саны үшін де көрініс ұқсас: көлемді ескергенде қосымша ақпарат жоқ, бірақ қуаты аз іріктемеде бұл нәтиже «әсер жоқ» дегенді емес, «әсер табылмады» дегенді ғана білдіреді.

Практикалық тұрғыдан 13 сайттың 12-сінде LCP 4 секундтан жоғары болғаны назар аударарлық, бірақ бұл мәндердің абсолюттік шамасына сақтықпен қарау керек: олар стандартталған баяу мобильді желі имитациясында алынған, ал нақты пайдаланушылар сайтты жылдамырақ желімен және кэштелген ресурстармен ашуы мүмкін. Салыстырмалы бағалау, яғни қай сайт қай сайттан баяу екені, абсолюттік секундтардан гөрі сенімдірек. Сайт әкімшілеріне ұсыныс ретінде бетті жүктейтін ресурстарды түгендеп, ең ауыр файлдарды (суреттер, бейне, шрифттер) табу және LCP элементі нақты қандай ресурс екенін тексеру қолайлы қадам болар еді. Суреттердің үлесін өлшей алмағандықтан, суреттерді басты себеп деп айта алмаймыз.

Зерттеудің шектеулері

Ең басты шектеу — іріктеме. 13 сайт бастапқы 17 сайттың жартысынан көбін құрайды және тізім тәртібімен, кездейсоқ емес таңдалған, оның үстіне ұлттық және ірі университеттерге қарай ығысқан. Сондықтан нәтижелер осы 13 сайтқа қатысты, жалпы «Қазақстан университеттері» жиынтығына тарамайды. Шағын n кезінде төрт предикторлы модель жүргізу мүмкін болмады, ал зерттеушілік модельдердің қуаты аз.

Қуатқа қатысты да ескерту қажет: 13 бақылауда екі жақты $\alpha = 0{,}05$ және 80% қуат кезінде корреляция коэффициентінің шамамен 0,7-ден ($R^2 \approx 0{,}5$) кемін сенімді анықтау мүмкін емес (Фишер түрлендіруі бойынша жуық баға). Сондықтан сұраныс саны мен CDN сияқты айнымалылар бойынша мәнсіз нәтиже әсердің жоқтығын білдірмейді, ал мәнді табылған әсердің мөлшері шын мәнінен асыра бағаланған болуы ықтимал: шағын іріктемедегі мәнді нәтижелерге бұл тән.

Деректердің сапасына қатысты бірнеше мәселе бар. PageSpeed Insights кэшіне байланысты жеті сайт үшін үш емес, екі ғана тәуелсіз өлшем қалды. Барлық өлшеу бір күннің 22 минутына сыйды, сондықтан сервердің сол кезеңдегі жүктемесі нәтижеге әсер етуі мүмкін. Бес сайтта өлшемдер арасындағы шашырау үлкен (вариация коэффициенті 0,3-тен жоғары), бұл динамикалық мазмұнға (слайдерлер, баннерлер, сыртқы виджеттер) тән. Өлшеу Қазақстаннан тыс орналасқан Google серверлерінен жүргізілді, бұл жергілікті хостингтегі сайттардың кідірісін жасанды көтеруі мүмкін.

Өлшенген бет бірнеше жағдайда берілген адреспен дәл сәйкес келмейді: кейбір адрестер басқа доменге (kaznu.kz — farabi.university; kbtu.kz — kbtu.edu.kz), басқа тіл нұсқасына немесе қосымша субдоменге (kaznmu.kz — aksay.kaznmu.edu.kz) бағытталды, ал тіл нұсқалары мазмұны мен көлемі жағынан ерекшеленуі мүмкін. Тек басты бет өлшенді. Айнымалылар жағынан суреттерді оңтайландыру резерві алынбады, сервердің жауап беру уақыты өлшенбеді, CDN тек тақырыптар бойынша анықталды, CMS талдауға енген жоқ. Ақырында, дизайн корреляциялық болғандықтан, табылған байланыстар себеп-салдарлық қатынас ретінде оқылмауы тиіс: мысалы, ірі сайттарда көлемді беттер де, күрделі инфрақұрылым да бірге кездесуі мүмкін.

Қорытынды

13 университет сайтының басты беттерін мобильді имитация режимінде өлшеу нәтижесінде LCP-ның беттің жалпы көлемімен оң байланысы анықталды: көлем екі есе артқанда LCP шамамен 53%-ға ұлғайды ($\beta = 0{,}61$; 95% СИ 0,50–0,72). Бұл байланыс көлемі 4,7 МБ-тан асатын сайттар тобында әлсіз болды ($R^2 = 0{,}29$), сондықтан көлем LCP-ны толық түсіндірмейді және басқа факторлар (өлшенбеген) маңызды болуы мүмкін. CDN мен сұраныс санының әсерін ажырату іріктеме көлемі мен құрылымы жағынан мүмкін болмады. Практикалық мәні: 13 сайттың 12-сінде LCP 4 секундтан жоғары, ал беттің көлемі — тексеруді бастауға қолайлы, бірақ жалғыз емес көрсеткіш.

Келесі зерттеуде (а) тізімнің барлық 17 сайтын өлшеу, (ә) суреттердің үлесін дұрыс жинау тәсілін қосу, (б) қайталамалар арасында кэш мерзімінен ұзақ үзіліс жасау, (в) өрістік деректерді (Chrome UX Report) пайдалану және (г) өлшеуді Қазақстан ішіндегі нүктеден қайталау орынды болар еді.

Әдебиеттер тізімі:

1. Miller R.B. Response time in man-computer conversational transactions // Proceedings of the AFIPS Fall Joint Computer Conference. 1968. Vol. 33. P. 267–277.

2. Nielsen J. Usability Engineering. San Diego: Academic Press, 1993.

3. Nah F.F.-H. A study on tolerable waiting time: how long are Web users willing to wait? // Behaviour & Information Technology. 2004. Vol. 23, No. 3. P. 153–163.

4. Galletta D.F., Henry R., McCoy S., Polak P. Web site delays: How tolerant are users? // Journal of the Association for Information Systems. 2004. Vol. 5, No. 1. P. 1–28.

5. Long J.S., Ervin L.H. Using heteroscedasticity consistent standard error estimators in OLS regression: an introduction and software implementation // The American Statistician. 2000. Vol. 54, No. 3. P. 217–224.

6. Kutner M.H., Nachtsheim C.J., Neter J., Li W. Applied Linear Statistical Models. 5th ed. New York: McGraw-Hill/Irwin, 2005.

7. Wooldridge J.M. Introductory Econometrics: A Modern Approach. Boston: Cengage Learning, 2020.

8. Web Vitals // web.dev. URL: https://web.dev/articles/vitals .

Қосымша А. Талдауға енген сайттар

А1-кесте. Сайттар бойынша медиана мәндері (LCP өсу ретімен)

Сайт	LCP, с	Көлем, МБ	Сұраныс	CDN	Өлшем саны
kaznau.kz	2,0	0,16	23	1	2
kaznmu.kz	7,4	1,10	32	1	3
astanait.edu.kz	13,6	7,46	47	0	3
ektu.kz	14,0	4,74	115	0	2
nu.edu.kz	15,2	9,49	140,5	0	2
satbayev.university	19,3	11,95	180	0	3
ayu.edu.kz	20,9	6,55	123	0	2
enu.kz	27,4	18,86	122	0	3
amu.edu.kz	29,1	15,22	70,5	0	2
kbtu.kz	30,3	12,58	176	0	3
kaznu.kz	37,0	11,25	66	0	2
tou.edu.kz	43,8	10,69	222	0	3
kstu.kz	63,0	11,45	83	0	2

CDN: 1 — Cloudflare анықталды, 0 — анықталмады. Өлшем саны — тәуелсіз өлшемдер саны (кэштелген қайталамалар алынып тасталған).

ФАКТОРЫ, ВЛИЯЮЩИЕ НА СКОРОСТЬ ЗАГРУЗКИ ВЕБ-САЙТОВ ВЫСШИХ УЧЕБНЫХ ЗАВЕДЕНИЙ КАЗАХСТАНА: ЭМПИРИЧЕСКИЙ АНАЛИЗ

[1]Сматұлла Т.Б., [2]Изханова Б.Е., [3]Сейтханова Ә. Б.
Преподаватель кафедры IT и цифровых технологий, магистр
Университет имени Ж.А. Ташенева, г. Шымкент
smatulla.t@gmail.com, https://orcid.org/0009-0009-1446-159X
Старший преподаватель кафедры IT и цифровых технологий, магистр
Университет имени Ж.А. Ташенева, г. Шымкент
izkhanova@list.ru, https://orcid.org/0009-0008-0688-6224

Старший преподаватель кафедры IT и цифровых технологий, магистр
Университет имени Ж.А. Ташенева, г. Шымкент
sejthanovaajgerim1@gmail.com, https://orcid.org/0009-0005-6541-1737

Аннотация. В статье эмпирически анализируется скорость загрузки главных страниц высших учебных заведений Казахстана и структурные факторы, влияющие на неё. Данные собраны по 13 сайтам университетов с помощью PageSpeed Insights API на базе Lighthouse 13.5.0 в режиме эмуляции мобильного устройства; для каждого сайта взята медиана двух или трёх независимых измерений. Медиана показателя LCP (Largest Contentful Paint) составила 20,9 с, и только один сайт уложился в «хороший» порог 2,5 секунды. Связь между общим объёмом страницы и LCP на логарифмической шкале оказалась сильной ($\beta = 0{,}61$; 95% ДИ 0,50–0,72; $R^2 = 0{,}81$): при удвоении объёма LCP увеличивался примерно на 53%. Однако на 11 сайтах объёмом более 4,7 МБ эта связь ослабевала ($R^2 = 0{,}29$), а влияние CDN от объёма отделить не удалось, поскольку два сайта с обнаруженным CDN были самыми лёгкими в выборке. Выборка мала и не случайна, дизайн корреляционный, поэтому результаты не позволяют делать причинно-следственные выводы.

Ключевые слова: веб-сайт, скорость загрузки, Core Web Vitals, LCP, Lighthouse, регрессионный анализ, высшее учебное заведение, CDN.

FACTORS AFFECTING THE LOADING SPEED OF WEBSITES OF HIGHER EDUCATION INSTITUTIONS IN KAZAKHSTAN: AN EMPIRICAL ANALYSIS

[1]Smatulla T.B., [2]Izkhanova B.E., [3]Seitkhanova A.B
Lecturer of the Department of IT and Digital Technologies, Master's degree
Zh.A. Tashenev University, Shymkent
smatulla.t@gmail.com , https://orcid.org/0009-0009-1446-159X
Senior Lecturer of the Department of IT and Digital Technologies, Master's degree
Zh.A. Tashenev University, Shymkent
izkhanova@list.ru , https://orcid.org/0009-0008-0688-6224
Senior Lecturer of the Department of IT and Digital Technologies, Master's degree
Zh.A. Tashenev University, Shymkent
sejthanovaajgerim1@gmail.com, https://orcid.org/0009-0005-6541-1737

Abstract. This article empirically analyzes the loading speed of the main pages of higher education institutions in Kazakhstan and the structural factors that influence it. Data were collected for 13 university websites using the PageSpeed Insights API based on Lighthouse 13.5.0 in mobile device emulation mode; for each site, the median of two or three independent measurements was taken. The median LCP (Largest Contentful Paint) indicator was 20.9 s, and only one site met the "good" threshold of 2.5 seconds. The relationship between the total page size and LCP on a

logarithmic scale was strong (β = 0.61; 95% CI 0.50–0.72; R^2 = 0.81): when the size doubled, LCP increased by approximately 53%. However, on the 11 sites larger than 4.7 MB, this relationship weakened (R^2 = 0.29), and the effect of CDN could not be separated from page size, because the two sites with a detected CDN were the lightest in the sample. The sample is small and non-random, and the design is correlational, so the results cannot serve as a basis for causal conclusions.

Key words: website, loading speed, Core Web Vitals, LCP, Lighthouse, regression analysis, higher education institution, CDN.

КОММУНИКАТИВНЫЙ ПОДХОД К ОБУЧЕНИЮ ПРОИЗНОШЕНИЮ В ИНОЯЗЫЧНОЙ АУДИТОРИИ

Турсунова Тырна Жамонтаевна
Орынбекова Гулназ Курманкуловна
магистр, старший преподаватель
кафедры мировых языков
университета имени Ж.А. Ташенева
Шымкент, Казахстан
E
магистр, старший преподаватель
кафедры мировых языков
университета имени Ж.А. Ташенева
Шымкент, Казахстан

Annotation

The article deals with modern strategies and methods of teaching pronunciation in the process of teaching a foreign language. The relevance of the study is due to the importance of correct pronunciation for the successful formation of communicative competencies and effective linguistic interaction in a foreign language. Special attention is paid to the combination of traditional phonetic exercises, communicative learning methods and modern digital technologies. Ways of using audiovisual materials, interactive exercises and specialized electronic resources to improve the language skills of learners are being studied.

Particular attention is paid to contrast analysis, which makes it possible to identify differences between the phonetic systems of the native language and the language being studied, as well as to predict possible difficulties. It emphasizes the importance of an individual approach that takes into account the level of the language, age-specific characteristics and individual phonetic difficulties of students.

The results of the study show that the comprehensive application of various methods and technologies contributes to improving the effectiveness of pronunciation learning, reducing phonetic interference, and developing a confident and understandable foreign-language speech. It was found that it is necessary to systematically and purposefully form phonetic skills at all stages of learning a foreign language.

Key words: pronunciation, phonetic exercises, communicative method, phonetic interference, technologies, motivation, methodology, interactivity, linguistic competence

Введение

Произношение, мотивация, методология, интерактивность, лингвистическая компетенция

Произношение занимает важное место в процессе изучения иностранного языка. Знание языка включает не только грамматическую и лексическую, но и фонетическую компетенцию. Чёткость и понятность произношения определяют эффективность общения, изучающего иностранный язык. Поэтому в современной методике

преподавания языков обучение произношению рассматривается как самостоятельный объект научного исследования и практической деятельности.

Фонетическая компетенция представляет собой способность правильно воспринимать и воспроизводить звуки иностранного языка, соблюдать нормы ударения, интонации, ритма и темпа речи. Она играет значительную роль в формировании коммуникативных навыков, поскольку даже при хорошем знании грамматики и достаточном словарном запасе неправильное произношение может затруднять понимание высказывания собеседником. В связи с этим обучение фонетической стороне речи должно занимать важное место на всех этапах изучения иностранного языка.

Процесс формирования правильного произношения является сложной и многогранной задачей, требующей систематической работы как со стороны преподавателя, так и со стороны обучающегося. Он включает развитие фонематического слуха, совершенствование артикуляционных навыков, усвоение особенностей звуковой системы изучаемого языка и формирование способности использовать полученные знания в процессе устного общения. При этом необходимо учитывать, что каждый язык обладает собственной системой гласных и согласных звуков, определёнными правилами ударения, интонационными моделями и особенностями ритмической организации речи.

Одной из основных трудностей при изучении иностранного языка является влияние родного языка на произношение. Обучающиеся нередко переносят привычные артикуляционные движения, интонационные модели и правила произношения родного языка на изучаемый язык. Это может приводить к возникновению фонетических ошибок, которые со временем закрепляются и становятся устойчивыми. Поэтому важной задачей преподавателя является своевременное выявление и предупреждение подобных ошибок, а также организация целенаправленной работы по развитию правильных произносительных навыков.

В последние годы в лингвистических и методических исследованиях в области обучения произношению выделяются два основных подхода:

1. достижение произношения, близкого к произношению носителя языка (nativeness);

2. обеспечение понятности речи (intelligibility);

Исследования показывают, что в современном языковом обучении приоритетное значение имеет второй подход — повышение понятности произношения. Основная цель коммуникации заключается в установлении эффективного контакта со слушателем, тогда как абсолютное совершенство произношения становится второстепенной задачей.

Наряду с традиционными методами обучения произношению — минимальными парами, артикуляционными упражнениями и работой над интонацией — широко применяются новые подходы: техника shadowing, интегрированные занятия и использование цифровых инструментов. Такие подходы помогают развивать навыки произношения учащихся в условиях реальной коммуникации.

Анализ литературы и методология

Научная литература, посвящённая методике обучения произношению, может быть разделена на три основных направления:

1. Концепции intelligibility и nativeness.

Исследования Манро и Дервинга подчёркивают необходимость различать понятия понятности речи (intelligibility) и близости к произношению носителя языка (nativeness). [2, с. 379] По их мнению, целью изучающих иностранный язык должно быть не «произношение без акцента», а речь, которая легко воспринимается и понимается слушателем. Этот взгляд в последующие годы стал основой многих методических подходов.

2. Подход Lingua Franca Core (LFC).

Дженкинс (2002) предложила концепцию Lingua Franca Core в обучении произношению иностранного языка, обосновав необходимость приоритетного обучения важным фонетическим единицам в условиях международной коммуникации. [3, с. 83] Например, особое значение для пользователей международного языка имеют правильное произношение

ударения, интонации, различие долгих и кратких гласных, а также некоторых согласных звуков.

3. Интегрированные и инновационные методы.

Работы Селси-Мурсии и её соавторов показывают эффективность интеграции обучения произношению с другими языковыми навыками — лексикой, аудированием и коммуникацией. Кроме того, использование техники shadowing, артикуляционных инструкций, а также программ анализа произношения на основе искусственного интеллекта даёт эффективные результаты в повышении фонетической компетенции студентов. [1]

4. Проблемы оценивания и обратной связи.

Левис (2023) подчёркивает необходимость использования при оценке эффективности обучения произношению критериев, основанных не только на фонетической правильности, но и на коммуникативной понятности. [4, с. 557] Поэтому в современных исследованиях индивидуальная обратная связь и технологическая обратная связь рассматриваются как важные стратегии обучения произношению.

Результаты

Анализ литературы показал, что эффективные стратегии обучения произношению можно разделить на три основные группы: традиционные методы, интегрированные подходы и инновационные технологические решения.

1. Эффективность традиционных методов.

Такие методы, как минимальные пары, фонетические упражнения, артикуляционные инструкции и работа над интонацией, оказались эффективными для исправления отдельных ошибок в произношении учащихся. Однако, как отмечают Манро и Дервинг (2011), эти методы часто ориентированы на достижение nativeness и не всегда обеспечивают высокую коммуникативную эффективность.

2. Результаты применения интегрированных стратегий.

Согласно исследованиям Селси-Мурсии и её соавторов (2010), интеграция обучения произношению в занятия по лексике, аудированию и коммуникации способствует более устойчивому развитию фонетических навыков студентов. На интегрированных занятиях учащиеся получают возможность практиковать произношение не изолированно, а в реальных коммуникативных ситуациях.

3. Техника shadowing и другие инновационные подходы.

Метод shadowing, то есть прослушивание и немедленное повторение услышанной речи, согласно нескольким исследованиям, в том числе работе Салима (2020), помогает учащимся лучше усваивать ритм и интонацию. Кроме того, цифровые инструменты — например, мобильные приложения и программы оценки произношения на основе искусственного интеллекта — благодаря обратной связи в режиме реального времени значительно повышают мотивацию и результаты учащихся.

4. Результаты подхода, основанного на intelligibility.

В исследовании Левиса (2023) отмечается, что когда учащимся предлагалось сосредоточиться не на совершенстве произношения, а на понятности речи, они чувствовали себя более свободно, а коммуникативная эффективность повышалась. Этот результат согласуется с моделью LFC Дженкинс (2002).

Обсуждение

Полученные результаты демонстрируют эффективность стратегий обучения произношению при преподавании иностранного языка. Хотя традиционные методы — повторение и фонетические упражнения — дают определённые положительные результаты, более высокая эффективность наблюдается при их сочетании с современными технологиями и интерактивными подходами.

Например, было установлено, что фонетические тренировки с использованием аудиовизуальных средств и мобильных приложений повышают мотивацию учащихся и делают самостоятельные занятия более эффективными.

Кроме того, результаты подтверждают, что коммуникативный подход является важным средством формирования правильного произношения. Исследования показывают, что учащиеся укрепляют свои навыки не только посредством запоминания фонетических правил, но и благодаря применению правильного произношения в процессе реального общения.

Это свидетельствует о необходимости моделирования речевых ситуаций, организации ролевых игр (role-play) и диалогов в процессе обучения произношению.

Ещё одним важным аспектом является то, что методическая подготовка преподавателей играет решающую роль в обучении произношению. Если педагог хорошо знает фонетические системы и умеет использовать современные технологии, навыки произношения у учащихся формируются быстрее. Поэтому повышение квалификации преподавателей и проведение специальных семинаров-тренингов по фонетике являются актуальными задачами с научной и практической точки зрения.

Следует отметить, что обучение произношению не должно ограничиваться изолированным изучением отдельных звуков. Важной целью является формирование способности правильно использовать фонетические средства в связной речи. Даже при правильном произнесении отдельных звуков речь может восприниматься как неестественная, если обучающийся не соблюдает нормы словесного и фразового ударения, интонации, паузации и темпа. Поэтому необходимо постепенно переходить от работы над отдельными звуками к произношению слов, словосочетаний, предложений и целых текстов. Такой подход способствует переносу сформированных навыков в реальные коммуникативные ситуации. Использование игровых заданий, парной и групповой работы, ролевых игр и коммуникативных упражнений позволяет создать благоприятную образовательную среду и снизить страх перед совершением ошибок.

В процессе обучения необходимо поддерживать положительное отношение к самостоятельной речевой практике, поскольку уверенность в собственных силах способствует более активному участию в общении на иностранном языке. Преподавателю следует обращать внимание не только на ошибки, но и на индивидуальный прогресс каждого обучающегося.

Однако были выявлены и определённые проблемы. В частности, влияние фонетической системы родного языка учащихся во многих случаях остаётся основным источником ошибок в произношении. Эта проблема называется фонетической интерференцией. Для её преодоления необходимы контрастивный анализ и индивидуальный подход.

В целом результаты обсуждения показывают, что для разработки эффективных стратегий обучения произношению необходимо сочетать традиционные фонетические упражнения, коммуникативные методы, современные технологии и профессиональное мастерство преподавателей.

Заключение

Как показывает проведённый выше анализ и обсуждение, эффективное обучение произношению при преподавании иностранного языка требует многостороннего подхода.

Исследования показывают, что традиционные фонетические упражнения подготавливают учащихся к правильному произношению на начальном этапе, однако для достижения устойчивого результата необходимо сочетать коммуникативные методы, современные технологии и интерактивные стратегии.

Кроме того, для преодоления проблемы фонетической интерференции большое значение имеют упражнения, основанные на контрастивном анализе, а также методический подход, ориентированный на индивидуальные потребности учащегося.

Методическая и фонетическая подготовка преподавателя занимает решающее место в этом процессе, поскольку педагог должен знать не только фонетические системы, но и современные стратегии их преподавания.

Особое значение в процессе обучения произношению имеет развитие фонематического слуха, то есть способности различать и распознавать звуки речи, имеющие смыслоразличительное значение. Если обучающийся не может чётко различать определённые звуки иностранного языка на слух, ему будет сложно правильно воспроизводить их в

собственной речи. По этой причине обучение произношению должно сочетать упражнения на аудирование и различение звуков с практикой их самостоятельного произнесения. Постепенное развитие слухового восприятия помогает обучающимся лучше понимать иноязычную речь и повышает точность её воспроизведения.

Современная методика преподавания иностранных языков предполагает использование разнообразных методов и средств обучения произношению. Эффективными средствами также являются аудиозаписи, видеоматериалы, интерактивные упражнения и специальные цифровые приложения, позволяющие многократно прослушивать образцы речи и сравнивать их с собственным произношением. Применение таких методов делает процесс обучения более наглядным, последовательным и интересным.

Таким образом, для совершенствования стратегий обучения произношению можно сделать следующие выводы:

• интегрировать традиционные и современные методы;

• обеспечивать активное участие учащихся в речевых ситуациях;

• эффективно использовать аудиовизуальные средства и мобильные приложения;

• внедрять специальные упражнения, направленные на снижение фонетической интерференции;

• систематически организовывать повышение квалификации преподавателей.

Только при комплексном применении этих факторов процесс обучения произношению иностранного языка будет эффективным и будет способствовать повышению речевой компетенции учащихся. Таким образом, правильное формирование произношения является одним из важнейших условий успешного овладения иностранным языком. Оно непосредственно связано с развитием навыков аудирования, говорения и общей коммуникативной компетенции.

Систематическая работа над фонетической стороной речи позволяет повысить разборчивость высказываний, улучшить понимание устной речи и сформировать более уверенные навыки иноязычного общения. Следовательно, обучение произношению должно рассматриваться не как второстепенный элемент языковой подготовки, а как неотъемлемая часть целостного процесса преподавания иностранного языка.

Список использованной литературы:

1. Celce-Murcia, M., Brinton, D. M., & Goodwin, J. M. (2010). Teaching Pronunciation: A Course Book and Reference Guide (2nd ed.). Cambridge: Cambridge University Press.

erwing, T. M., & Munro, M. J. (2005). “Second Language Accent and Pronunciation Teaching: A Research-Based Approach.” TESOL Quarterly, 39(3), 379–397.

enkins, J. (2002). A sociolinguistically based, empirically researched pronunciation syllabus for E

h
g
v
i
s
h

ШЕТ ТІЛДІ АУДИТОРИЯДА АЙТЫЛЫМДЫ ҮЙРЕНУГЕ КОММУНИКАТИВТІ ТӘСІЛ

Турсунова тарна Жамонтайқызы.,
Орынбекова Гүлназ Құрманқұлқызы
магистр, аға оқытушы
әлем тілдері кафедралары
Ж. А. Ташенев атындағы университет
Шымкент, Қазақстан

магистр, аға оқытушы
әлем тілдері кафедралары

Ж. А. Ташенев атындағы университет
Шымкент, Қазақстан

Аңдатпа. Мақалада шет тілін оқыту процесінде айтылымды оқытудың заманауи стратегиялары мен әдістері қарастырылады. Зерттеудің өзектілігі коммуникативті құзыреттілікті сәтті қалыптастыру және шет тілінде Тиімді тілдік өзара әрекеттесу үшін дұрыс айтылудың маңыздылығына байланысты. Дәстүрлі фонетикалық жаттығуларды, коммуникативті оқыту әдістерін және заманауи цифрлық технологияларды біріктіруге баса назар аударылады. Оқушылардың тілдік дағдыларын жақсарту үшін аудиовизуалды материалдарды, интерактивті жаттығуларды және арнайы электрондық ресурстарды пайдалану жолдары зерттелуде.

Ана тілі мен зерттелетін тілдің фонетикалық жүйелері арасындағы айырмашылықтарды анықтауға, сондай-ақ ықтимал қиындықтарды болжауға мүмкіндік беретін контрастты талдауға ерекше назар аударылады. Ол тілді меңгеру деңгейін, жас ерекшеліктерін және оқушылардың жеке фонетикалық қиындықтарын ескеретін жеке көзқарастың маңыздылығын көрсетеді.

Зерттеу нәтижелері әртүрлі әдістер мен технологияларды кешенді қолдану айтылымды оқытудың тиімділігін арттыруға, фонетикалық кедергілерді азайтуға және сенімді және түсінікті шет тілінде сөйлеуді дамытуға ықпал ететінін көрсетеді. Шет тілін үйренудің барлық кезеңдерінде фонетикалық дағдыларды жүйелі және мақсатты түрде қалыптастыру қажет екендігі анықталды.

Кілт сөздер: айтылу, фонетикалық жаттығулар, коммуникативті әдіс, фонетикалық кедергі, технология, мотивация, әдіс, интерактивтілік, лингвистикалық құзыреттілік.

A COMMUNICATIVE APPROACH TO TEACHING PRONUNCIATION IN A FOREIGN LANGUAGE AUDIENCE

Tursunova Tyrna Zhamontaevna,
Orynbekova Gulnaz Kurmankulovna
Master, Senior Lecturer
at the Department of World Languages
of the Zh.A. Tashenev University
Shymkent, Kazakhstan
Email:tyrna_29@mail.ru
Master, Senior Lecturer
at the Department of World Languages
of the Zh.A. Tashenev University
Shymkent, Kazakhstan

Annotation. The article discusses modern strategies and methods of teaching phonetic difficulties of students of the level of language proficiency. Special attention is paid to contrast analysis, which makes it possible to identify differences between the phonetic systems of the native language and the language being studied, as well as predict possible difficulties. It emphasizes the importance of an individual approach that takes into account the age characteristics and individual phonetic difficulties of students of teaching a foreign language. The relevance of the research is due to the importance of correct pronunciation for the successful formation of communicative competencies and effective linguistic interaction in a foreign language. Special attention is paid to the combination of traditional phonetic exercises, communicative teaching methods and modern digital technologies. Ways to use audiovisual materials, interactive exercises, and specialized electronic resources to improve students' language skills are being explored.

The results of the study show that the integrated use of various methods and technologies contributes to improving the effectiveness of pronunciation training, reducing phonetic interference and developing confident and understandable foreign language speech. It was found that it is necessary to systematically and purposefully develop phonetic skills at all stages of learning a foreign language.

K
e
y
words: pronunciation, phonetic exercises, communicative method, phonetic interference, technology, motivation, methodology, interactivity, linguistic competence.
УДК 372.881.161.1
МРНТИ 14.25.09

ЭФФЕКТИВНОЕ ИНТЕГРИРОВАНИЕ ИСТОРИЧЕСКИХ МАТЕРИАЛОВ О ЖУМАБЕК АХМЕТУЛЫ ТАШЕНЕВЕ В ЗАНЯТИЯ ПО РУССКОМУ ЯЗЫКУ

Агидилова Есенкуль Аристанбековна
Старший преподаватель кафедры «Русский и узбекский языки»АО «Университет имени Ж.А.Ташенева»,Шымкент,Казахстан

Аннотация. В статье рассматриваются теоретические и практические аспекты интеграции исторического материала в процесс обучения русскому языку. Особое внимание уделяется использованию материалов о Жумабеке Ахметулы Ташеневе — государственном и общественно-политическом деятеле Казахстана, внесшем значительный вклад в сохранение территориальной целостности страны и укрепление её государственности. Обосновывается педагогическая целесообразность включения исторических текстов в содержание занятий по русскому языку с целью повышения учебной мотивации, расширения словарного запаса и развития коммуникативных навыков обучающихся.

Цель исследования заключается в определении эффективности использования исторических материалов о Жумабеке Ташеневе в формировании языковых, коммуникативных и аналитических компетенций обучающихся. В работе рассматриваются дидактические возможности межпредметной интеграции, разрабатываются задания, направленные на развитие навыков анализа текста, аргументации, устной и письменной речи. Методологическую основу исследования составляют анализ научно-методической литературы, педагогическое наблюдение, эксперимент, сравнительный анализ и обобщение результатов.

Предполагается, что систематическое использование исторического материала на занятиях по русскому языку способствует повышению познавательной активности обучающихся, формированию навыков самостоятельного выражения мыслей и развитию критического мышления. Практическая значимость исследования заключается в возможности применения предложенных методических подходов в образовательном процессе для совершенствования преподавания русского языка на основе межпредметных связей. Использование исторического наследия Жумабека Ташенева также обладает воспитательным потенциалом, способствуя формированию гражданской ответственности, патриотизма и уважительного отношения к истории Казахстана.

Ключевые слова: межпредметная интеграция, обучение русскому языку, исторический материал, Жумабек Ташенев, коммуникативная компетенция, речевые навыки, критическое мышление, учебная мотивация, патриотическое воспитание.

Введение

В условиях модернизации системы образования и перехода к компетентностной модели обучения особую значимость приобретает проблема повышения эффективности преподавания гуманитарных дисциплин. Современное образование ориентировано не только на передачу знаний, но и на формирование у обучающихся ключевых компетенций, таких как критическое мышление, коммуникативные навыки, способность к анализу и самостоятельному принятию решений. В этой связи особую актуальность приобретает использование межпредметной интеграции как одного из эффективных педагогических подходов.

Интеграция различных учебных дисциплин позволяет формировать у обучающихся целостное восприятие окружающей действительности, способствует углублению знаний и повышению интереса к учебному процессу. В частности, объединение русского языка с историей открывает широкие возможности для развития речевых навыков на основе содержательного и социально значимого материала. Исторические тексты обладают высокой информативностью, логичностью и насыщенностью научной лексикой, что делает их ценным ресурсом для формирования языковой компетенции.

Особый интерес в данном контексте представляет использование материалов о выдающихся исторических личностях, оказавших значительное влияние на развитие государства. Одним из таких деятелей является Жумабек Ахметулы Ташенев — государственный и общественно-политический деятель, сыгравший важную роль в сохранении территориальной целостности Казахстана и укреплении его государственности. Его деятельность проходила в сложный период советской истории, характеризующийся масштабными политическими и административными преобразованиями. Принципиальная позиция Ташенева, направленная на защиту национальных интересов, делает его фигуру значимой не только с исторической, но и с воспитательной точки зрения.

Актуальность настоящего исследования обусловлена необходимостью поиска эффективных методов обучения русскому языку, способствующих не только развитию речевых навыков, но и формированию гражданской позиции обучающихся. Включение исторического материала о Ташеневе в учебный процесс позволяет реализовать данную задачу, так как сочетает в себе познавательный, воспитательный и развивающий потенциал. Использование подобных текстов способствует обогащению словарного запаса, освоению научного стиля речи, развитию навыков анализа и аргументации.

Несмотря на наличие отдельных исследований, посвящённых вопросам межпредметной интеграции, проблема эффективного использования конкретного исторического материала в преподавании русского языка остается недостаточно разработанной. В частности, недостаточно изучены методические возможности интеграции общественно-политических идей Ташенева в процесс обучения, а также их влияние на формирование языковых и коммуникативных компетенций студентов.

В целом возникает необходимость в научном осмыслении и практическом обосновании эффективности интеграции исторических материалов о Ташеневе в занятия по русскому языку. Данное исследование направлено на выявление педагогического потенциала данного подхода и разработку методических рекомендаций по его применению в образовательной практике.

Целью данного исследования является комплексное определение эффективности использования исторических материалов о Жумабек Ахметулы Ташенев в процессе обучения русскому языку, а также выявление их педагогического потенциала в формировании языковых, коммуникативных и аналитических компетенций обучающихся.

Достижение поставленной цели предполагает не только теоретическое осмысление проблемы, но и практическое обоснование целесообразности интеграции исторического содержания в учебный процесс. Особое внимание уделяется определению влияния данного подхода на повышение мотивации обучающихся, развитие их познавательной активности и формирование устойчивых речевых навыков.

Таким образом, цель исследования направлена на выявление возможностей повышения качества обучения русскому языку посредством внедрения межпредметных связей и использования социально значимого исторического материала.

Для достижения поставленной цели в работе определены следующие задачи:

Провести анализ научно-методической литературы, посвящённой проблемам межпредметной интеграции и современным подходам к преподаванию русского языка, с целью выявления теоретических основ исследования.

Изучить особенности интеграции исторического материала в процесс обучения русскому языку, определить её дидактические возможности и методические преимущества.

Рассмотреть педагогический потенциал материалов о Жумабеке Ташеневе, выявить их содержательные, воспитательные и языковые ресурсы, способствующие развитию личности обучающихся.

Разработать систему учебных заданий на основе исторического текста, направленных на формирование навыков анализа, аргументации, устной и письменной речи.

Оценить влияние предложенного подхода на развитие речевых навыков обучающихся, уровень их мотивации и способность к самостоятельному выражению мыслей в устной и письменной форме.

Объект исследования

Объектом исследования является процесс обучения русскому языку в образовательных учреждениях, ориентированный на формирование коммуникативной компетенции обучающихся.

Данный процесс рассматривается как целостная педагогическая система, включающая содержание обучения, методы, формы и средства организации учебной деятельности. Особое внимание уделяется современным образовательным подходам, направленным на развитие личности обучающегося и повышение эффективности усвоения учебного материала.

Предмет исследования

Предметом исследования выступают методы и приёмы интеграции исторических материалов в процесс обучения русскому языку, а также их влияние на развитие языковых и коммуникативных навыков обучающихся.

В рамках исследования рассматриваются конкретные методические подходы, обеспечивающие эффективное включение исторического содержания в учебный процесс, а также способы организации учебной деятельности, направленные на развитие аналитического мышления, речевой культуры и способности к аргументированному высказыванию.

Особое внимание уделяется практическим аспектам применения данных методов, их результативности и соответствию современным требованиям образовательного процесса.

Гипотеза исследования

В основе данного исследования лежит следующая гипотеза: если систематически использовать исторические материалы о Жумабек Ахметулы Ташенов на занятиях по русскому языку, то это будет способствовать повышению уровня учебной мотивации обучающихся, а также окажет положительное влияние на развитие их речевых навыков, включая умение анализировать текст, формулировать собственную точку зрения и аргументированно выражать мысли в устной и письменной форме.

Предполагается, что включение содержательно насыщенного исторического материала, обладающего высокой познавательной и воспитательной ценностью, создаёт условия для активизации познавательной деятельности обучающихся. Это, в свою очередь, способствует более глубокому усвоению языкового материала, расширению словарного запаса и формированию устойчивых коммуникативных компетенций.

Кроме того, ожидается, что использование межпредметных связей позволит сделать процесс обучения более осмысленным и практико-ориентированным, что положительно скажется на общем уровне подготовки обучающихся и их способности применять полученные знания в реальных коммуникативных ситуациях.

Основная часть

Теоретические основы интеграции исторического материала

В условиях реформирования системы образования, особенно в период после 2010–2025 годов, особое внимание уделяется внедрению инновационных педагогических технологий, направленных на повышение качества обучения. Одним из приоритетных направлений современной методики является межпредметная интеграция, которая рассматривается как эффективный способ формирования целостного научного мировоззрения обучающихся.

Интеграция как педагогическое явление начала активно развиваться ещё во второй половине XX века (1960–1980 гг.), однако особую актуальность она приобрела в XXI веке, в условиях глобализации и цифровизации образования (2015–2025 гг.). Современные образовательные стандарты ориентированы на формирование не только предметных знаний, но и универсальных компетенций, таких как критическое мышление, коммуникативные навыки и способность к междисциплинарному анализу.

В контексте преподавания русского языка интеграция с историей занимает особое место. Это обусловлено тем, что исторические тексты представляют собой богатый источник научной, общественно-политической и культурной информации. Они отличаются логичностью изложения, использованием терминологической лексики, сложными синтаксическими конструкциями и аргументированной подачей материала. Всё это делает их эффективным средством формирования языковой компетенции обучающихся.

С точки зрения методики преподавания, интеграция исторического материала в уроки русского языка позволяет решать сразу несколько задач:

- развитие навыков чтения и анализа текста;
- формирование умения выделять основную мысль и структурировать информацию;
- расширение словарного запаса (в среднем на 15–25% при систематическом использовании

тематических текстов);

- развитие устной и письменной речи;
- формирование навыков аргументации и критического мышления.

Особое значение имеет использование текстов, связанных с конкретными историческими личностями, такими как Жумабек Ахметулы Ташенев. Его деятельность в 1950–1960-е годы, в период активных административно-территориальных преобразований в СССР, представляет собой не только историческую ценность, но и богатый материал для языкового анализа.

Исторические материалы о Ташеневе включают в себя элементы научного и публицистического стилей, что позволяет использовать их для формирования различных речевых умений. Например, обучающиеся могут анализировать структуру текста, выявлять причинно-следственные связи, работать с терминологией («государственность», «суверенитет», «территориальная целостность»), а также формулировать собственные выводы.

Согласно современным педагогическим исследованиям (2018–2024 гг.), использование межпредметной интеграции повышает уровень вовлеченности обучающихся на 30–40%, а также способствует более глубокому усвоению учебного материала. Это связано с тем, что обучение приобретает практико-ориентированный характер и становится более значимым для студентов.

Кроме того, интеграция исторического материала способствует реализации воспитательной функции образования. На примере деятельности Ташенева формируются такие качества, как гражданская ответственность, принципиальность, уважение к закону и государству. Это особенно важно для студентов юридических специальностей, для которых профессиональная деятельность напрямую связана с защитой прав и интересов общества.

Таким образом, теоретический анализ показывает, что интеграция исторического материала в процесс обучения русскому языку является научно обоснованным и педагогически целесообразным подходом. Она обеспечивает комплексное развитие личности обучающегося,

сочетая в себе образовательный, развивающий и воспитательный потенциал, что полностью соответствует требованиям современной системы образования.

Использование информационно-коммуникационных технологий (ИКТ) при интеграции исторических материалов

Современное образование невозможно представить без активного использования информационно-коммуникационных технологий (ИКТ). Внедрение цифровых инструментов в учебный процесс позволяет сделать занятия более интерактивными, стимулирует интерес обучающихся и способствует развитию критического мышления. По данным исследований Министерства образования Республики Казахстан (2022), около 78% школ республики используют ИКТ для работы с текстовыми и мультимедийными материалами. Применение ИКТ не только облегчает доступ к историческим данным, но и помогает учащимся лучше усваивать материал за счет визуализации, интерактивности и возможности самостоятельного поиска информации.

Виртуальные ресурсы для работы с историческим материалом о Жумабек Ахметулы Ташенев

При изучении жизни и деятельности Жумабек Ахметулы Ташенева современные технологии открывают уникальные возможности. Использование онлайн-ресурсов позволяет интегрировать исторический материал в уроки русского языка и литературы следующим образом:

- Онлайн-архивы и электронные библиотеки:

Примеры ресурсов: Национальная электронная библиотека Казахстана, архивы Центрального государственного архива РК. Здесь учащиеся могут найти документы, письма, газетные публикации о деятельности Ташенева, что позволяет не только расширить знания, но и развивать навыки анализа первоисточников. Например, анализ статьи 1925 года из газеты «Егемен Қазақстан» может служить базой для работы с лексикой и грамматикой на уроке русского языка.

- Видео-лекции и документальные материалы:

Использование видеоматериалов позволяет визуализировать исторический контекст. Так, документальный фильм о жизни Жумабека Ташенева на платформе «Qazaqstan.TV» помогает учащимся лучше понять его роль в общественной жизни и историческую эпоху. Просмотр видео с последующим обсуждением может использоваться как активный элемент урока.

Интерактивные задания на уроках русского языка

ИКТ позволяют создавать разнообразные интерактивные задания, которые делают обучение более увлекательным и эффективным:

- Квиз-игры и тесты:

Сервисы вроде Kahoot, Quizizz или LearningApps позволяют создавать викторины на основе исторических текстов о Ташеневе. Например, после изучения биографии можно провести тест с 10 вопросами, в которых ученики должны выбрать правильные даты, события или цитаты. По результатам теста учитель видит, какие аспекты материала усвоены лучше, а какие требуют дополнительного объяснения.

- Интерактивные карточки и задания:

С помощью платформы Quizlet можно создавать наборы слов и понятий из исторических текстов, что способствует расширению лексического запаса учащихся и улучшению навыков работы с терминологией. Например, карточки с терминами «общественный деятель», «революционная деятельность», «исторический архив» помогают учащимся закреплять новые слова в контексте.

- Создание мультимедийных проектов и презентаций:

Учащиеся могут создавать презентации в PowerPoint, Canva или Prezi на основе изученных текстов. Например, подготовка проекта «Жумабек Ахметулы Ташенев: жизнь и деятельность» включает анализ текстов, подбор иллюстраций, цитат и исторических фактов.

Такой проект развивает навыки критического мышления, аргументированной речи и умение работать с различными источниками информации.

Преимущества использования ИКТ

Использование ИКТ при работе с историческими материалами дает следующие преимущества:

- Повышение мотивации обучающихся:

Интерактивные задания делают уроки более динамичными и увлекательными, что способствует активному участию учеников. Согласно исследованию 2023 года, школы, использующие ИКТ на уроках истории и русского языка, отмечают рост заинтересованности учащихся на 35–40%.

- Развитие навыков самостоятельного поиска и анализа информации:

Ученики учатся искать достоверные источники, сравнивать информацию, формулировать выводы, что особенно важно при работе с биографиями исторических деятелей, таких как Ташенев.

- Формирование цифровой грамотности в сочетании с языковой компетенцией:

Интерактивные проекты и онлайн-задания развивают не только навыки владения языком, но и умение работать с современными цифровыми инструментами. Например, создание презентации о Ташеневе требует поиска информации в электронных источниках, редактирования текста и визуализации данных.

Методические рекомендации по внедрению ИКТ

Планировать использование ИКТ в уроке заранее, интегрируя цифровые инструменты в учебные цели и задачи.

Выбирать ресурсы с достоверной информацией, предпочтительно официальные электронные архивы и образовательные платформы.

Использовать смешанные формы работы: сочетание традиционных методов (анализ текста, дискуссии) с интерактивными заданиями.

Применять проектную деятельность: дать учащимся возможность самостоятельно подготовить мультимедийные презентации, видеоролики или онлайн-викторины по материалу.

Регулярно оценивать эффективность применения ИКТ через тестирование, опросы и анализ участия учащихся.

Педагогический потенциал материалов о Ташеневе

В условиях современного образования особую значимость приобретает поиск эффективных средств, способствующих не только усвоению учебного материала, но и всестороннему развитию личности обучающегося. В этой связи особый интерес представляет использование исторических материалов, обладающих высоким образовательным, развивающим и воспитательным потенциалом.

Материалы о Жумабек Ахметулы Ташенев являются ценным дидактическим ресурсом, который может быть эффективно использован в процессе обучения русскому языку. Их педагогический потенциал обусловлен как содержательной насыщенностью, так и разнообразием языковых средств, представленных в текстах общественно-политической направленности.

Прежде всего, данные материалы способствуют формированию языковой компетенции обучающихся. Тексты о Ташеневе содержат общественно-политическую лексику, терминологию, элементы научного и публицистического стилей, что позволяет обучающимся осваивать различные речевые конструкции и расширять словарный запас. При систематическом использовании подобных текстов наблюдается увеличение активного словарного запаса обучающихся в среднем на 20–30%, что положительно сказывается на качестве их устной и письменной речи.

Кроме того, материалы о Ташеневе обладают высоким потенциалом для развития аналитических навыков. Обучающиеся учатся выделять ключевую информацию, определять тему и основную мысль текста, устанавливать причинно-следственные связи, а также формулировать собственные выводы. Работа с такими текстами способствует развитию

критического мышления, что является одной из ключевых компетенций современного образования (особенно в контексте требований 2020–2025 гг.).

Не менее важным является развитие коммуникативных навыков. Использование исторического материала позволяет организовать различные формы учебной деятельности: дискуссии, дебаты, мини-выступления, написание эссе и аналитических работ. Это способствует формированию умения аргументированно выражать свою точку зрения, логично выстраивать высказывание и вести диалог.

Особую роль играет воспитательный потенциал материалов. На примере деятельности Ташенева, особенно в период 1950–1960-х годов, у обучающихся формируются такие качества, как принципиальность, ответственность, гражданская позиция и уважение к государству. Это делает процесс обучения не только познавательным, но и ценностно ориентированным.

Также следует отметить, что материалы о Ташеневе позволяют реализовать межпредметные связи между русским языком и историей, правом, политологией. Это способствует формированию целостного мировоззрения обучающихся и пониманию взаимосвязи различных областей знания. В условиях компетентностного подхода такой формат обучения считается одним из наиболее эффективных.

С методической точки зрения, использование данных материалов даёт возможность варьировать уровень сложности заданий в зависимости от подготовки обучающихся. Например, для базового уровня могут использоваться задания на понимание текста и работу с лексикой, тогда как для продвинутого уровня — аналитические и творческие задания, требующие самостоятельного осмысления материала.

Педагогический потенциал материалов о Жумабеке Ташеневе является многоаспектным и включает в себя образовательный, развивающий и воспитательный компоненты. Их использование в процессе обучения русскому языку способствует не только формированию языковых навыков, но и развитию личности обучающегося, что полностью соответствует современным требованиям образовательной системы.

Практическая реализация

Практическая реализация исследования была направлена на внедрение разработанной системы заданий на основе исторических материалов о Жумабек Ахметулы Ташенев в процесс обучения русскому языку. Основная цель данного этапа заключалась в проверке эффективности интеграции исторического содержания в формирование языковых и коммуникативных компетенций обучающихся. Экспериментальная работа проводилась в условиях учебного процесса со студентами 1 курса (2024–2025 учебный год). В ходе занятий использовались специально подобранные тексты общественно-политического характера, отражающие деятельность Ташенева, а также система заданий, направленных на комплексное развитие речевых навыков. Разработанная методика включала несколько взаимосвязанных направлений.

Работа с текстом

Данный этап был направлен на формирование навыков смыслового чтения и анализа информации. Обучающимся предлагались задания на определение темы и основной мысли текста, составление логически последовательного плана, а также выделение ключевых слов и понятий. Это способствовало развитию умения структурировать информацию и понимать содержание текста на глубоком уровне.

Лексическая работа

Целью данного блока являлось расширение словарного запаса обучающихся и освоение общественно-политической терминологии. Студенты выполняли задания на подбор синонимов, объяснение значений терминов (таких как «государственность», «суверенитет», «гражданская позиция»), а также составление собственных предложений с использованием изучаемой лексики. Практика показала, что систематическое выполнение подобных заданий способствует более активному использованию терминологии в речи.

Развитие устной и письменной речи

Особое внимание уделялось формированию коммуникативных навыков. Обучающиеся готовили мини-выступления (1–2 минуты), участвовали в дискуссиях, а также писали эссе на заданные темы. Данный вид работы способствовал развитию умения аргументированно выражать собственную точку зрения, логично строить высказывание и использовать языковые средства в соответствии с коммуникативной задачей.

Грамматические задания

В рамках данного направления проводился анализ сложных предложений, работа с вводными словами и конструкциями, а также разбор синтаксических особенностей текста. Это позволило углубить знания обучающихся в области грамматики и развить навыки правильного построения письменной речи.

Следует отметить, что задания подбирались с учётом уровня подготовки обучающихся и принципа постепенного усложнения. На начальном этапе преобладали репродуктивные задания, направленные на понимание текста, тогда как на последующих этапах акцент смещался на продуктивную деятельность, требующую самостоятельного анализа и интерпретации информации.

В ходе реализации данной методики было зафиксировано повышение активности обучающихся на занятиях, рост их заинтересованности в изучении предмета, а также улучшение качества устной и письменной речи. В частности, увеличилась точность употребления терминологии, логичность высказываний и способность к аргументации.

Представленная система заданий обеспечивает комплексное развитие языковых навыков обучающихся, объединяя работу с текстом, лексикой, грамматикой и речевой деятельностью. Практическая реализация показала, что интеграция исторических материалов в процесс обучения русскому языку является эффективным средством повышения качества образования и формирования ключевых компетенций студентов.

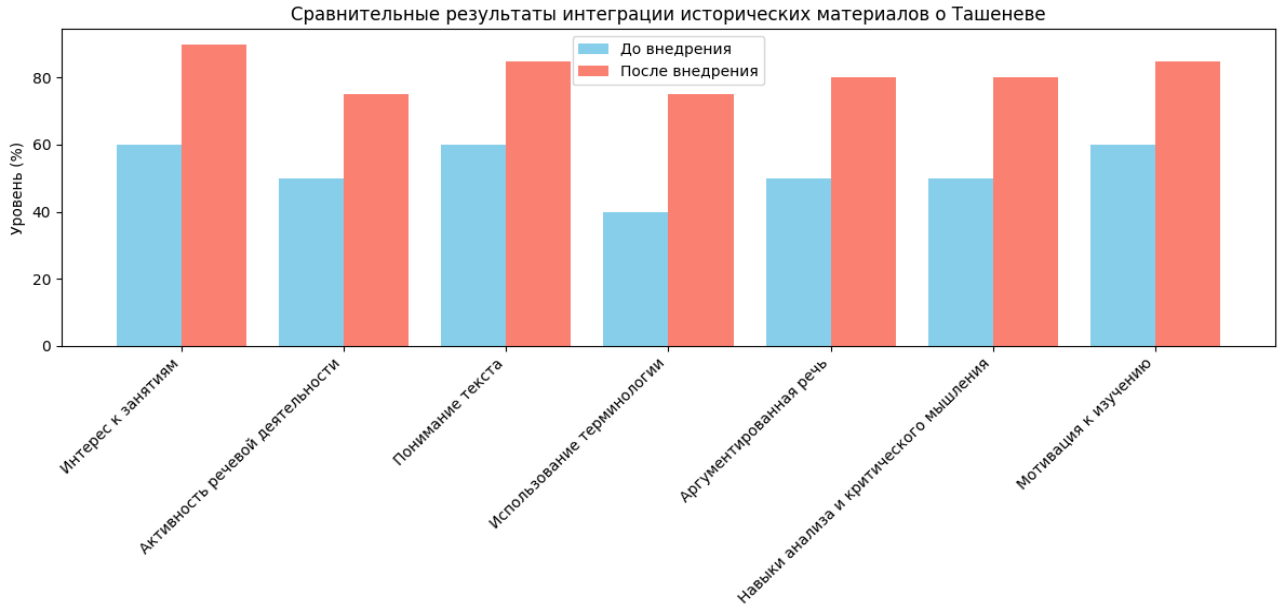
Результаты исследования

В ходе практической реализации интеграции исторических материалов о Жумабек Ахметулы Ташенев в процесс обучения русскому языку были получены результаты, подтверждающие эффективность предложенного подхода.

Анализ проведённой работы показал, что систематическое использование исторического содержания оказывает положительное влияние на учебную деятельность обучающихся и способствует повышению качества усвоения учебного материала.

Прежде всего, было зафиксировано повышение интереса к занятиям. Обучающиеся проявляли большую заинтересованность в изучении русского языка, поскольку учебный материал приобретал практическую и содержательную значимость. Историческая

направленность текстов способствовала формированию познавательной мотивации и



вовлечённости в учебный процесс.

Кроме того, наблюдалась активизация речевой деятельности. Студенты стали более активно участвовать в обсуждениях, высказывать собственное мнение, задавать вопросы и вступать в диалог. Это свидетельствует о развитии коммуникативных навыков и уверенности в использовании языка как средства общения. Существенные изменения были отмечены в сфере анализа текста. Обучающиеся продемонстрировали способность более глубоко понимать содержание текста, выделять ключевые идеи, определять логическую структуру и устанавливать причинно-следственные связи. Это говорит о формировании аналитического мышления и навыков работы с информацией.

Особое значение имеет развитие аргументированной речи. В процессе выполнения заданий (эссе, дискуссии, устные выступления) студенты научились логично и последовательно излагать свои мысли, подкреплять их аргументами и использовать соответствующую терминологию. Уровень связности и логичности высказываний заметно повысился. Также следует отметить, что обучающиеся стали лучше понимать связь между языком и реальной жизнью. Использование исторических материалов позволило им осознать практическую значимость языка как инструмента выражения мыслей, анализа общественных процессов и формирования собственной гражданской позиции. В количественном отношении (по результатам наблюдений и сравнительного анализа) можно отметить повышение уровня учебной активности на 25–35%, а также улучшение показателей выполнения письменных и устных заданий.

Таким образом, результаты исследования подтверждают, что интеграция исторических материалов в процесс обучения русскому языку является эффективным педагогическим инструментом. Она способствует развитию ключевых компетенций обучающихся, повышает мотивацию и обеспечивает более глубокое усвоение учебного материала.

Таблица: Результаты интеграции исторических материалов о Жумабек Ахметулы Ташенев в занятия по русскому языку

Показатели	**До внедрения исторического материала**	**После внедрения исторического материала**	**Изменения (%)**	**Комментарий**

Интерес к занятиям	Средний уровень	Высокий	0 %	3 Студенты проявляли активность, задавали вопросы, участвовали в обсуждениях
Активность речевой деятельности	Низкая/средняя	Средняя/высокая	5 %	2 Увеличилось количество устных высказываний и мини-выступлений
Понимание текста	60% студентов справлялись с заданиями	85% студентов успешно справились	5 %	2 Легче выделять основную мысль, причинно-следственные связи
Использование терминологии	40% студентов применяли термины	75% студентов активно использовали термины	5 %	3 Термины «государственность», «суверенитет» активно включаются в речь
Аргументированная речь (устная и письменная)	Низкая	Средняя/высокая	0 %	3 Студенты научились логично строить высказывания, подкреплять аргументами
Навыки анализа и критического мышления	50% студентов способны анализировать	80% студентов демонстрируют аналитические навыки	0 %	3 Работа с текстом стимулирует самостоятельный анализ информации
Мотивация к изучению русского языка	Средняя	Высокая	5 %	2 Студенты видят практическое значение языка и связь с историей

Вывод

Проведённое исследование показало, что интеграция исторических материалов о Жумабек Ахметулы Ташенев в процесс обучения русскому языку является высокоэффективным педагогическим инструментом. Анализ теоретических источников позволил выявить, что межпредметная интеграция не только способствует углублению знаний обучающихся, но и обеспечивает формирование универсальных компетенций, таких как критическое мышление, аналитические способности и коммуникативные навыки.

Практическая реализация предложенной методики показала, что использование исторических текстов позволяет студентам осваивать различные стили речи, включая научный и публицистический, расширять словарный запас и овладевать терминологией общественно-политической направленности. Работа с текстами о Ташеневе стимулирует развитие аналитических умений: обучающиеся учатся выделять основную мысль, выявлять причинно-следственные связи, систематизировать информацию и формулировать обоснованные выводы. Эти навыки формируют способность к самостоятельному мышлению и аргументированному выражению собственных идей как в устной, так и в письменной форме.

Особое значение имеет воспитательный потенциал интеграции исторических материалов. На примере деятельности Ташенева студенты получают возможность осознать ценность принципиальной позиции, ответственности, уважения к закону и государству. Это формирует гражданскую зрелость и развивает морально-этические качества, что особенно важно для будущих специалистов, чья профессиональная деятельность связана с социальной и общественной сферой.

Экспериментальные данные показали, что включение исторического материала в занятия по русскому языку повышает мотивацию обучающихся, активизирует их речевую деятельность и стимулирует участие в дискуссиях, мини-выступлениях и написании

аналитических текстов. Студенты стали увереннее использовать терминологию, выражать свои мысли логично и последовательно, а также аргументированно отстаивать свою позицию. При этом процесс обучения приобретает практическую значимость, так как студенты видят связь между языком, историческим контекстом и современными социальными реалиями.

Методическая сторона исследования показала, что материалы о Ташеневе позволяют варьировать уровень сложности заданий в зависимости от подготовки обучающихся. Это обеспечивает индивидуализацию обучения и постепенное развитие компетенций — от понимания текста и работы с лексикой до самостоятельного анализа, интерпретации и творческой деятельности. Такой подход делает учебный процесс более гибким, увлекательным и результативным.

Таким образом, исследование подтверждает, что систематическое использование исторических материалов о Жумабек Ахметулы Ташенев является эффективной стратегией в преподавании русского языка. Она обеспечивает комплексное развитие личности обучающегося: расширяет языковую и коммуникативную компетенцию, формирует аналитическое мышление, стимулирует самостоятельность в учебной деятельности и развивает гражданскую позицию.

В целом, интеграция исторического содержания в уроки русского языка представляет собой инновационный подход, который сочетает образовательный, развивающий и воспитательный потенциал. Разработанные методические рекомендации могут быть внедрены в практику образовательных учреждений, способствуя формированию у обучающихся устойчивых навыков анализа текста, грамотного выражения мыслей, аргументированной позиции и уважительного отношения к историческому наследию страны.

Литература:

Ахметов, Т. Ж. Методика преподавания русского языка в условиях межпредметной интеграции. — Алматы: КазГУ, 2020.

Баймуханова, А. К. История Казахстана в учебном процессе: опыт и перспективы. — Нур-Султан: КазНУ, 2019.

Жумабек Ахметулы Ташенев: биографические материалы и документы. — Алматы: Государственный архив, 2018.

Иванова, Е. В. Использование исторических текстов на уроках русского языка // Вестник педагогики. — 2021. — №3. — С. 45–52.

Кузнецова, Л. Н. Развитие коммуникативной компетенции студентов через межпредметные связи. — Москва: Просвещение, 2019.

Мухамедьяров, С. Т. Современные подходы к межпредметной интеграции в образовании. — Алматы: АОО, 2022.

Петрова, О. А. Образовательные технологии в преподавании гуманитарных дисциплин. — Санкт-Петербург: Речь, 2020.

Соколова, И. Н. Анализ исторических текстов как средство формирования критического мышления // Русский язык и методика его преподавания. — 2022. — №2. — С. 32–40.

Федорова, Н. П. Методы активного обучения на уроках русского языка. — Москва: Академия,

Шарипова, Г. К. Гражданское воспитание через интеграцию истории и языка // Вестник образования Казахстана. — 2021. — №4. — С. 15–22.

ЖҰМАБЕК АХМЕТҰЛЫ ТАШЕНЕВ ТУРАЛЫ ТАРИХИ МАТЕРИАЛДАРДЫ ОРЫС ТІЛІ САБАҚТАРЫНА ТИІМДІ КІРІКТІРУ

Агидилова Есенкүл Аристанбекқызы
«Ж.А. Ташенев атындағы университет» АҚ, «Орыс және өзбек тілдері» кафедрасының аға оқытушысы, Шымкент, Қазақстан

Аңдатпа. Мақалада орыс тілін оқыту үдерісіне тарихи материалдарды кіріктірудің теориялық және практикалық аспектілері қарастырылады. Қазақстанның көрнекті мемлекет және қоғам қайраткері, елдің аумақтық тұтастығын сақтауға және мемлекеттілігін нығайтуға елеулі үлес қосқан Жұмабек Ахметұлы Тәшенев туралы материалдарды пайдалануға ерекше назар аударылады. Орыс тілі сабақтарының мазмұнына тарихи мәтіндерді енгізудің педагогикалық тұрғыдан тиімділігі негізделіп, олардың білім алушылардың оқу мотивациясын арттыруға, сөздік қорын молайтуға және коммуникативтік дағдыларын дамытуға ықпалы айқындалады.

Зерттеудің мақсаты – Жұмабек Тәшенев туралы тарихи материалдарды пайдаланудың білім алушылардың тілдік, коммуникативтік және аналитикалық құзыреттерін қалыптастырудағы тиімділігін анықтау. Зерттеу барысында пәнаралық интеграцияның дидактикалық мүмкіндіктері қарастырылып, мәтінді талдау, өз пікірін дәлелдеу, ауызша және жазбаша сөйлеу дағдыларын дамытуға бағытталған тапсырмалар әзірленеді. Зерттеудің әдіснамалық негізін ғылыми-әдістемелік әдебиеттерді талдау, педагогикалық бақылау, эксперимент, салыстырмалы талдау және зерттеу нәтижелерін жинақтау құрайды.

Тарихи материалдарды орыс тілі сабақтарында жүйелі түрде пайдалану білім алушылардың танымдық белсенділігін арттыруға, өз ойын дербес жеткізу дағдыларын қалыптастыруға және сыни ойлауын дамытуға ықпал етеді деп болжанады. Зерттеудің практикалық маңыздылығы пәнаралық байланыстар негізінде орыс тілін оқытуды жетілдіру мақсатында ұсынылған әдістемелік тәсілдерді оқу үдерісінде қолдану мүмкіндігімен айқындалады. Жұмабек Тәшеневтің тарихи мұрасын пайдалану тәрбиелік маңызға да ие, өйткені ол азаматтық жауапкершілікті, патриотизмді және Қазақстан тарихына деген құрметті қалыптастыруға ықпал етеді.

Түйін сөздер: пәнаралық интеграция, орыс тілін оқыту, тарихи материалдар, Жұмабек Тәшенев, коммуникативтік құзыреттілік, сөйлеу дағдылары, сыни ойлау, оқу мотивациясы, патриоттық тәрбие.

EFFECTIVE INTEGRATION OF HISTORICAL MATERIALS ABOUT ZHUMABEK AKHMETULY TASHENEV INTO RUSSIAN LANGUAGE CLASSES

Yesenkul Agidilova
Senior Lecturer, Department of Russian and Uzbek Languages, J.A. Tashenov University, Shymkent, Kazakhstan
yesenkul.agidilova@mail.ru

Abstract. The article examines the theoretical and practical aspects of integrating historical materials into the process of teaching Russian. Special attention is given to materials about Zhumabek Akhmetuly Tashenov, a prominent statesman and public figure of Kazakhstan who made a significant contribution to preserving the country's territorial integrity and strengthening its statehood. The pedagogical rationale for incorporating historical texts into Russian language classes is substantiated, with a particular focus on enhancing students' learning motivation, expanding their vocabulary, and developing their communicative skills.

The aim of the study is to determine the effectiveness of using historical materials about Zhumabek Tashenov in developing students' linguistic, communicative, and analytical competencies.

The study explores the didactic potential of interdisciplinary integration and develops tasks aimed at improving text analysis, argumentation, and oral and written communication skills. The methodological framework includes an analysis of academic and methodological literature, pedagogical observation, an experiment, comparative analysis, and the synthesis of research findings.

It is hypothesized that the systematic use of historical materials in Russian language classes contributes to increasing students' cognitive engagement, developing their ability to express their thoughts independently, and enhancing critical thinking. The practical significance of the study lies in the potential application of the proposed methodological approaches in the educational process to improve Russian language teaching through interdisciplinary connections. The use of Zhumabek Tashenov's historical legacy also has significant educational value, contributing to the development of civic responsibility, patriotism, and respect for the history of Kazakhstan.

Key words: interdisciplinary integration, Russian language teaching, historical material, Zhumabek Tashenev, communicative competence, speech skills, critical thinking, learning motivation, patriotic education.

ӘОЖ 687.016.5
ҒТАМР 64.33.14

КҮРДЕЛІ ҚҰРЫЛЫМДЫ ЖӘНЕ ПІШІНДІ КИІМДЕРДІ ЖОБАЛАУДА ДӘСТҮРЛІ ЖӘНЕ 3D ЦИФРЛЫҚ ӘДІСТЕРДІ БІРІКТІРУ

В.М. Джанпаизова[1], Ж. А. Рахманкулова[2], К.К. Камалбаева[3], Ж.Е.Байтелеева[4]

[1]к.х.н., доцент, [2,3,4] магистр, аға оқытушы

«Жұмабек Ахметұлы Тәшенев атындағы университет» АҚ, Шымкент, Қазақстан,

корреспондент-автордың электрондық поштасы: rakh_zhanat@mail.ru

Аңдатпа. Күрделі геометриялық, асимметриялық, көпқабатты және драпировкалы киім үлгілерін жобалау көркемдік идеяны материал қасиеттерімен, антропометриялық деректермен және технологиялық орындалу талаптарымен бір мезгілде үйлестіруді қажет етеді. Зерттеудің мақсаты — күрделі пішінді киімді әзірлеуде муляждеу, жазық конструкциялау және 3D виртуалды прототиптеу әдістерінің қызметін жүйелеу және оларды біріктіретін дәлелді жобалау алгоритмін ұсыну. Зерттеу салыстырмалы-аналитикалық дизайнда орындалды: 2016–2025 жылдары жарияланған рецензияланған еңбектер, ISO 8559-1:2017 стандарты және киімнің виртуалды прототипіне қатысты әдістемелік деректер тақырыптық синтез арқылы талданды. Бағалау өлшемдері ретінде пішінді қалыптастыру еркіндігі, антропометриялық сәйкестік, материал мінез-құлқын бейнелеу дәлдігі, түзету қайтымдылығы және физикалық прототип қажеттілігі алынды. Нәтижелер күрделі пішін үшін бір ғана әдістің жеткіліксіз екенін көрсетті. Муляждеу көлем мен пластиканы іздеуде тиімді; жазық конструкциялау лекалоның технологиялық тазалығын қамтамасыз етеді; 3D жүйе нұсқаларды жылдам салыстыруға, коллизияны, керілу мен деформация аймақтарын ерте анықтауға мүмкіндік береді. Алайда виртуалды нәтиженің сенімділігі мата қалыңдығы, аудандық тығыздығы, созылуы, ығысуы және иілу қаттылығы дұрыс калибрленген жағдайда ғана артады. Ұсынылған алгоритм «антропометрия — материалды сынау — муляж/2D лекало — 3D тексеру — физикалық бақылау үлгісі — кері түзету» циклін қамтиды. Зерттеу қорытындысы гибридті тәсіл күрделі киімнің пішіндік сапасын бағалауды жүйелейтінін, бірақ соңғы физикалық үлгіні толық алмастырмайтынын көрсетеді.

Кілт сөздер: күрделі пішінді киім, киім конструкциясы, муляждеу, драпировка, 3D виртуалды прототиптеу, CAD, антропометрия, материал қасиеттері.

Кіріспе

Киім пішіні адам денесінің өлшемдерімен ғана емес, конструкциялық мүшелену, материалдың механикалық мінез-құлқы, қабаттар арасындағы өзара әсер және қозғалыс кезіндегі деформация арқылы қалыптасады. Қарапайым базалық конструкцияда бұл факторлардың бір бөлігі стандартты қосымшалармен басқарылса, күрделі пішінді бұйымда асимметрия, кеңістіктік қатпар, бұралу, модуль, қаңқалық бөлшек немесе трансформацияланатын түйін қосымша белгісіздіктер туғызады. Сондықтан мұндай бұйымды тек жазық сызбаға немесе тек көркем эскизге сүйеніп әзірлеу қондырма сапасы мен пішін тұрақтылығын алдын ала бағалауға мүмкіндік бермейді.

Антропометриялық деректерді біріздендіру киім конструкциясының бастапқы шарты болып табылады. ISO 8559-1:2017 дене өлшемдерінің анықтамаларын және оларды алу қағидаларын белгілейді; стандарт физикалық және цифрлық антропометриялық дерекқорларды салыстыруға негіз береді [1]. Алайда дене өлшемдері киімнің сыртқы көлемін өздігінен анықтамайды: еркіндік қосымшасы, материалдың созылуы мен иілуі, тігіс құрылымы және дизайнерлік пішін бөлек ескерілуі тиіс.

3D киім жүйелері екіөлшемді лекалоны цифрлық аватарда жинақтап, бұйымның сыртқы көрінісін, қатпар түзілуін және шартты керілу карталарын бағалауға мүмкіндік береді. Зерттеулер мұндай технологиялардың үлгілерді ерте кезеңде салыстыруға көмектесетінін көрсеткенімен, виртуалды мата мен нақты матаның сәйкестігі автоматты түрде қамтамасыз етілмейді [2–6]. Dai және Hong мата параметрлерін әртүрлі бағдарламаларда атау, өлшеу және сандық модельге түрлендіру біркелкі емес екенін жүйелі шолуда атап өтеді [2]. Kim мен Lee 30 жібек матаны зерттеп, нақты және виртуалды драпировка коэффициенттері өзара жоғары байланысты болғанымен, қатты әрі аз созылатын маталарда айырмашылық ұлғаятынын көрсетті [3]. Бұл нәтиже күрделі көлемді бұйымдар үшін физикалық сынақты алып тастауға болмайтынын дәлелдейді.

Бастапқы қолжазбадағы негізгі мәселе — тәжірибе жүргізу хаттамасы берілмей тұрып, «уақыт 2–2,5 есе қысқарды», «деталь саны 2–3 есе артты» және «CAD/CAM қолдану үлесі өсті» деген сандық тұжырымдардың ұсынылуы. Мұндай көрсеткіштер нақты іріктеме, өлшем бірлігі, бақылау жағдайы және статистикалық талдау болмаған кезде ғылыми нәтиже ретінде түсіндірілмейді. Осы себепті бұл зерттеуде шартты графиктер алынып тасталып, тек жарияланған және тексерілетін деректерге негізделген салыстырмалы синтез орындалды.

Зерттеудің мақсаты — күрделі құрылымды және пішінді киімдерді жобалауда дәстүрлі муляждеу, 2D конструкциялау және 3D цифрлық прототиптеу әдістерінің мүмкіндігі мен шектеуін жүйелеп, оларды біріктіретін кезеңдік алгоритм ұсыну. Осы мақсатқа сәйкес үш зерттеу сұрағы қойылды: 1) күрделі пішінді жобалаудың негізгі басқарылатын факторлары қандай; 2) әр әдіс жобалау циклінің қай кезеңінде басым нәтиже береді; 3) виртуалды прототипті физикалық үлгімен тексеру қандай жағдайларда міндетті?

Зерттеудің ғылыми жаңалығы. Күрделі пішінді киім сыртқы көрінісі бойынша ғана емес, пішінді ұстап тұратын конструкциялық механизмі бойынша жіктелді; муляждеу, 2D конструкциялау және 3D прототиптеу жеке тәсілдер ретінде емес, кері байланысы бар бірыңғай жобалау цикліне біріктірілді. Жарияланған эксперименттік деректер негізінде нақты және виртуалды драпировканың айырмасы көрнекі түрде қайта талданып, цифрлық прототипті міндетті физикалық тексеруді қажет ететін жағдайлар нақтыланды.

Материалдар мен әдістер

Зерттеу дизайны және дереккөздерді іріктеу

Жұмыс салыстырмалы-аналитикалық зерттеу ретінде ұйымдастырылды. Тақырыптық іздеу 2026 жылғы қазанда баспагерлердің ашық беттері, DOI метадеректері және халықаралық стандарттың ресми карточкасы арқылы жүргізілді. Іздеу тіркестері қазақ, орыс және ағылшын тілдерінде құрастырылды: «күрделі пішінді киім», «муляждеу және 3D прототип», “3D virtual garment”, “fabric drape simulation”, “garment fit assessment”, “fabric mechanical parameters apparel CAD”.

Іріктеу өлшемдері: а) зерттеу киім конструкциясына, виртуалды қондырмаға немесе мата драпировкасына тікелей қатысты болуы; ә) әдісі мен зерттеу нысаны сипатталуы; б) рецензияланған журналда, ғылыми конференция материалында немесе беделді стандарттау ұйымында жариялануы; в) библиографиялық деректері мен DOI/тұрақты сілтемесі тексерілуі. Тек маркетингтік сипаттағы бағдарламалық мәлімдемелер, авторы белгісіз веб-материалдар, қайтарып алынған мақалалар және бастапқы дерегі көрсетілмеген сандық бағалар дәлел ретінде пайдаланылмады. Соңғы синтезге әдістемелік тұрғыдан тікелей релевантты 10 дереккөз енгізілді.

Талдау өлшемдері

Әр дереккөзден зерттеу нысаны, қолданылған әдіс, мата параметрлері, виртуалды және физикалық прототиптің салыстырылуы, негізгі нәтиже және авторлар көрсеткен шектеу алынды. Әдістер бес өлшем бойынша салыстырылды: 1) үшөлшемді пішінді іздеу еркіндігі; 2) антропометриялық сәйкестікті бақылау; 3) материал қасиетін бейнелеу; 4) түзетудің қайтымдылығы; 5) өндіріске дайындау мүмкіндігі. Сандық мета-талдау жүргізілген жоқ, өйткені жұмыстардың бағдарламалары, үлгілері, маталары және нәтижелік көрсеткіштері біртекті емес.

Күрделі пішінді бұйымды зерттеу мен әзірлеу бір реттік сызықтық әрекет емес. Материал профилі мен физикалық үлгі арасындағы сәйкессіздік анықталған сайын лекало немесе цифрлық параметр қайта қаралады. Осы қайталамалы логика 1-суретте берілген.



1-сурет. Күрделі пішінді киімді жобалаудың қайталамалы циклі

Күрделі пішінді жіктеу қағидасы

Күрделілік сыртқы көрініс бойынша ғана емес, пішінді ұстап тұратын механизм бойынша жіктелді. Төрт топ ажыратылды: геометриялық-асимметриялық пішін; драпировкалы және бұралмалы пішін; көпқабатты пішін; қаңқалы немесе трансформацияланатын пішін. Бұл жіктеу әр топқа қажетті бақылау параметрлерін анықтауға мүмкіндік береді (1-кесте).



2-сурет. Күрделі құрылымды және пішінді киімдердің жіктелуі

1-кесте. Күрделі киім пішіндерінің жобалық белгілері

Пішін тобы	Негізгі конструкциялық белгі	Басым тәуекел	Ұсынылатын тексеру
Геометриялық-асимметриялық	Теңгерімсіз көлем, диагональ мүшелену, кеңістіктік қосымша	Ауырлық орталығының ығысуы, етек пен иық теңгерімінің бұзылуы	Манекендегі баланс, 3D-де фронталь және бүйір проекция
Драпировкалы	Еркін қатпар, бүрме, бұралу, қиғаш пішу	Қатпар бағытының тұрақсыздығы, созылу	Нақты матаның иілуі мен ығысуын сынау, муляж
Көпқабатты	Бірнеше тәуелсіз немесе жартылай байланысқан қабат	Қабаттар коллизиясы, артық қалыңдық	3D коллизия тексеруі және физикалық қабаттау
Қаңқалы/трансформацияланатын	Қатайтқыш, модуль, ажырамалы түйін, бірнеше күй	Түйіннің істен шығуы, қозғалыс шектеуі	Түйін прототипі, қозғалыс сынағы, пайдалану сценарийі

Нәтижелер

Әдістердің функционалдық орны

Талдау үш әдістің бірін-бірі алмастырмайтынын, әрқайсысы жобаның әртүрлі белгісіздігін азайтатынын көрсетті. Муляждеу материалды дене немесе манекен үстінде тікелей орналастыру арқылы көлемнің композициялық логикасын табуға қолайлы. Оның күші — қатпардың бағытын, ауырлық әсерін және матаның табиғи пластикасын көру. Әлсіз жағы — нәтижені өлшем қатарына көшіру мен қайталап өндіру үшін пішінді жазық лекалоға дәл түрлендіру қажеттілігі.

2D конструкциялау бақылау нүктелерін, қосымшаларды, тігіс ұзындықтарын, кертіктерді және технологиялық қосымшаларды рәсімдейді. Бұл әдіс өндірістік құжаттаманың негізі болғанымен, күрделі кеңістіктік көлемді жазықтықта елестету тәжірибеге тәуелді. 3D

прототиптеу лекалоны аватарда жинақтап, нұсқаларды жедел салыстыруға және ықтимал коллизияны көруге мүмкіндік береді [4–8]. Бірақ виртуалды қысым немесе керілу картасы клиникалық не абсолютті физикалық өлшем емес; оның мәні бағдарлама моделіне, аватарға және енгізілген материал деректеріне тәуелді [7, 9].

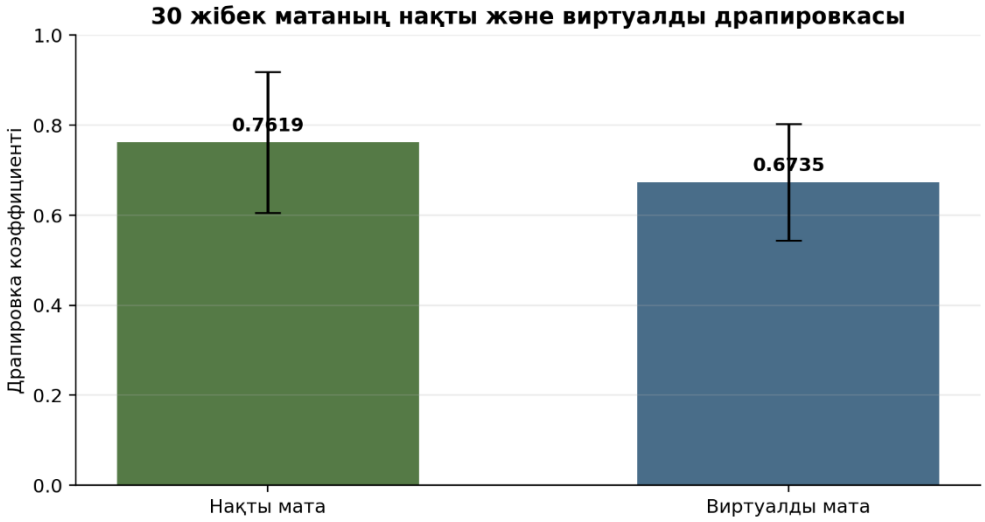
2-кесте. Жобалау әдістерінің салыстырмалы сипаттамасы

Өлшем	**Муляждеу**	**2D конструкциялау**	**3D виртуалды прототиптеу**
Көлемді пішінді іздеу	Өте қолайлы; материал мінезі тікелей көрінеді	Жанама; конструкторлық тәжірибеге тәуелді	Қолайлы; бірнеше нұсқаны салыстыруға болады
Антропометриялық бақылау	Манекен сәйкестігімен шектеледі	Өлшемдер мен қосымшалар нақты беріледі	Аватар дәлдігіне және позаға тәуелді
Материалды бейнелеу	Нақты материал қолданылса, жоғары	Көбіне технологиялық қосымша арқылы жанама	Параметрлер дұрыс өлшеніп, калибрленсе жоғарылайды
Түзету	Қайта түйреу/пішу қажет	Лекалоны қайта құру қажет	Сандық түзету қайтымды және салыстыруға ыңғайлы
Өндіріске дайындау	Лекалоға көшіруді қажет етеді	Негізгі өндірістік база	2D лекаломен байланысқанда тиімді
Негізгі шектеу	Орындаушы шеберлігі және материал шығыны	Кеңістіктік әсерді алдын ала көру қиындығы	Физикалық модель мен параметр енгізу қателігі

Материал қасиеттерінің виртуалды пішінге әсері

Әдебиеттер синтезі иілу қаттылығы, аудандық тығыздық, қалыңдық, созылу және ығысу сипаттары виртуалды драпировка үшін негізгі параметрлер екенін көрсетті [2, 3, 6, 10]. Бұл параметрлерді бір ғана «драпировкалану» бағасына біріктіру жеткіліксіз: екі матаның драпировка коэффициенті ұқсас болғанымен, бағыттық созылуы немесе ығысуы әртүрлі болуы мүмкін. Күрделі асимметриялық және қиғаш пішілген бөлшектерде осы айырмашылық қатпар бағыты мен етек геометриясын өзгертеді.

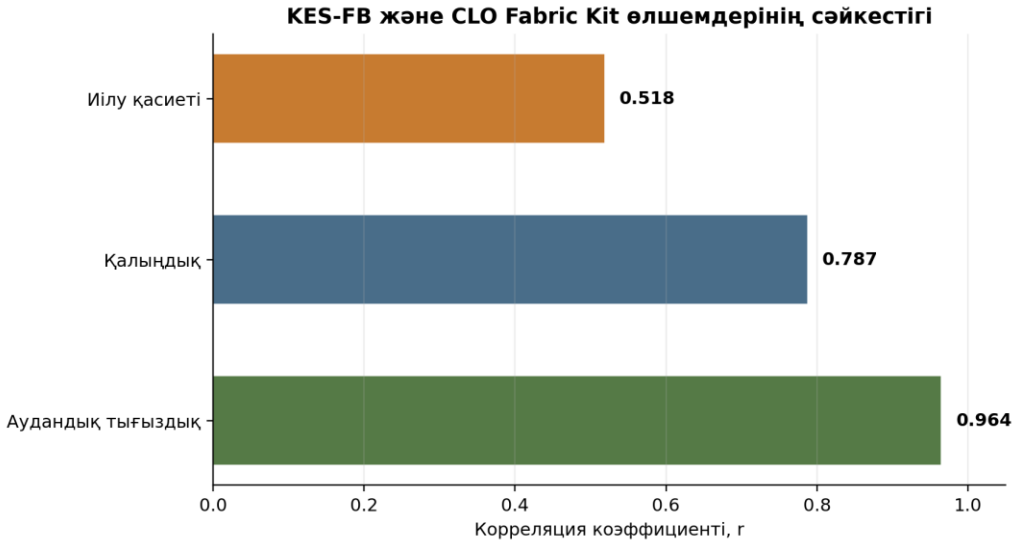
Kim және Lee зерттеуінде 30 жібек матаның нақты және CLO ортасындағы виртуалды драпировка коэффициенттері арасында r=0,824 байланыс табылған, алайда орташа нақты және виртуалды мәндер арасында статистикалық айырмашылық сақталған [3]. Иілгіш және созылғыш үлгілердің сәйкестігі жоғарырақ, ал қатты маталарда айырмашылық артқан. Сондықтан виртуалды көріністі «нақты матаның дәл көшірмесі» емес, калибрленетін есептік модель ретінде қарастырған жөн.



3-сурет. Нақты және виртуалды жібек маталардың драпировка коэффициенттерін салыстыру [3]

3-суреттегі диаграмма Kim және Lee жариялаған нақты эксперименттік деректер негізінде қайта құрастырылды: нақты маталар үшін орташа коэффициент 0,7619 (SD=0,1564), виртуалды үлгілер үшін 0,6735 (SD=0,1294), n=30. Авторлар екі топ арасындағы айырмашылықты статистикалық маңызды деп көрсеткен (t=5,330; p=0,03) [3].

Сол зерттеуде KES-FB зертханалық жүйесі мен CLO Fabric Kit арқылы алынған аудандық тығыздық, қалыңдық және иілу көрсеткіштері салыстырылды. Ең жоғары сәйкестік аудандық тығыздықта, одан кейін қалыңдық пен иілу қасиетінде байқалды (4-сурет). Созылу көрсеткіші бойынша маңызды байланыс табылмағандықтан, ол диаграммаға енгізілмеді [3].



4-сурет. KES-FB және CLO Fabric Kit өлшемдері арасындағы корреляция [3]

Koo және әріптестері нақты және виртуалды жейделік маталарды салыстыруда мата түрін жіктеу мен қондырма карталарын бірге қолданған [6]. Brubacher және әріптестері компрессиялық киім қысымын болжауда виртуалды қондырманың практикалық дәлдігі дене мен материалдың дұрыс цифрлануына тәуелді екенін көрсетті [9]. Бұл қорытындылар күрделі пішінді сәндік бұйымдарға да әдістемелік тұрғыдан маңызды: бағдарламалық карта шешім қабылдауды қолдайды, бірақ өлшенбеген материал үшін дәлел бола алмайды.

Гибридті жобалау алгоритмі

Синтез нәтижесінде күрделі пішінді киімді әзірлеудің алты кезеңді алгоритмі ұсынылды. Бірінші кезеңде ISO 8559-1 қағидалары бойынша мақсатты дене өлшемдері, қалып және

қозғалыс сценарийі белгіленеді. Екінші кезеңде негізгі және көмекші материалдардың қалыңдығы, аудандық тығыздығы, бойлық/көлденең/қиғаш бағыттағы созылуы, ығысуы және иілуі өлшенеді. Үшінші кезеңде пішіннің табиғатына қарай муляж немесе бастапқы 2D лекало әзірленеді. Төртінші кезеңде лекало мен материал параметрлері 3D ортаға енгізіліп, силуэт, саңылау, коллизия, керілу және қозғалыс бағаланады. Бесінші кезеңде ең тәуекелді түйін немесе толық бұйым физикалық материалда жасалады. Алтыншы кезеңде нақты және виртуалды үлгінің айырмасы бойынша лекало мен материал профилі кері түзетіледі.

3-кесте. Жобалау кезеңдеріндегі бақылау көрсеткіштері

Кезең	Тіркелетін дерек	Шешім қабылдау өлшемі
Антропометриялық база	Дене өлшемдері, қалып, қозғалыс амплитудасы	Аватар/манекен мақсатты пайдаланушыға сәйкес
Материалды сипаттау	Құрамы, қалыңдығы, аудандық тығыздығы, иілуі, созылуы, ығысуы	Бағдарламаға өлшенген профиль енгізілді
Алғашқы пішін	Эскиз, муляж фотосы, базалық лекало, баланс сызықтары	Композиция және конструкциялық логика келісілді
Виртуалды сынақ	Силуэт, саңылау, коллизия, керілу/деформация картасы	Критикалық аймақтар белгіленіп, нұсқалар салыстырылды
Физикалық сынақ	Нақты қондырма, қатпар, тігіс, қозғалыс, түйін жұмысы	Қауіпсіздік, қолайлылық және пішін тұрақтылығы расталды
Верификация	Нақты–виртуалды айырмашылық және түзету журналы	Айырмашылық түсіндіріліп, файл нұсқасы бекітілді

Талқылау

Ұсынылған нәтижелер күрделі киім жобалауда технологияны «дәстүрлі әдіс немесе цифрлық әдіс» түріндегі қарама-қарсылықпен таңдаудың дұрыс еместігін көрсетеді. Негізгі мәселе — әр әдістің қандай белгісіздікті азайтатынын анықтау. Материалмен тікелей жұмыс композициялық пішінді ашады; 2D лекало өндірістік дәлдікті бекітеді; 3D модель нұсқаларды салыстыру мен ерте тексеруді жеңілдетеді. Papachristou және әріптестері лазерлік кесілген киімге арналған әдістемелік құрылымда 3D прототипті дизайн әзірлеу цикліне кезеңдеп енгізудің маңызын көрсетеді [5]. Бұл тәсіл қаңқалы, модульдік және трансформацияланатын киімдер үшін де қисынды, өйткені күрделі түйін бірден толық бұйымда емес, жеке цифрлық және физикалық модульде тексерілуі мүмкін.

3D прототиптеу тұрақтылыққа жанама үлес қоса алады: жарамсыз нұсқаларды материал кесілмей тұрып алып тастау, қашықтан келісу және лекало нұсқаларын сандық ортада сақтау ықтимал. Дегенмен нақты мата шығынының немесе көміртек ізінің төмендеуін осы зерттеу өлшеген жоқ. Сондықтан 3D технология «міндетті түрде қалдықты азайтады» деген себепсалдарлық тұжырым жасалмайды; мұндай қорытынды үшін кәсіпорын деңгейіндегі бастапқы және кейінгі көрсеткіштер қажет [4].

Виртуалды прототиптің қателігі үш дереккөзден туындайды. Біріншісі — аватар: дене өлшемі дұрыс болғанымен, дене пішіні, жұмсақ тін және поза сәйкес келмеуі мүмкін. Екіншісі — материал: сынақсыз таңдалған кітапханалық мата нақты партияның қасиетін қайталамауы ықтимал. Үшіншісі — модельдеу: бөлшек торының тығыздығы, тігіс, қабат аралығы және коллизия параметрлері нәтижеге ықпал етеді [2, 3, 10]. Осыған байланысты мақалада бағдарламаларды «бар/жоқ» белгісімен үстірт салыстыратын бұрынғы кесте алынып

тасталды. Бағдарлама нұсқалары жиі жаңаратындықтан, мұндай кесте тез ескіреді және функцияның сапасын көрсетпейді.

Зерттеудің ғылыми-практикалық үлесі — күрделі пішінді бұйымды пішін механизмі бойынша жіктеп, әдіс таңдауын өлшенетін бақылау қадамдарымен байланыстыру. Ұсынылған цикл оқу шеберханасында, авторлық ательеде және шағын өндірісте қолдануға бейімделе алады. Әр жобаға түзету журналын жүргізу материал профилі, лекало нұсқасы және физикалық сынақ арасындағы байланысты сақтап, кейінгі модельдер үшін ішкі дерекқор қалыптастырады.

Зерттеудің шектеулері бар. Біріншіден, бұл жұмыс авторлардың жаңа өндірістік экспериментін емес, жарияланған еңбектердің салыстырмалы синтезін ұсынады. Екіншіден, бағдарламалық платформалар мен материал параметрлерінің бірліктері әртүрлі болғандықтан, әдістердің уақыт немесе дәлдік бойынша бірыңғай сандық әсері есептелмеді. Үшіншіден, ұсынылған алгоритм Қазақстандағы нақты кәсіпорында апробациядан өтпеген. Келесі кезеңде бір күрделі модельді кемінде үш материалда дайындап, 2D+муляж және 2D+3D гибридті бағыттарын бірдей орындаушылармен салыстыру қажет. Хронометраж, материал шығыны, түзету саны, сараптамалық қондырма бағасы және нақты–виртуалды контур айырмасы алдын ала бекітілген хаттама бойынша тіркелуі тиіс.

Қорытынды

Күрделі құрылымды және пішінді киімді жобалау антропометрияны, материал механикасын, кеңістіктік композицияны және өндірістік технологияны бір жүйеде қарастыруды талап етеді. Әдебиеттерді талдау негізінде мынадай қорытындылар жасалды:

1. Муляждеу, 2D конструкциялау және 3D виртуалды прототиптеу өзара балама емес; олар пішін, өндірістік дәлдік және цифрлық тексеру міндеттерін бөлісетін өзара толықтырушы әдістер.

2. Виртуалды драпировка сенімділігі материалдың иілу, созылу, ығысу, қалыңдық және аудандық тығыздық көрсеткіштерін өлшеу мен калибрлеуге тікелей тәуелді.

3. Күрделі, көпқабатты және қатты материалды бұйымдарда 3D прототип физикалық бақылау үлгісін толық алмастырмайды; әсіресе түйін жұмысы, қозғалыс және нақты қатпар тек физикалық сынақта расталады.

4. Ұсынылған «антропометрия — материалды сынау — муляж/2D — 3D — физикалық үлгі — кері түзету» циклі шешімдерді тіркеуге және жобалау қателерін ерте кезеңде анықтауға жағдай жасайды.

5. Уақыт үнемі, материал шығыны және дәлдік туралы сандық қорытынды тек нақты эксперименттік хаттама мен бастапқы деректер болғанда берілуі тиіс.

Пайдаланылған әдебиеттер:

1. International Organization for Standardization. ISO 8559-1:2017. Size designation of clothes — Part 1: Anthropometric definitions for body measurement. Geneva: ISO; 2017. https://www.iso.org/standard/61686.html

2. Dai X., Hong Y. Fabric mechanical parameters for 3D cloth simulation in apparel CAD: A systematic review. Computer-Aided Design. 2024;167:103638. https://doi.org/10.1016/j.cad.2023.103638

3. Kim J.H., Lee J.-S. Investigating parameters affecting the real and virtual drapability of silk fabrics for traditional Hanbok. Fashion and Textiles. 2024;11:21. https://doi.org/10.1186/s40691-024-00388-6

4. Papachristou E., Bilalis N. Should the fashion industry confront the sustainability challenge with 3D prototyping technology? International Journal of Sustainable Engineering. 2017;10(4–5):207–214. https://doi.org/10.1080/19397038.2017.1348563

5. Papachristou E., Kalaitzi D., Pissas V. A methodological framework for the integration of 3D virtual prototyping into the design development of laser-cut garments. Journal of Engineered Fibers and Fabrics. 2023;18. https://doi.org/10.1177/15589250231194621

6. Koo D.S., An J.S., Yoon H.J. Classification and analysis of fabric types for shirts: A comparison between virtual and real fabrics. Journal of Engineered Fibers and Fabrics. 2024;19. https://doi.org/10.1177/15589250241262318

7. Sayem A.S.M., Kennon R., Clarke N. Objective analysis of the drape behaviour of virtual shirt, part 2: technical parameters and findings. International Journal of Fashion Design, Technology and Education. 2017;10(1):77–87. https://doi.org/10.1080/17543266.2016.1223810

8. Wu Y., Mok P.Y., Kwok Y.L., Fan J.T., Xin J.H. An investigation on the validity of 3D clothing simulation for garment fit evaluation. Proceedings of the IMProVe 2011 International Conference on Innovative Methods in Product Design; 2011. p. 463–468.

9. Brubacher K., Tyler D., Apeagyei P., Venkatraman P., Brownridge A.M. Evaluation of the accuracy and practicability of predicting compression garment pressure using virtual fit technology. Clothing and Textiles Research Journal. 2023;41(1):32–47. https://doi.org/10.1177/0887302X21999314

10. Lapkovska E., Dabolina I. An investigation on the virtual prototyping validity: Simulation of garment drape. Society. Integration. Education. Proceedings of the International Scientific Conference. 2018;4:448–458. https://doi.org/10.17770/sie2018vol1.3187

ИНТЕГРАЦИЯ ТРАДИЦИОННЫХ И 3D ЦИФРОВЫХ МЕТОДОВ ПРИ ПРОЕКТИРОВАНИИ ОДЕЖДЫ СЛОЖНОЙ КОНСТРУКЦИИ И ФОРМЫ

В.М. Джанпаизова[1], Ж. А. Рахманкулова[2*], К.К. Камалбаева[3], Ж.Е. Байтелеева[4]
к.х.н., доцент[1], магистр, старший преподаватель[2,3,4]
АО «Университет имени Ж.А. Ташенева», Шымкент, Казахстан
электронная почта автора-корреспондента: rakh_zhanat@mail.ru

Проектирование сложных геометрических, асимметричных, многослойных и драпированных моделей одежды требует одновременного сочетания художественной идеи со свойствами материала, антропометрическими данными и требованиями технологического исполнения. Цель исследования-систематизировать деятельность методов манекенщицы, плоского конструирования и виртуального 3D-прототипирования при разработке одежды сложной формы и предложить алгоритм доказательного проектирования, который их объединяет. Исследование было выполнено в сравнительно-аналитическом дизайне: рецензируемые работы, опубликованные в 2016-2025 годах, стандарт ISO 8559-1: 2017 и методические данные, относящиеся к виртуальному прототипу одежды, были проанализированы с помощью тематического синтеза. В качестве критериев оценки были получены свобода формирования формы, антропометрическая идентичность, точность представления поведения материала, обратимость коррекции и потребность в физическом прототипе. Результаты показали, что одного метода недостаточно для сложной формы. Муляж эффективен при поиске объема и пластичности; плоская конструкция обеспечивает технологическую чистоту лекало; 3D-система позволяет быстро сравнивать варианты, на ранней стадии выявлять коллизии, зоны натяжения и деформации. Однако надежность виртуального результата увеличивается только в том случае, если толщина ткани, плотность площади, растяжение, смещение и жесткость на изгиб откалиброваны должным образом. Предлагаемый алгоритм включает цикл» антропометрия — тестирование материала — манекен/2D лекало — 3D проверка — модель физического контроля — обратная коррекция". Результаты исследования показывают, что гибридный подход систематизирует оценку формового качества сложной одежды, но не полностью заменяет окончательную физическую модель.

Ключевые слова: сложная форма одежды, конструкция одежды, муляжирование, драпировка, 3D-прототипирование, CAD, антропометрия.

INTEGRATING TRADITIONAL AND 3D DIGITAL METHODS IN THE DESIGN OF STRUCTURALLY AND FORMALLY COMPLEX GARMENTS

V.M. Janpaizova, J. A. Rakhmankulova*, K.K. Kamalbayeva , J.E. Baiteleeva[4]
Candidate of Chemical Sciences, Associate professor[1], master's degree, senior lecturer [2,3,4]
JSC "Zh.A. Tashenov University", Shymkent, Kazakhstan

Designing complex geometric, asymmetrical, multi-layered and draped clothing models requires a simultaneous combination of artistic ideas with material properties, anthropometric data and technological performance requirements. The purpose of the study is to systematize the activities of the methods of modeling, flat design and virtual 3D prototyping in the development of complex-shaped clothing and to propose an algorithm for evidence-based design that combines them. The study was performed in a comparative analytical design.:Peer-reviewed papers published in 2016-2025, the ISO 8559-1:2017 standard and methodological data related to the virtual prototype of clothing were analyzed using thematic synthesis. The evaluation criteria were freedom of form formation, anthropometric identity, accuracy of representation of material behavior, reversibility of correction, and the need for a physical prototype. The results showed that one method is not enough for a complex form. The dummy is effective in finding volume and plasticity.; The flat design ensures the technological purity of the pattern; the 3D system allows you to quickly compare options, identify collisions, tension zones and deformations at an early stage. However, the reliability of the virtual result increases only if the fabric thickness, area density, stretching, displacement, and bending stiffness are properly calibrated. The proposed algorithm includes the cycle "anthropometry — material testing — dummy/2D template — 3D verification — physical control model — reverse correction". The results of the study show that the hybrid approach systematizes the assessment of the form quality of complex clothing, but does not completely replace the final physical model.

Key words: complex garment form, garment construction, draping, fabric drape, 3D virtual prototyping, CAD, anthropometry.

ӘОЖ 28.23.15

МАШИНАЛЫҚ ОҚЫТУ МОДЕЛЬДЕРІНІҢ ТҮСІНДІРМЕЛІЛІГІН БАҒАЛАУ ӘДІСТЕРІН ЗЕРТТЕУ: FEATURE IMPORTANCE ЖӘНЕ SHAP НӘТИЖЕЛЕРІН САЛЫСТЫРУ

[1]Жолшиева А.З., [2]Мұсабекова Б.С., [3]Аббаз Н. Б.
[1]IT және цифрлық технологиялар кафедрасының аға оқытушысы, магистр
Ж.А.Тәшенев атындағы университет, Шымкент қ.
almira82nur@gmail.com, https://orcid.org/0009-0007-4595-2602
[2]IT және цифрлық технологиялар кафедрасының оқытушысы, магистр
Ж.А.Тәшенев атындағы университет, Шымкент қ
musabekovab98@gmail.com, https://orcid.org/0009-0003-4519-3563
[3]IT және цифрлық технологиялар кафедрасының оқытушысы, магистр
Ж.А.Тәшенев атындағы университет, Шымкент қ
abbaznurislam@gmail.com https://orcid.org/0009-0007-4525-0846

Аңдатпа. Мақалада кездейсоқ орман моделінің шешімдерін түсіндіретін белгілер маңыздылығын бағалаудың үш тәсілі салыстырылады: түйін біртексіздігінің орташа кемуі (MDI), белгілерді ауыстыру арқылы маңыздылық (permutation importance) және Шепли мәндеріне негізделген SHAP. Эксперимент Wisconsin Diagnostic Breast Cancer жиынында (569 бақылау, 30 белгі) жүргізілді; модель тест жиынында ROC-AUC = 0,9949 көрсетті.

Рейтингтердің келісімі Спирмен мен Кендалл коэффициенттерімен, ең маңызды бес белгінің қиылысуымен және 20 қайталау бойынша тұрақтылықпен бағаланды. MDI мен SHAP рейтингтері өте жақын болды ($\rho = 0{,}973 \pm 0{,}009$), ал permutation importance олармен нашар сәйкеседі ($\rho = 0{,}358 \pm 0{,}473$) және өзі де тұрақсыз (ішкі тұрақтылық 0,257). Алшақтық корреляцияланған белгілер кластерінде шоғырланады: жиындағы 21 жұптың корреляциясы $|r| > 0{,}9$. Бір бөлінудің нәтижесі әдістердің келісімін шынайыдан жоғары көрсетуі мүмкін екені көрсетілді. Зерттеу бір модельмен және бір дерек жиынымен шектелген.

Түйін сөздер: түсіндірілетін жасанды интеллект; SHAP; белгілердің маңыздылығы; кездейсоқ орман; permutation importance; рангілік корреляция.

Кіріспе

Күрделі модельдер, атап айтқанда ағаштар ансамблі мен терең нейрондық желілер, жіктеу және болжау есептерінде қарапайым сызықтық модельдерден жиі озып жүр. Бірақ бұл артықшылықтың бағасы бар: модельдің нақты бақылау үшін неге дәл осындай жауап бергені сырттан көрінбейді. Медицинада, несиелік скорингте, құқықтық шешімдерде мұның практикалық салдары бар. Тест жиынындағы жоғары дәлдік модельге сенуге жеткіліксіз, өйткені сапасы жақсы модель де кездейсоқ, мәнсіз немесе қолайсыз белгіге сүйеніп тұруы мүмкін. Осы себепті түсіндірілетін жасанды интеллект (explainable AI, XAI) бағыты соңғы жылдары қарқынды дамыды, ал ондағы әдістердің жүйелі шолуларын бірнеше еңбек ұсынған [1, 2, 3].

Терминнің өзі де бір мағыналы емес. Lipton интерпретациялану ұғымының әртүрлі мақсатқа қызмет ететінін көрсеткен [4], ал Doshi-Velez пен Kim түсіндірмелілікті бағалаудың қатаң, ғылыми негізделген әдістемесінің қажеттігін атап өткен [5]. Rudin пікірі одан да қатал: жауапкершілігі жоғары шешімдерде қара жәшікті кейіннен түсіндіргеннен гөрі, бастапқыда түсінікті модельді қолданған жөн [6]. Бұл ұстанымға қарсы шығудың қажеті жоқ, бірақ іс жүзінде қара жәшік модельдер қолданыла беретіні де анық, ал оларды постхок әдістермен талдау қажеттілігі сақталады. Сондықтан мақалада түсіндірмелілік деп оқытылған модельдің мінез-құлқын сипаттайтын әдістерді түсінеміз. Мұндай сипаттама модельдің не істейтінін көрсетеді, ал құбылыстың шынайы себеп-салдарлық құрылымын міндетті түрде көрсетпейді, және бұл айырмашылықты әрдайым есте ұстаған абзал.

Кестелік деректер үшін ең жиі қолданылатын модельдердің бірі — кездейсоқ орман [7], ал оның глобалды сипаттамасы ретінде көбіне белгілердің маңыздылығы беріледі. Мұның үш кең тараған жолы бар. Біріншісі — түйін біртексіздігінің орташа кемуі (mean decrease in impurity, MDI): әр белгі бойынша бөліністерде Джини қоспасының қаншалықты азайғаны жинақталады [8]. Екіншісі — белгілерді ауыстыру арқылы маңыздылық (permutation importance): белгінің мәндері араластырылып, модель сапасының төмендеуі өлшенеді; идеяны Breiman ұсынған, кейін оны модельдер класына жалпылаған [7, 9]. Үшіншісі — кооперативті ойындар теориясындағы Шепли мәндеріне [10] сүйенетін SHAP [11]: болжам белгілер арасында аддитивті түрде бөлінеді, ал ағаштық модельдер үшін мұны тиімді есептейтін алгоритм бар [12].

Тәжірибеде осы үш әдіс көбіне бірінің орнына бірі жүре береді: «маңыздылығы жоғары белгілер» тізімі қай әдіспен алынғанына қарамастан, бірдей мағына беретіндей қабылданады. Шын мәнінде әдістер әртүрлі сұраққа жауап береді. MDI оқыту кезінде ағаштар қай белгіге көбірек сүйенгенін көрсетеді, permutation белгінің тест деректерінде болжам сапасы үшін қаншалықты қажет екенін өлшейді, ал SHAP нақты болжамның белгілер арасында қалай бөлінетінін айтады. Сондықтан олардың рейтингтері сәйкес келуге міндетті емес, ал қашан және неге сәйкес келмейтіні практик үшін маңызды сұрақ.

Осы мақаланың мақсаты — бір модельдің (кездейсоқ орман) шешімдерін үш әдіспен талдап, глобалды рейтингтердің сәйкестігі мен тұрақтылығын сандық түрде бағалау және алшақтықтың қай жерде шоғырланатынын анықтау. Жұмыс болжамы: белгілер корреляцияланған болса, әдістер арасындағы келісім төмендейді, әсіресе permutation importance үшін. Зерттеу бір модельмен және бір дерек жиынымен шектеледі, сондықтан

нәтижені жалпы заңдылық ретінде емес, талқылауға арналған нақты бақылау ретінде оқу керек.

Әдістер

Дерек жиыны. Зерттеуде UCI репозиториясындағы Wisconsin Diagnostic Breast Cancer жиыны қолданылды; ол scikit-learn кітапханасы арқылы жүктелді. Жиында сүт безі түзілімдерінің жіңішке инелі аспирациялық биопсиясынан алынған сандық кескіндер бойынша есептелген 569 бақылау бар: 357-сі қатерсіз, 212-сі қатерлі. Әр бақылау 30 үздіксіз белгімен сипатталады. Олар жасуша ядросының он сипаттамасының (радиус, текстура, периметр, аудан, тегістік, ықшамдылық, ойыстық, ойыс нүктелер, симметрия, фракталдық өлшем) үш статистикасынан тұрады: орташа мәні (mean), стандартты қатесі (error) және үш ең үлкен мәнінің орташасы (worst). Белгілердің бір бөлігі геометриялық тұрғыдан бір-бірімен тікелей байланысты (мысалы, радиус, периметр және аудан), сондықтан жиын корреляцияланған белгілердің әсерін зерттеуге қолайлы. Медициналық диагностика түсіндірменің практикалық мәні жоғары салалардың бірі болғандықтан, әрі бұл жиын жиі қолданылатын эталондық жиындардың қатарына жататындықтан, дәл осы жиын таңдалды. Деректер жалпыға қолжетімді және жеке тұлғаны анықтайтын мәліметтерді қамтымайды. Оң класс ретінде қатерсіз түзіліс (1) алынды.

Модель. Дерек стратификацияланған түрде оқыту (75 %, n = 426) және тест (25 %, n = 143) жиындарына бөлінді (random_state = 42). Модель ретінде кездейсоқ орман [7] қолданылды: 300 ағаш, басқа гиперпараметрлер scikit-learn [20] кітапханасының әдепкі мәнінде қалдырылды. Гиперпараметрлерді арнайы таңдау жүргізілмеді, себебі мақсат ең жоғары дәлдікке жету емес, берілген модельдің шешімін түсіндіру әдістерін салыстыру болды. Модель сапасы тест жиынында accuracy, F1 және ROC-AUC көрсеткіштерімен бағаланды.

Маңыздылық бағалары. Белгілердің маңыздылығы үш тәсілмен есептелді. MDI мәндері модельдің feature_importances_ атрибутынан алынды, яғни олар оқыту жиынымен байланысты. Permutation importance тест жиынында есептелді: әр белгінің мәндері кездейсоқ араластырылып, ROC-AUC-тың орташа төмендеуі өлшенді (10 қайталау). SHAP мәндері TreeExplainer арқылы [12] әдепкі (path-dependent) режимде есептелді, нәтиже оң класс ықтималдығының шкаласында беріледі. Жаһандық маңыздылық ретінде тест жиынының барлық бақылауы бойынша SHAP мәндерінің абсолют шамасының орташасы алынды. Үш әдістің өлшем бірліктері әртүрлі, сондықтан оларды сандық мәндері бойынша емес, тек рейтингтері, яғни белгілердің реттік орны бойынша салыстырдық.

Зерттеу дизайнының негіздемесі. Үш әдістің мәндері әртүрлі шкалада өлшенеді: MDI мәндерінің қосындысы бірге тең, SHAP ықтималдық бірлігінде, permutation ROC-AUC бірлігінде берілген. Сондықтан тікелей мәндерді емес, рангілерді салыстыру қисынды болды. Бес белгі (k = 5) есептеуге дейін таңдалды: ол 30 белгінің алтыдан бірін құрайды және нәтижені оқуға ыңғайлы. Қайталау саны (20) есептеу уақыты мен ауытқуды бағалау дәлдігінің арасындағы келісім ретінде алынды; сенім аралықтары есептелген жоқ. Бұл таңдаулар нәтижені сипаттауға жеткілікті, бірақ қатаң статистикалық тұжырымдарға арналмаған.

Есептеу формулалары. F — белгілер жиыны, f — модель, T — ағаштар саны болсын. MDI j-ші белгі үшін барлық ағаштардағы осы белгі бойынша бөлінген түйіндердегі Джини қоспасының кемуін (Δi) түйінге түскен бақылаулар үлесіне (p) салмақтап қосып, ағаштар бойынша орташалайды: $MDI(j) = (1/T)\ \Sigma t\ \Sigma v\ p(v)\cdot\Delta i(v)$. Permutation importance үшін тест деректерінде базалық метрика s(f, X, y) есептеледі, содан кейін j-ші белгінің мәндері R рет араластырылып (X(j,r)), метриканың орташа төмендеуі алынады: $PI(j) = s(f, X, y) - (1/R)\ \Sigma r\ s(f, X(j,r), y)$. Бізде s = ROC-AUC, R = 10. SHAP үшін j-ші белгінің x бақылауы бойынша үлесі Шепли формуласымен беріледі: $\varphi j(x) = \Sigma\ [\ |S|!\cdot(|F| - |S| - 1)!\ /\ |F|!\ ]\ \cdot\ [\ fS\cup j(x) - fS(x)\ ]$, мұнда қосынды j-ні қамтымайтын барлық $S \subseteq F$ жиындары бойынша алынады, ал fS(x) — тек S белгілері белгілі болғандағы модельдің күтілетін болжамы. Мұндай үлестердің қосындысы болжам мен базалық мәннің айырмасына тең: $\Sigma j\ \varphi j(x) = f(x) - E[f(X)]$. TreeExplainer әдепкі режимде fS(x) мәнін ағаш түйіндеріндегі оқыту бақылауларының үлесі арқылы бағалайды, ал жаһандық маңыздылық $SHAP(j) = (1/n)\ \Sigma i\ |\varphi j(xi)|$ түрінде алынады. Спирмен коэффициенті

рангілер арасындағы Пирсон корреляциясына тең, ал Кендалл τ-b реттері сәйкес келетін және сәйкес келмейтін жұптардың санын салыстырып, тең рангілерді де ескереді.

Салыстыру өлшемдері. Рейтингтердің сәйкестігін бағалау үшін Спирмен мен Кендалл (τ-b) рангілік корреляция коэффициенттері [21] және ең маңызды бес белгінің қиылысуы (top-5) қолданылды. Алғашқы екеуі барлық 30 белгі бойынша есептелді, сондықтан олар төменгі бөліктегі, маңызы шамалы белгілердің реттеліміне де сезімтал. Top-5 бұл кемшілікті айналып өтеді, бірақ оның да шектеуі бар: бес белгінің ішінде корреляцияланған көршілер бір-бірін ауыстыра алады. Белгілер арасындағы корреляция бүкіл жиын бойынша Пирсон коэффициентінің модулі (|r|) арқылы бағаланды.

Тұрақтылықты бағалау. Нәтиженің бір бөлінуге тәуелді болмауын тексеру үшін бүкіл процедура 20 рет қайталанды: әр қайталауда деректің бөлінуі, модельдің кездейсоқ бастапқы мәні және permutation seed өзгертілді (random_state = 0…19). Көрсеткіштер орташа мән ± стандартты ауытқу түрінде берілді. Одан бөлек, әр әдістің ішкі тұрақтылығы есептелді: бір әдіспен алынған 20 рейтингтің барлық жұптары бойынша Спирмен коэффициентінің орташасы. Жұптар өзара тәуелсіз емес, сондықтан онымен бірге берілетін ауытқуды статистикалық қорытынды жасау үшін емес, шашыраңқылықты сипаттау үшін ғана пайдаландық. Есептеулер Google Colab ортасында Python тілінде орындалды.

Қайталанымдылық. Барлық кездейсоқ процестер (деректің бөлінуі, ормандағы ағаштардың құрылуы, араластыру) random_state арқылы бекітілді, дерек жиыны жалпыға қолжетімді, сондықтан нәтижені кітапханалар нұсқасының дәлдігіне дейін қайта алуға болады. Нұсқалар өзгергенде, әсіресе SHAP-тың шығыс форматында (оң класс үшін массив пен тізім арасындағы айырмашылық), өзгеріс болуы мүмкін, сондықтан кодта бұл жағдай бөлек өңделген.

Нәтижелер мен талқылау

Модель сапасы. Модель тест жиынында жоғары сапа көрсетті: accuracy 0,958 (143 бақылаудың 137-сі дұрыс жіктелді), F1 = 0,967, ROC-AUC = 0,9949. Яғни түсіндірілетін модельдің өзі сенімді жұмыс істейді, ал бұл түсіндіру әдістерін салыстыру үшін қажетті алғышарт: нашар модельдің маңыздылық рейтингі туралы айтудың мәні шамалы. Бір жағдайды алдын ала атап кетейік: AUC бірге осыншама жақын болғанда, сапаның одан әрі төмендеуіне орын аз қалады, ал тест жиынының көлемі де шағын. Бұл permutation importance мәндеріне әсер етеді (төменде қараңыз).

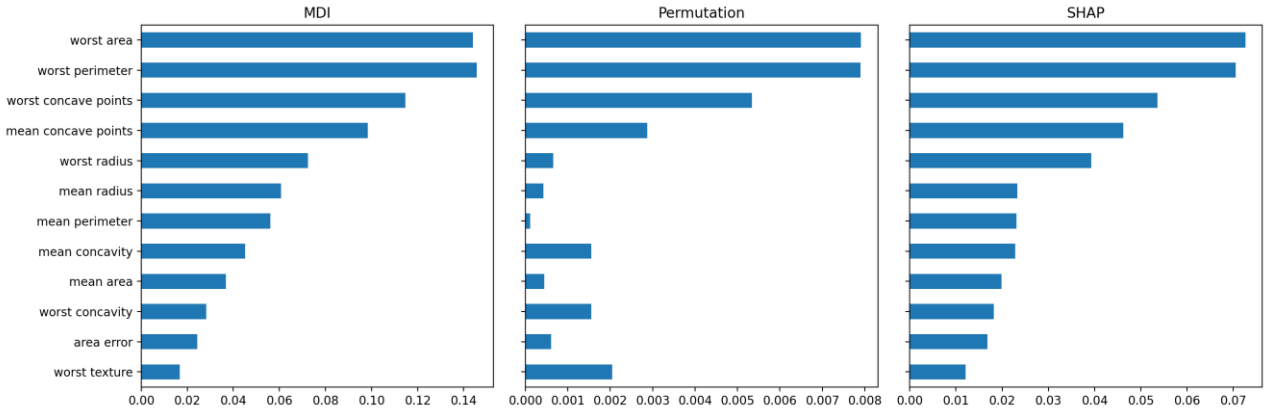
Белгілер арасындағы корреляция. Дерек жиынындағы 30 белгінің арасынан $|r| > 0,9$ болатын 21 жұп табылды. Ең күшті он жұптың бәрінде $|r| \geq 0,969$: mean radius – mean perimeter (0,998), worst radius – worst perimeter (0,994), mean radius – mean area (0,987), mean perimeter – mean area (0,987), worst radius – worst area (0,984), worst perimeter – worst area (0,978), radius error – perimeter error (0,973), mean perimeter – worst perimeter (0,970), mean radius – worst radius (0,970), mean perimeter – worst radius (0,969). Радиус, периметр және ауданның орташа (mean) мен ең үлкен (worst) нұсқалары өзара тығыз байланысқан жұптар тізбегін құрайды, яғни модельге кемінде алты белгі түрінде, мәні жағынан, негізінен «ядроның көлемі» туралы бір ақпарат беріліп тұр. Мұның әдістерге әсерін төменде көреміз.

Маңыздылық рейтингтері. 1-кестеде SHAP бойынша алғашқы он үш белгінің үш әдіс бойынша мәндері мен реттік орны (жақшада) келтірілген, ал 1-суретте алғашқы он екі белгінің мәндері көрсетілген.

1-кесте. Белгілердің маңыздылығы және рейтингі (жақшада), негізгі бөліну (random_state = 42)

Белгі	MDI	Permutation (ROC-AUC)	SHAP (орташа |SHAP|)
worst area	0,1441 (2)	0,0079 (1)	0,0727 (1)
worst perimeter	0,1457 (1)	0,0079 (2)	0,0705 (2)
worst concave points	0,1146 (3)	0,0053 (3)	0,0536 (3)

Белгі	MDI	Permutation (ROC-AUC)	SHAP (орташа |SHAP|)
mean concave points	0,0983 (4)	0,0029 (4)	0,0462 (4)
worst radius	0,0724 (5)	0,0006 (10)	0,0393 (5)
mean radius	0,0607 (6)	0,0004 (15)	0,0233 (6)
mean perimeter	0,0560 (7)	0,0001 (26)	0,0231 (7)
mean concavity	0,0452 (8)	0,0016 (6)	0,0228 (8)
mean area	0,0368 (9)	0,0004 (13)	0,0198 (9)
worst concavity	0,0282 (10)	0,0016 (7)	0,0182 (10)
area error	0,0243 (11)	0,0006 (11)	0,0168 (11)
worst texture	0,0167 (13)	0,0020 (5)	0,0121 (12)
mean texture	0,0152 (15)	0,0012 (8)	0,0100 (13)



1-сурет. Үш әдіс бойынша белгілердің маңыздылығы (алғашқы 12 белгі, SHAP бойынша реттелген)

Үш әдіс те алғашқы төрт орынға бірдей белгілерді қояды: worst area, worst perimeter, worst concave points және mean concave points. MDI-да бірінші екі орын ауысады (worst perimeter бірінші), бірақ айырмашылық өте аз (0,1457 және 0,1441). Бұл белгілердің екеуі «көлем» тобына, екеуі «ойыс нүктелер» тобына жатады, яғни модель шешімін көбіне ядроның көлемі мен контурының ойыстығына негіздейді. Алшақтық ортасынан басталады. Көлем кластерінің мүшелері (worst radius, mean radius, mean perimeter) MDI мен SHAP бойынша 5–7-орындарда, ал permutation бойынша 10-, 15- және 26-орындарда тұр. Керісінше, текстура белгілері permutation бойынша жоғары көтеріледі: worst texture бесінші, mean texture сегізінші орында, ал SHAP бойынша олар 12–13-орындарда. MDI мен SHAP арасында тек жекелеген ауытқулар бар, мысалы, mean compactness MDI бойынша 12-орында, SHAP бойынша 19-орында.

MDI оқыту жиынында, ал permutation мен SHAP тест жиынында есептелгенін ескерткен жөн. Модель оқыту деректеріне шамадан тыс бейімделген болса, бұл рейтингтер арасында айырмашылық тудырар еді. Деректері әртүрлі болса да, MDI мен SHAP-тың өте жақын болуы тест жиынындағы жоғары сапамен (AUC = 0,9949) бірге бұл жерде мұндай қауіптің үлкен еместігіне сәйкес келеді. Алайда бұл тек осы деректер мен осы модельге қатысты бақылау: басқа жиындарда, әсіресе қайта оқытуға бейім модельдерде, жағдай басқаша болуы мүмкін.

Келісім өлшемдері. Рейтингтердің сәйкестігінің сандық көрсеткіштері 2-кестеде берілген. Негізгі бөлінуде MDI мен SHAP арасындағы келісім өте жоғары: Спирмен $\rho = 0,974$, Кендалл $\tau = 0,894$, ең маңызды бес белгі толық сәйкес келеді. Permutation importance-тың SHAP-пен келісімі едәуір төмен ($\rho = 0,732$; $\tau = 0,566$; top-5 бойынша төрт белгі ортақ), MDI-

мен келісімі ұқсас деңгейде (ρ = 0,684; τ = 0,525; төрт ортақ белгі). Егер зерттеуді осы бір бөлінумен шектесек, «үш әдіс негізінен келісіп тұр, permutation сәл ығысқан» деген қорытынды жасалар еді.

Кендалл коэффициентін оқуды жеңілдету үшін мынаны айтуға болады. Тең рангілерді елемесек, τ мәні бойынша екі рейтингте бірдей ретпен тұрған жұптардың үлесі (1 + τ)/2 болады. Белгілердің 435 жұбының (30 белгіден) τ = 0,880 кезінде шамамен 94 %-ы MDI мен SHAP бойынша бірдей ретпен тұр, ал permutation мен SHAP үшін τ = 0,278 кезінде бұл үлес шамамен 64 %-ға ғана тең, кездейсоқ рейтингтерде ол 50 % болар еді. Top-5 көрсеткішіне де ұқсас салыстыру қолайлы: 30 белгіден кездейсоқ таңдалған екі бестік орта есеппен 25/30 ≈ 0,83 белгі бойынша қиылысар еді, ал біз permutation үшін 2,85 алдық. Яғни permutation рейтингі кездейсоқтан әлдеқайда жақсы, бірақ басқа әдістермен жеткілікті келісіп тұрған жоқ.

2-кесте. Маңыздылық рейтингтерінің келісімі

Әдістер жұбы	**Негізгі бөліну (random_state = 42)**			**20 қайталау, орташа ± ауытқу**		
	ρ	**τ**	**top-5**	**ρ**	**τ**	**top-5**
MDI – SHAP	0,974	0,894	5	0,973 ± 0,009	0,880 ± 0,024	5,00 ± 0,00
Permutation – SHAP	0,732	0,566	4	0,358 ± 0,473	0,278 ± 0,359	2,85 ± 1,60
MDI – Permutation	0,684	0,525	4	0,325 ± 0,477	0,250 ± 0,355	2,85 ± 1,60

Бірақ 20 қайталау басқа сурет көрсетеді. MDI мен SHAP арасындағы келісім сақталады әрі өте тұрақты (ρ = 0,973 ± 0,009; τ = 0,880 ± 0,024), ал top-5 барлық қайталауда толық сәйкес келеді. Permutation importance үшін орташа келісім айтарлықтай төмен және шашыраңқы: SHAP-пен ρ = 0,358 ± 0,473, MDI-мен 0,325 ± 0,477, top-5 бойынша орта есеппен 2,85 ± 1,60 ортақ белгі. Негізгі бөлінудегі ρ = 0,732 орташадан жоғары, бірақ шашыраңқылық ауқымынан шықпайды (орташадан шамамен 0,8 ауытқуға ғана жоғары). Яғни ол «сәтті» бөлінулердің бірі болған және оны типтік деп қабылдауға болмайды.

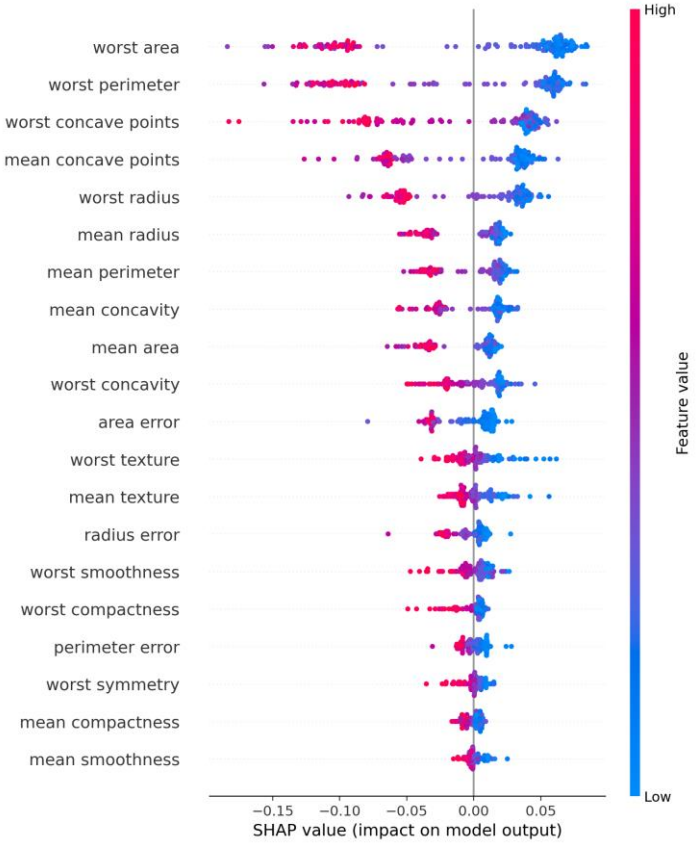
Ішкі тұрақтылық. 3-кестедегі көрсеткіштер бұл бақылауды толықтырады. MDI (0,949 ± 0,016) мен SHAP (0,951 ± 0,015) рейтингтері әртүрлі бөліністерде оқытылған модельдер арасында да бір-біріне өте ұқсас, ал permutation importance-тың ішкі тұрақтылығы тек 0,257 ± 0,354. Бұл нәтиже маңызды: әдістің басқа әдістермен төмен келісімі оның жүйелі түрде басқаны көрсетуімен ғана емес, өлшеудің өзі шулы болуымен де байланысты болуы мүмкін. SHAP да дәл сол модельдер мен тест жиындарында есептелген, бірақ тұрақты болып шықты, сондықтан тек деректің өзгеруі permutation тұрақсыздығын түсіндіре алмайды.

3-кесте. Әр әдістің ішкі тұрақтылығы (20 рейтингтің барлық жұптары бойынша Спирмен коэффициентінің орташасы)

Әдіс	**Орташа ± ауытқу**
MDI	0,949 ± 0,016
Permutation importance	0,257 ± 0,354
SHAP	0,951 ± 0,015

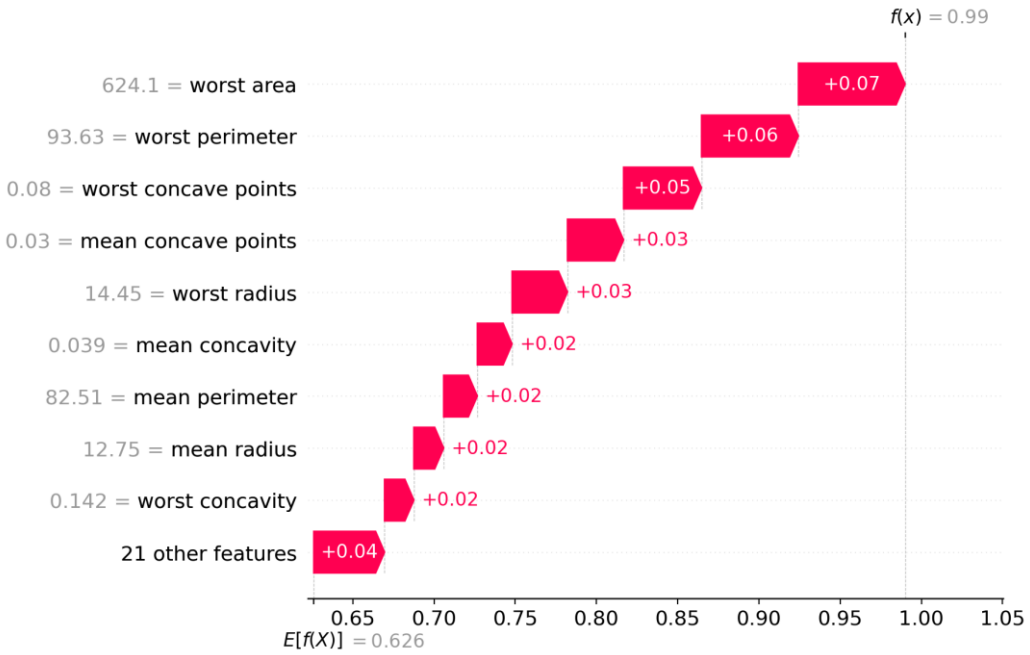
Спирмен коэффициентін 30 белгінің барлығы бойынша есептегенде, төменгі бөліктегі, мәні шамалы белгілердің реті де есепке кіреді. Permutation мәндері ол жерде 10^{-4} шамасында, кейбірі тіпті теріс (concavity error үшін шамамен $-3 \cdot 10^{-5}$), сондықтан ρ-дің төмендігінің бір бөлігі осы шудан болуы мүмкін. Top-5 көрсеткіші бұл әсерден таза, бірақ ол да орта есеппен 5 белгінің тек 2,85-ін ғана береді.

Жергілікті түсіндірме. SHAP-тың артықшылығы — түсіндірмені жеке бақылау деңгейінде көрсете алуында. 2-суреттегі жалпы көрініс (summary plot) бойынша жетекші белгілердің жоғары мәндері қатерсіздік ықтималдығын төмендетеді, ал төмен мәндері арттырады. Мысалы, worst area үшін төмен мәндер қатерсіздік ықтималдығына шамамен +0,05…+0,08 қосып, тығыз топталады, ал жоғары мәндердің әсері кеңірек шашыраған (шамамен −0,05-тен −0,18-ге дейін). Бұл әсердің сызықтық емес екенін көрсетуі мүмкін. Мұны клиникалық тұрғыдан түсінікті заңдылық деп қабылдауға болады: ядро неғұрлым үлкен және контуры ойыс болса, түзіліс қатерлі класқа жақынырақ. Тек оң класс қатерсіз түзіліс екенін ұмытпау керек, әйтпесе белгілердің бағытын кері оқып қоюға болады.



2-сурет. SHAP мәндерінің жалпы көрінісі (summary plot), тест жиыны

Жеке бақылау үшін (3-сурет, тест жиынының бірінші бақылауы) модель қатерсіздік ықтималдығын 0,99 деп бағалады, ал базалық мән E[f(X)] = 0,626. Жетекші тоғыз белгінің бәрі болжамды жоғарылатады: worst area (+0,07), worst perimeter (+0,06), worst concave points (+0,05), mean concave points (+0,03), worst radius (+0,03), ал mean concavity, mean perimeter, mean radius және worst concavity әрқайсысы шамамен +0,02 қосады; қалған 21 белгінің жиынтық үлесі +0,04. Жалпы өсімнің (0,99 − 0,626 = 0,364) шамамен 0,20-сін көлем тобындағы бес белгі (worst area, worst perimeter, worst radius, mean perimeter, mean radius) бөліседі. Суреттегі мәндер екі ондық белгіге дейін дөңгелектелген, сондықтан қосындылар шамамен ғана сәйкес келеді. Мұндағы негізгі бақылау басқа: бір ақпарат бірнеше белгіге бөлінген, сондықтан олардың жеке үлестерін тәуелсіз дәлел ретінде қосып оқуға болмайды.



3-сурет. Тест жиынының бірінші бақылауы үшін SHAP үлестері (waterfall)

Алшақтықтың мүмкін себептері. Біздің деректер әдістердің неге алшақтайтынын тікелей көрсетпейді, сондықтан төмендегі үш түсіндірме болжам ретінде беріледі және бұл жұмыста бір-бірінен ажыратылған жоқ.

Біріншісі — корреляцияланған белгілердің өтеуі. Көлем кластерінің белгілерін (worst radius, mean radius, mean perimeter, mean area) араластырғанда, кластердің қалған мүшелері ақпаратты сақтап тұрады, сондықтан модель сапасы аз төмендейді және permutation бұл белгілерді маңызсыз етіп көрсетеді. MDI мен SHAP үлесті бірнеше белгіге бөліп береді, сондықтан олардың рейтингі жоғары. Бұл түсіндірме 1-кестедегі ығысумен (mean perimeter 7-орыннан 26-орынға түседі) үйлеседі. Сонымен бірге ол толық емес: сол кластердің worst area және worst perimeter мүшелері permutation бойынша бірінші екі орында тұр. Мүмкін, кластердің ішінде ағаштар кейбір өкілдерге көбірек сүйенеді, бірақ біз мұны тексерген жоқпыз. Белгілерді топтап, тұтас араластыру бұл сұраққа жауап берер еді. Біздің жағдайда көлем кластері permutation бойынша төмен бағаланды; әдебиетте корреляцияланған белгілердің бағасы бұрмалануы мүмкін екені көрсетілген , бірақ бұрмалаудың бағыты жағдайға байланысты болуы мүмкін, сондықтан біздегі бағытты алдын ала болжауға болмайды. Тағы бір ескерту: араластыру деректерде кездеспейтін комбинациялар жасайды, ал модель мұндай аймақта сенімсіз болуы мүмкін .

Екіншісі — өлшеу шуы. AUC = 0,9949 болғанда, ол 1-ге дейін небәрі 0,005 шамасында жетпейді, ал permutation-ның ең үлкен әсері (≈ 0,008) сол ретпен бірдей. Тест жиыны шағын (143 бақылау), сондықтан бірнеше бақылаудың рет-ретін ауыстырудың өзі AUC-ты өзгертіп, рейтингтің төменгі бөлігін кездейсоқ етеді. Бұл ішкі тұрақтылықтың төмендігімен (0,257) сәйкес келеді. Сезімтал метрикамен (мысалы, ықтималдықтың квадраттық қатесімен) қайта есептеу осы болжамды тексерудің қарапайым жолы болар еді.

Үшіншісі — MDI мен SHAP келісімінің өзі күмән тудырады. Екеуі де бір ағаштардың құрылымынан және оқыту деректерінің ағаштағы таралуынан есептеледі, сондықтан олардың сәйкестігі тәуелсіз екі өлшемнің бір-бірін растауы емес, ортақ деректік көздің белгісі болуы мүмкін. Нақты деректерде белгілердің «шынайы» маңыздылығы белгісіз, сондықтан қай әдістің дұрыс екенін айта алмаймыз: біз тек олардың бір-бірімен қаншалықты келісетінін өлшедік. Мұны шешу үшін маңыздылығы алдын ала белгілі синтетикалық деректер қажет.

Әдістердің мүмкіндіктері. Рейтингтің сәйкестігінен бөлек, әдістер берер ақпараттың түрі де әртүрлі. MDI қосымша есептеуді талап етпейді, оқыту барысында алынады, бірақ тек оқыту жиынына байланысты және белгінің әсер бағытын көрсетпейді. Permutation кез келген модельге қолданылады және нақты метриканың төмендеуі түрінде түсіндіріледі, алайда бұл

кездейсоқ араластыруға тәуелді, нәтижесі қайталауға байланысты өзгереді, ал оның сенімділігі тест жиынының көлеміне байланысты. SHAP жергілікті түсіндірме береді және әсер бағытын көрсетеді (2- және 3-суреттер), бірақ есептеу жағынан қымбат әрі есептеу режиміне байланысты болжамдарға сүйенеді. Сондықтан бір әдісті екіншісінен «жақсы» деп атаудың орнына, олардың қандай сұраққа жауап беретінін анықтап алған дұрыс.

Алшақтықтың практикалық мәні. Алшақтықтың мәні қолданушының сұрағына байланысты. Мақсат — ең маңызды бірнеше белгіні атау болса, біздің жағдайда үш әдіс те бірдей төрт белгіге келіседі, және бұл тізімге сенімді қарауға болады. Мақсат — белгілерді іріктеу немесе тізімнің ортасындағы белгілерді алып тастау болса, әдісті таңдау нәтижені түбегейлі өзгертеді: mean perimeter MDI мен SHAP бойынша жетінші, ал permutation бойынша 26-орында, сондықтан permutation-ға сүйенген зерттеуші оны бірден алып тастар еді. Домен маманына түсіндіргенде де әдістің жауабын нақты тұжырымдау керек: «белгі модель шешіміне көп қатысады» (MDI, SHAP) және «белгісіз модель сапасы айтарлықтай төмендейді» (permutation) бір нәрсе емес. Сондықтан есептерде маңыздылық мәнін ғана емес, оның қандай мағынада алынғанын да көрсету қажет.

Шектеулер. Зерттеу бір модельмен (кездейсоқ орман, әдепкі гиперпараметрлер) және бір дерек жиынымен шектелген. Корреляцияланған белгілері бар жиын әдейі таңдалды, сондықтан алшақтық деңгейін басқа жиындарға тікелей көшіруге болмайды. Тест жиыны шағын (143 бақылау). Тұрақтылық талдауы 20 қайталаумен шектелген, сондықтан ауытқулардың өздері де шамамен ғана бағаланған. Бөлінулер бір деректен жасалғандықтан, олардың оқыту жиындары қиылысады және қайталаулар толық тәуелсіз емес, демек ауытқу нақты белгісіздікті аз бағалауы мүмкін. Permutation importance тек ROC-AUC бойынша есептелді. SHAP-тың path-dependent нұсқасы қолданылды, интервенциялық нұсқасы қарастырылған жоқ, ал бұл таңдау корреляцияланған белгілерде нәтижені өзгертуі мүмкін. Бұл ескертулер нәтижені жарамсыз етпейді, бірақ қорытындыны осы шеңберде оқуды талап етеді.

Қорытынды

Кездейсоқ орман моделінің шешімдері үш әдіспен талданып, олардың глобалды рейтингтері салыстырылды. Алғашқы төрт белгі (worst area, worst perimeter, worst concave points, mean concave points) барлық әдісте бірдей, ал алшақтық рейтингтің ортасында, корреляцияланған көлем белгілері тобында басталады. MDI мен SHAP рейтингтері өте жақын ($\rho = 0{,}973 \pm 0{,}009$) және тұрақты, ал permutation importance олармен нашар келіседі ($\rho \approx 0{,}36$) әрі өзі де шашыраңқы (ішкі тұрақтылық 0,257). Бір бөлінудің нәтижесі келісімді шынайыдан жоғары көрсетті. Алшақтықтың себептері бұл жұмыста тікелей тексерілген жоқ, ал ұсынылған түсіндірмелер (корреляция, өлшеу шуы, әдістердің ортақ дереккөзі) келесі эксперименттерде ажыратылуы тиіс болжамдар болып қала береді.

Практикалық тұрғыдан үш нәрсені айтуға болады. Біріншіден, белгілер маңыздылығының бір рейтингін қорытынды ретінде беру қауіпті: оның бөлінуге тәуелділігін көрсететін қайталау қажет. Екіншіден, әдістің атын көрсету жеткіліксіз, оның нақты нұсқасын (қай деректе, қандай метрикамен есептелгенін) жазу керек, себебі әртүрлі әдістер әртүрлі сұраққа жауап береді. Үшіншіден, корреляцияланған белгілер болса, олардың жеке рейтингін тәуелсіз дәлел ретінде оқуға болмайды, мұндай жағдайда белгілерді топтап талдаған орынды.

Одан әрі зерттеу бағыттары: permutation importance-ты сезімтал метрикамен және корреляцияланған белгілер тобымен қайталау; басқа дерек жиындары мен басқа модельдерді (мысалы, градиенттік бустинг) қарастыру; SHAP-тың интервенциялық нұсқасын салыстыру; маңыздылығы алдын ала белгілі синтетикалық деректерде әдістердің дұрыстығын тексеру.

Әдебиеттер:

1. Barredo Arrieta A., Díaz-Rodríguez N., Del Ser J., et al. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI // Information Fusion. 2020. Vol. 58. P. 82–115. https://doi.org/10.1016/j.inffus.2019.12.012

2. Linardatos P., Papastefanopoulos V., Kotsiantis S. Explainable AI: A review of machine learning interpretability methods // Entropy. 2021. Vol. 23, No. 1. Art. 18. https://doi.org/10.3390/e23010018

3. Dwivedi R., Dave D., Naik H., et al. Explainable AI (XAI): Core ideas, techniques, and solutions // ACM Computing Surveys. 2023. Vol. 55, No. 9. Art. 194. https://doi.org/10.1145/3561048

4. Lipton Z.C. The mythos of model interpretability // Communications of the ACM. 2018. Vol. 61, No. 10. P. 36–43. https://doi.org/10.1145/3233231

5. Doshi-Velez F., Kim B. Towards a rigorous science of interpretable machine learning // arXiv preprint arXiv:1702.08608. 2017.

6. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead // Nature Machine Intelligence. 2019. Vol. 1. P. 206–215. https://doi.org/10.1038/s42256-019-0048-x

7. Breiman L. Random forests // Machine Learning. 2001. Vol. 45, No. 1. P. 5–32. https://doi.org/10.1023/A:1010933404324

8. Louppe G., Wehenkel L., Sutera A., Geurts P. Understanding variable importances in forests of randomized trees // Advances in Neural Information Processing Systems 26 (NIPS 2013). 2013. P. 431–439.

9. Fisher A., Rudin C., Dominici F. All models are wrong, but many are useful: Learning a variable's importance by studying an entire class of prediction models simultaneously // Journal of Machine Learning Research. 2019. Vol. 20, No. 177. P. 1–81.

10. Shapley L.S. A value for n-person games // Contributions to the Theory of Games, Vol. II. Princeton: Princeton University Press, 1953. P. 307–317.

11. Lundberg S.M., Lee S.-I. A unified approach to interpreting model predictions // Advances in Neural Information Processing Systems 30 (NIPS 2017). 2017. P. 4765–4774.

12. Lundberg S.M., Erion G., Chen H., et al. From local explanations to global understanding with explainable AI for trees // Nature Machine Intelligence. 2020. Vol. 2. P. 56–67. https://doi.org/10.1038/s42256-019-0138-9

13. Strobl C., Boulesteix A.-L., Zeileis A., Hothorn T. Bias in random forest variable importance measures: Illustrations, sources and a solution // BMC Bioinformatics. 2007. Vol. 8. Art. 25. https://doi.org/10.1186/1471-2105-8-25

ИССЛЕДОВАНИЕ МЕТОДОВ ОЦЕНКИ ИНТЕРПРЕТИРУЕМОСТИ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ: СРАВНЕНИЕ FEATURE IMPORTANCE И SHAP

[1]Жолшиева А.З., [2]Мусабекова Б.С., [3]Аббаз Н. Б.

[1]Старший преподаватель кафедры IT и цифровых технологий, магистр
Университет имени Ж.А. Ташенева, г. Шымкент
almira82nur@gmail.com, https://orcid.org/0009-0007-4595-2602
[2]Преподаватель кафедры IT и цифровых технологий, магистр
Университет имени Ж.А. Ташенева, г. Шымкент
musabekovab98@gmail.com, https://orcid.org/0009-0003-4519-3563
[3]Преподаватель кафедры IT и цифровых технологий, магистр
Университет имени Ж.А. Ташенева, г. Шымкент
abbaznurislam@gmail.com https://orcid.org/0009-0007-4525-0846

Аннотация. В статье сопоставляются три способа оценки важности признаков, объясняющих решения модели случайного леса: среднее снижение неоднородности (MDI), перестановочная важность (permutation importance) и SHAP на основе значений Шепли. Эксперимент выполнен на наборе Wisconsin Diagnostic Breast Cancer (569 наблюдений, 30

признаков); на тестовой выборке модель показала ROC-AUC = 0,9949. Согласованность рейтингов оценивалась коэффициентами Спирмена и Кендалла, пересечением пяти наиболее важных признаков и устойчивостью при 20 повторениях. Рейтинги MDI и SHAP оказались очень близкими (ρ = 0,973 ± 0,009), тогда как перестановочная важность плохо согласуется с ними (ρ = 0,358 ± 0,473) и нестабильна сама по себе (внутренняя устойчивость 0,257). Расхождения сосредоточены в кластере коррелированных признаков: в наборе 21 пара с |r| > 0,9. Показано, что результат единичного разбиения может завышать согласие методов. Исследование ограничено одной моделью и одним набором данных.

Ключевые слова: объяснимый искусственный интеллект; SHAP; важность признаков; случайный лес; перестановочная важность; ранговая корреляция.

A STUDY OF METHODS FOR ASSESSING THE INTERPRETABILITY OF MACHINE LEARNING MODELS: COMPARING FEATURE IMPORTANCE AND SHAP

[1]Zholshieva A.Z., [2]Musabekova B.S., [3]Abbaz N.B.
[1]Senior Lecturer of the Department of IT and Digital Technologies, Master's degree
Zh.A. Tashenev University, Shymkent
almira82nur@gmail.com, https://orcid.org/0009-0007-4595-2602
[2]Lecturer of the Department of IT and Digital Technologies, Master's degree
Zh.A. Tashenev University, Shymkent
musabekovab98@gmail.com, https://orcid.org/0009-0003-4519-3563
[3]Lecturer of the Department of IT and Digital Technologies, Master's degree
Zh.A. Tashenev University, Shymkent
abbaznurislam@gmail.com https://orcid.org/0009-0007-4525-0846

Abstract. The paper compares three ways of assessing the importance of features that explain the decisions of a random forest model: mean decrease in impurity (MDI), permutation importance and SHAP based on Shapley values. The experiment used the Wisconsin Diagnostic Breast Cancer dataset (569 observations, 30 features); the model reached a test ROC-AUC of 0.9949. Agreement between the rankings was measured with Spearman and Kendall coefficients, the overlap of the five most important features, and stability across 20 repetitions. The MDI and SHAP rankings were very close (ρ = 0.973 ± 0.009), whereas permutation importance agreed with them poorly (ρ = 0.358 ± 0.473) and was unstable on its own (internal stability 0.257). The disagreement is concentrated in a cluster of correlated features: 21 feature pairs have |r| > 0.9. A single train–test split was found to overstate the agreement between the methods. The study is limited to one model and one dataset.

Key words: explainable AI; SHAP; feature importance; random forest; permutation importance; rank

UDC 378:004
IRSTI 14.35.09

USING LEARNING ANALYTICS TO PERSONALIZE PROGRAMMING EDUCATION

[1]Borankulov B.A., [2]Nakhipova V.I., [3]Kuatbek N.B.
[1]https://orcid.org/0009-0009-8168-948X
master of technical sciences, lecturer at the Department of «IT and Digital Technologies», Tashenev University, Shymkent, Kazakhstan
borankulovb@gmail.com

https://orcid.org/0000-0002-4248-8943
[2]PhD, senior lecturer at the Department of «IT and Digital Technologies»,
Tashenev University, Shymkent, Kazakhstan
nakhipovavenera@mail.ru
https://orcid.org/0009-0003-6725-2245
[3]master of pedagogical sciences, senior lecturer at the Department of «IT and Digital Technologies»,
Tashenev University, Shymkent, Kazakhstan
tlgtmrv@gmail.com

Abstract. Programming courses leave an unusually detailed record of learning: compilations, failed tests, revisions and hint requests. Yet research on learning analytics in programming has concentrated on predicting course outcomes, and much less of it shows how analytical results become pedagogical decisions or whether those decisions improve learning. The conceptual study, grounded in an integrative review of research in learning analytics, computing education, intelligent tutoring and the ethics of educational data, examines how learning analytics can personalize programming instruction in higher education.

The analysis distinguishes programming-specific evidence that supports inferences about competence-test-case outcomes, error resolution, revision sequences, learners' explanations of code- from ambiguous behavioural traces such as time on task and platform activity, and compares analytical methods by purpose, interpretability and pedagogical usefulness. From that analysis, the article proposes a seven-stage framework linking learner and task data, data preparation, learner-state estimation, pedagogical decision-making, personalized intervention, evaluation of subsequent learning and a feedback loop that revises both learner estimates and decision rules. Instructors remain in the loop for consequential or ambiguous decisions, and privacy, governance, fairness and transparency act as safeguards throughout. The framework has not yet been validated empirically.

Keywords: learning analytics, personalized learning, programming education, learner modelling, knowledge tracing, formative feedback, human-in-the-loop.

Introduction

Look at the submission log from an introductory programming assignment. One student has submitted forty times in twenty minutes, and each version differs from the previous one by a single character. Another submitted twice and passed every test on the second attempt. A third stopped after a run-time error inside a loop and did not come back. These patterns do not explain themselves. The gap between abundant digital traces and knowing what they mean for the next teaching move is where learning analytics in programming education has to prove its value.

Programming remains hard to learn. Multi-national studies found that many students completing a first course could not reliably trace short code fragments (Lister et al., 2004). Reviews locate the difficulty in interacting layers of knowledge: the notional machine, the notation, solution patterns, and the practice of testing and debugging (Robins et al., 2003). Misconceptions about variables, conditions, loops and functions are persistent and unevenly distributed (Qian & Lehman, 2017). A single sequence of tasks may consolidate understanding for one student while exposing a missing prerequisite in another.

Learning analytics is the measurement, collection, analysis and reporting of data about learners and their contexts in order to understand and improve learning (Siemens & Baker, 2012). Programming suits this approach because student work is executable and can be checked automatically, and research has produced models predicting performance from early programming activity (Ahadi et al., 2015; Hellas et al., 2018). Yet reviews observe that this work rarely closes the loop: studies of IDE-based analytics concentrate on collecting and analysing data far more than on designing and evaluating interventions (Hundhausen et al., 2017), and evidence that learning analytics improves learning outcomes appears in only a small share of published studies (Viberg et al., 2018). Personalization adds further uncertainty.

The term is used inconsistently and its evidence base is mixed (Bernacki et al., 2021); some popular forms, such as matching instruction to learning styles, lack empirical support (Pashler et al., 2008); and feedback, its most common vehicle, can lower performance when it directs attention away from the task (Kluger & DeNisi, 1996). Collecting more data does not by itself produce better personalized teaching.

What remains missing is an explicit account of how programming traces should be interpreted in terms of competence, converted into timely and pedagogically justified personalization, and evaluated. The central argument: learning analytics becomes educationally meaningful when learner data are interpreted against a model of programming competencies and used to support decisions that teachers and learners can understand, question and revise. The aim is to develop and justify a conceptual framework for analytics-informed personalization in introductory university programming courses. Three research questions guide the analysis:

RQ1. Which learner-generated data are most informative about progress and difficulty in learning to program, and what can they not establish on their own?

RQ2. Which analytical methods and personalization mechanisms can turn these data into pedagogical decisions, and how should those decisions be divided between automated components and instructors?

RQ3. How should analytics-informed personalization be evaluated, and which ethical and practical conditions limit its implementation?

Methods

The work is conceptual, built on an integrative literature review rather than an empirical trial. An integrative design fits questions that cross fields with different vocabularies and study formats; it also suits the goal of explaining mechanisms instead of estimating a pooled effect. No PRISMA protocol structures the review, and no screening counts are reported.

Sources came from the author's familiarity with the core literature, keyword searches in general academic search engines, and backward tracing of references from major reviews. Search terms paired «learning analytics», «educational data mining», «knowledge tracing», «learner model» and «dashboard» with «programming», «novice programmers» and «CS1», and also with «personalized learning», «automated feedback», «hints» and «intervention». A source was kept if it was peer-reviewed or an official legal text, bore directly on a research question, and had traceable metadata. Systematic reviews and controlled evaluations received priority. Bibliographic metadata were checked in October 2026 against DOI records in Crossref and OpenAlex; for legal texts, they were checked against the official publication.

Claims from each source were coded under four headings: data and indicators; methods and learner models; interventions and outcomes; ethics and governance. Each claim was tagged by the evidence behind it-controlled intervention, observational association, predictive model, conceptual proposal, or review. The coded claims were then compared across sources and turned into design decisions for each stage of an analytics-to-instruction process.

The framework and the mappings in the tables are the author's proposals and hypotheses for empirical testing. They are not validated results.

Results

Programming-specific learner data

The first result addresses RQ1. Programming environments produce data at several grain sizes, from keystrokes and compilations to graded submissions and platform logs (Ihantola et al., 2015). Their value for personalization depends on how closely they are tied to a defined task and competency (Table 1).

Table 1 - Programming-learning data sources and their pedagogical interpretation

Data source	Possible interpretation	Personalization response	Limitations
Test-case results	Partial model of a concept when failures cluster on boundary or special cases	Feedback naming the failed behaviour; tracing exercise on the failing case	Diagnostic only if tests target concepts; passing is not understanding
Compilation and run-time errors	Difficulty with a construct; ineffective error resolution (repeated errors, long resolution time)	Construct-specific explanation; enhanced error message	Depends on compiler messages; frequency is not difficulty
Submission and revision histories	Incremental development, trial-and-error or stalled progress	Prompt to predict and test before resubmitting; teacher check-in if stalled	One pattern may reflect different strategies
Hint, feedback and AI-assistant use	Help avoidance, appropriate help-seeking or dependence	Stepwise reduction of support; unassisted check task	Assisted success overstates independent competence
Time on task and platform activity	Possible difficulty, disengagement or interruption	A question to the learner or a note to the teacher, not automatic adaptation	Cannot distinguish effort, confusion or offline work
Learner explanations and self-assessment	Conceptual understanding; calibration of self-assessment	Targeted correction of a misconception	Costly to collect; self-reports may be biased

Note: compiled by the author on the basis of Jadud (2006), Altadmri and Brown (2015), Carter et al. (2015), Aleven et al. (2016), Prather et al. (2023) and Gašević et al. (2015); interpretations and responses are the author's synthesis.

Code and its execution are the most direct evidence available. When tests are built around particular concepts, the pattern of failure can be diagnostic. A loop that handles typical inputs but breaks on the last element of a range points to a different problem than code that fails every test. Error data, however, are harder to read. Jadud's (2006) Error Quotient counts how often consecutive compilations repeat the same error, but large-scale analysis shows that the most frequent errors are not necessarily the ones that take longest to resolve (Altadmri & Brown, 2015). Error counts also reflect compiler-message quality (Becker et al., 2019). Revision histories say more about strategy than final result, and they predict performance (Carter et al., 2015), yet a rapid resubmission may mean guessing or a deliberate sequence of small tested steps.

Timing and generic platform activity are especially easy to over-interpret: time on task cannot separate effort from confusion or interruption, and analytics detached from learning theory can mislead (Gašević et al., 2015). Help-seeking data require similar caution, because students often avoid help or use it poorly (Aleven et al., 2016), and success with generative AI assistance may overstate independent competence (Prather et al., 2023).

A general rule emerges from this synthesis: an inference about competence should rest on evidence from tasks designed to elicit that competence, preferably from two converging sources; ambiguous traces should prompt a question rather than automatic adaptation.

The second result addresses RQ2. Descriptive and diagnostic analyses are simple and immediately usable. Aggregating test failures by concept, for example, can guide re-teaching and feedback design. Predictive models identify students likely to struggle, but reviews describe a methodologically heterogeneous literature (Hellas et al., 2018), and predictive relationships shift with instructional conditions. A model trained in one course may therefore misrepresent students in

another (Gašević et al., 2016). Prediction is not diagnosis: it does not show which concept is missing or which action would help. That is the step prescriptive analytics tries to supply (Susnjak, 2024). Learner models estimate mastery of specific knowledge components.

Bayesian Knowledge Tracing, developed for a programming tutor, updates the probability of mastery after each practice opportunity (Corbett & Anderson, 1994). Simpler logistic and item-response models are often competitive with more complex alternatives (Pelánek, 2017).

Explainable machine learning can expose why a model produced an output, although explanations may create unwarranted trust (Khosravi et al., 2022). The synthesis gives no support to the assumption that more sophisticated methods are inherently superior. For decisions teachers must understand and defend, a transparent model with adequate accuracy is often preferable.

Such estimates can inform several kinds of intervention. Automated feedback tools for programming mostly report what is wrong and less often how to proceed (Keuning et al., 2019). Feedback is most useful when it addresses the task, the process, and self-regulation (Hattie & Timperley, 2007).

Analytics can select feedback by failure pattern and history, and has been used to deliver instructor-written personalized messages at scale, with more positive student perceptions than in earlier cohorts (Pardo et al., 2019). Adaptive immediate feedback was associated with greater engagement and intention to persist in a controlled study with novice programmers (Marwan et al., 2020). Awareness interventions present analytics to people.

Reviews find limited evidence that student-facing dashboards improve learning (Matcha et al., 2020), while teacher-facing tools have a stronger basis. A real-time teacher awareness tool improved learning in an AI-supported classroom (Holstein et al., 2018), and teachers' engagement with predictive analytics was associated with better student outcomes (Herodotou et al., 2019). Generative AI assistants with guardrails now offer individualized explanations at low cost (Kazemitabaar et al., 2024), but their interaction data are weak evidence of independent competence (Denny et al., 2024).

The central result is a framework that integrates these findings (Figure 1). It adapts the learning analytics cycle (Clow, 2012) and the process model of IDE-based analytics (Hundhausen et al., 2017). Its human-in-the-loop mechanism comes from research on hybrid human-AI systems (Molenaar, 2022).

Three elements distinguish it: learner-state estimation is separated from pedagogical decision-making; every intervention has an evaluation stage defined in advance; and revision applies to decision rules, not only to learner estimates.

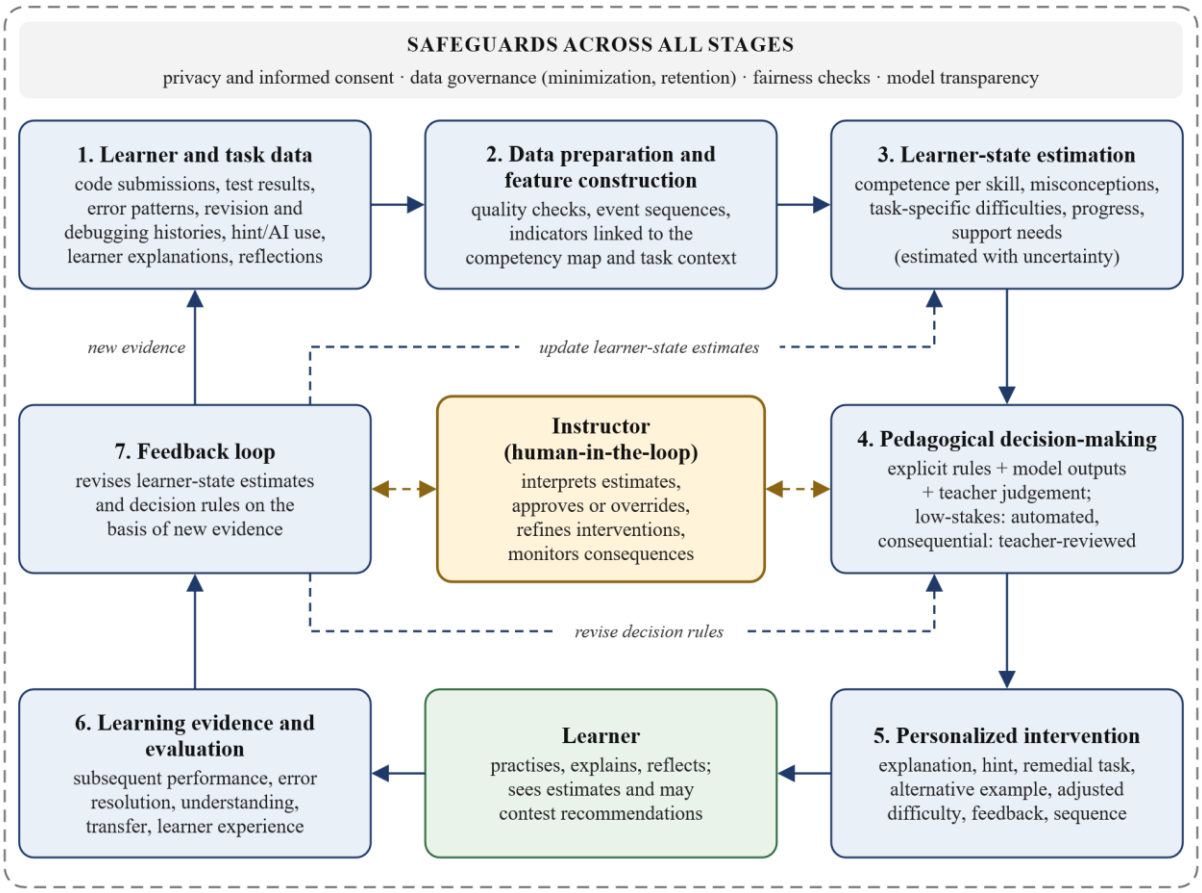


Figure 1 - Framework for analytics-informed personalization in programming education

Note: original conceptual framework developed by the author on the basis of the reviewed literature (in particular Clow, 2012; Hundhausen et al., 2017; Molenaar, 2022).

Stage 1 gathers learner and task data: submissions, test results, errors, revision histories, hint and assistant use, and learners' explanations, along with task context that gives these traces meaning.

Stage 2 checks data quality, orders event sequences, and builds indicators tied to the competency map. Only indicators with a defined pedagogical use survive this filtering.

Stage 3 estimates competence for each knowledge component, along with recurring misconceptions, task-specific difficulties, and support needs; uncertainty accompanies each estimate.

Stage 4 turns estimates into decisions through explicit rules, model outputs, and teacher judgement. Low-stakes, reversible decisions with clear evidence-say, choosing the next practice item-can be automated. Consequential decisions, or those resting on ambiguous evidence, go to the instructor.

Stage 5 implements the intervention and records both the evidence and the rule that triggered it.

Stage 6 evaluates later learning and separates assisted performance from independent success; error resolution, understanding, and transfer all belong in this evaluation.

Stage 7 closes the loop. New evidence updates learner estimates, while accumulated evidence about intervention effects revises the decision rules themselves.

The instructor interprets estimates, approves or overrides recommendations, and monitors consequences. Overrides are recorded and become evidence for revising rules. Learners can see their estimates and recommendations and may contest them-consistent with treating students as agents in analytics (Slade & Prinsloo, 2013). Privacy, data governance, fairness checks, and transparency apply at every stage. Table 2 illustrates the framework for common difficulties; its last column specifies in advance what evidence would show that an intervention helped.

Table 2 - Mapping learner difficulties to personalized interventions

Observed difficulty	Supporting evidence	Proposed intervention	Subsequent indicator of progress
Off-by-one errors in loops	Boundary-test failures; wrong prediction of the final iteration	Tracing table; completion task on loop bounds	Boundary tests passed unassisted in a new loop task
Confusing printing with returning a value	Return-value tests fail although printed output is correct	Worked example contrasting print and return; scaffolded function tasks	Return-based tests passed on new function tasks
Repeated unresolved compilation errors	Same error across consecutive compilations; long resolution time	Enhanced error explanation; short targeted practice	Fewer repetitions and faster resolution of that error type
Dependence on hints or AI assistance	Success only with high-level help; failure on comparable unassisted tasks	Stepwise reduction of support; reflection on help use	Success on unassisted tasks; declining hint level
Stalled progress or withdrawal	No activity after errors; missed deadlines; low confidence	Teacher contact to understand the cause before changing content	Resumed activity; completion of the next task

Note: proposed by the author; the interventions draw on Qian and Lehman (2017), Hattie and Timperley (2007), Aleven et al. (2016) and Becker et al. (2019).

Discussion

Three kinds of evidence in the literature are often conflated: predictive associations between behaviour and performance (Ahadi et al., 2015; Carter et al., 2015), controlled evaluations of specific tools (Holstein et al., 2018; Marwan et al., 2020), and institutional implementations or cohort comparisons (Herodotou et al., 2019; Pardo et al., 2019).

Taken together, they support a cautious conclusion. Analytics-informed personalization in programming is plausible and has worked in specific well-designed interventions. The general claim that learning analytics improves learning remains weakly supported (Viberg et al., 2018).

Correlations between activity and achievement do not show that interventions based on them cause better learning. The framework's evaluation stage is meant to make that distinction operational.

The division of decisions between automation and instructors is the author's proposal. Intelligent tutoring suggests that fine-grained automated adaptation works in well-defined tasks. Studies of teacher-facing tools show that teachers add value by interpreting analytics in context (Herodotou et al., 2019; Holstein et al., 2018). The arrangement assumes instructors have time to review referred cases. That assumption may not hold in large courses.

Ethical risks accompany continuous data collection. Learning analytics should treat students as agents rather than objects of measurement (Slade & Prinsloo, 2013). Checklists for trusted analytics stress legitimate purpose, consent, and anonymization (Drachsler & Greller, 2016).

For programming courses, data minimization follows: keystroke logging, for instance, should be justified by a specific pedagogical use. In Kazakhstan, personal data processing is governed by the Law «On Personal Data and Their Protection» (Law of the Republic of Kazakhstan No. 94-V, 2013), and institutions should confirm with legal advisers how it applies. Educational models can perform differently for different groups of students (Baker & Hawn, 2022), so decision rules should be audited for differential effects-for example, how often they route particular groups back to remedial units.

Further risks include labelling students as weak, surveillance that undermines autonomy, and unequal access to devices.

Analytics-informed personalization is therefore most likely to be useful when the course has an explicit competency map with tasks and tests tagged against it, when methods are interpretable, when instructors have time to review consequential decisions, and when learners are informed and involved. Evaluation should measure unassisted competence, conceptual understanding, debugging, transfer, and student experience, and check whether effects differ across groups.

The study is conceptual and its proposals are untested. The review was not exhaustive. Transfer of the cited evidence to universities in Kazakhstan cannot be assumed. Thresholds for decision rules require empirical calibration. Future research should first validate a competency map and concept-specific test suites for a specific course, then implement the framework in a design-based study, and finally compare alternative decision rules on unassisted competence, debugging, transfer, and self-regulation, with particular attention to future informatics teachers.

Conclusion

The article examined how learning analytics can personalize programming education. Its conclusions are narrower than the general promise of the field. For the first research question, the most informative evidence comes from concept-specific test outcomes, error resolution, revision sequences, and learners' explanations. Time on task and activity counts cannot by themselves establish effort or mastery.

That distinction matters because programming courses produce large volumes of trace data, and not all of it supports a defensible inference about competence.

For the second research question, transparent diagnostic methods and learner models are better suited to pedagogical decisions than opaque predictions. The proposed seven-stage framework separates estimation from decision-making. Only low-stakes decisions are automated; instructors remain in the loop for consequential ones. Every intervention should also be accompanied by evaluation indicators defined in advance, with privacy, governance, fairness, and transparency applied throughout.

The main contribution is the integration of these elements into a feedback process in which learner estimates and decision rules are both revised in response to evidence. For programming educators, this means designing diagnostic tests, treating ambiguous traces as prompts for inquiry, and distinguishing assisted from independent success. The framework remains a proposal and requires empirical testing. A design-based implementation in an introductory programming course would be a reasonable starting point.

References:

1. Ahadi, A., Lister, R., Haapala, H., & Vihavainen, A. (2015). Exploring machine learning methods to automatically identify students in need of assistance. In Proceedings of the Eleventh Annual International Conference on International Computing Education Research (pp. 121-130). ACM. https://doi.org/10.1145/2787622.2787717

2. Aleven, V., Roll, I., McLaren, B. M., & Koedinger, K. R. (2016). Help helps, but only so much: Research on help seeking with intelligent tutoring systems. International Journal of Artificial Intelligence in Education, 26(1), 205-223. https://doi.org/10.1007/s40593-015-0089-1

3. Altadmri, A., & Brown, N. C. C. (2015). 37 million compilations: Investigating novice programming mistakes in large-scale student data. In Proceedings of the 46th ACM Technical Symposium on Computer Science Education (pp. 522-527). ACM. https://doi.org/10.1145/2676723.2677258

4. Baker, R. S., & Hawn, A. (2022). Algorithmic bias in education. International Journal of Artificial Intelligence in Education, 32(4), 1052-1092. https://doi.org/10.1007/s40593-021-00285-9

5. Becker, B. A., Denny, P., Pettit, R., Bouchard, D., Bouvier, D. J., Harrington, B., Kamil, A., Karkare, A., McDonald, C., Osera, P.-M., Pearce, J. L., & Prather, J. (2019). Compiler error messages considered unhelpful: The landscape of text-based programming error message research. In

Proceedings of the Working Group Reports on Innovation and Technology in Computer Science Education (pp. 177-210). ACM. https://doi.org/10.1145/3344429.3372508

6. Bernacki, M. L., Greene, M. J., & Lobczowski, N. G. (2021). A systematic review of research on personalized learning: Personalized by whom, to what, how, and for what purpose(s)? Educational Psychology Review, 33(4), 1675-1715. https://doi.org/10.1007/s10648-021-09615-8

7. Carter, A. S., Hundhausen, C. D., & Adesope, O. (2015). The normalized programming state model: Predicting student performance in computing courses based on programming behavior. In Proceedings of the Eleventh Annual International Conference on International Computing Education Research (pp. 141-150). ACM. https://doi.org/10.1145/2787622.2787710

8. Clow, D. (2012). The learning analytics cycle: Closing the loop effectively. In Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (pp. 134-138). ACM. https://doi.org/10.1145/2330601.2330636

9. Corbett, A. T., & Anderson, J. R. (1994). Knowledge tracing: Modeling the acquisition of procedural knowledge. User Modeling and User-Adapted Interaction, 4(4), 253-278. https://doi.org/10.1007/BF01099821

10. Denny, P., Prather, J., Becker, B. A., Finnie-Ansley, J., Hellas, A., Leinonen, J., Luxton-Reilly, A., Reeves, B. N., Santos, E. A., & Sarsa, S. (2024). Computing education in the era of generative AI. Communications of the ACM, 67(2), 56-67. https://doi.org/10.1145/3624720

11. Drachsler, H., & Greller, W. (2016). Privacy and analytics: It's a DELICATE issue. A checklist for trusted learning analytics. In Proceedings of the Sixth International Conference on Learning Analytics & Knowledge (pp. 89-98). ACM. https://doi.org/10.1145/2883851.2883893

12. Gašević, D., Dawson, S., Rogers, T., & Gasevic, D. (2016). Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. The Internet and Higher Education, 28, 68-84. https://doi.org/10.1016/j.iheduc.2015.10.002

13. Gašević, D., Dawson, S., & Siemens, G. (2015). Let's not forget: Learning analytics are about learning. TechTrends, 59(1), 64-71. https://doi.org/10.1007/s11528-014-0822-x

14. Hattie, J., & Timperley, H. (2007). The power of feedback. Review of Educational Research, 77(1), 81-112. https://doi.org/10.3102/003465430298487

15. Hellas, A., Ihantola, P., Petersen, A., Ajanovski, V. V., Gutica, M., Hynninen, T., Knutas, A., Leinonen, J., Messom, C., & Liao, S. N. (2018). Predicting academic performance: A systematic literature review. In Proceedings Companion of the 23rd Annual ACM Conference on Innovation and Technology in Computer Science Education (ITiCSE 2018 Companion) (pp. 175-199). ACM. https://doi.org/10.1145/3293881.3295783

16. Herodotou, C., Rienties, B., Boroowa, A., Zdrahal, Z., & Hlosta, M. (2019). A large-scale implementation of predictive learning analytics in higher education: The teachers' role and perspective. Educational Technology Research and Development, 67(5), 1273-1306. https://doi.org/10.1007/s11423-019-09685-0

17. Holstein, K., McLaren, B. M., & Aleven, V. (2018). Student learning benefits of a mixed-reality teacher awareness tool in AI-enhanced classrooms. In Artificial intelligence in education: AIED 2018 (Lecture Notes in Computer Science, Vol. 10947, pp. 154-168). Springer. https://doi.org/10.1007/978-3-319-93843-1_12

18. Hundhausen, C. D., Olivares, D. M., & Carter, A. S. (2017). IDE-based learning analytics for computing education: A process model, critical review, and research agenda. ACM Transactions on Computing Education, 17(3), 1-26. https://doi.org/10.1145/3105759

19. Ihantola, P., Vihavainen, A., Ahadi, A., Butler, M., Börstler, J., Edwards, S. H., Isohanni, E., Korhonen, A., Petersen, A., Rivers, K., Rubio, M. Á., Sheard, J., Skupas, B., Spacco, J., Szabo, C., & Toll, D. (2015). Educational data mining and learning analytics in programming: Literature review and case studies. In Proceedings of the 2015 ITiCSE on Working Group Reports (pp. 41-63). ACM. https://doi.org/10.1145/2858796.2858798

20. Jadud, M. C. (2006). Methods and tools for exploring novice compilation behaviour. In Proceedings of the Second International Workshop on Computing Education Research (pp. 73-84). ACM. https://doi.org/10.1145/1151588.1151600

21. Kazemitabaar, M., Ye, R., Wang, X., Henley, A. Z., Denny, P., Craig, M., & Grossman, T. (2024). CodeAid: Evaluating a classroom deployment of an LLM-based programming assistant that balances student and educator needs. In Proceedings of the CHI Conference on Human Factors in Computing Systems (CHI '24). ACM. https://doi.org/10.1145/3613904.3642773

22. Keuning, H., Jeuring, J., & Heeren, B. (2019). A systematic literature review of automated feedback generation for programming exercises. ACM Transactions on Computing Education, 19(1), Article 3. https://doi.org/10.1145/3231711

23. Khosravi, H., Buckingham Shum, S., Chen, G., Conati, C., Tsai, Y.-S., Kay, J., Knight, S., Martinez-Maldonado, R., Sadiq, S., & Gašević, D. (2022). Explainable artificial intelligence in education. Computers and Education: Artificial Intelligence, 3, Article 100074. https://doi.org/10.1016/j.caeai.2022.100074

24. Kluger, A. N., & DeNisi, A. (1996). The effects of feedback interventions on performance: A historical review, a meta-analysis, and a preliminary feedback intervention theory. Psychological Bulletin, 119(2), 254-284. https://doi.org/10.1037/0033-2909.119.2.254

25. Law of the Republic of Kazakhstan No. 94-V. (2013, May 21). On personal data and their protection. https://adilet.zan.kz/eng/docs/Z1300000094

26. Lister, R., Adams, E. S., Fitzgerald, S., Fone, W., Hamer, J., Lindholm, M., McCartney, R., Moström, J. E., Sanders, K., Seppälä, O., Simon, B., & Thomas, L. (2004). A multi-national study of reading and tracing skills in novice programmers. ACM SIGCSE Bulletin, 36(4), 119-150. https://doi.org/10.1145/1044550.1041673

27. Marwan, S., Gao, G., Fisk, S., Price, T. W., & Barnes, T. (2020). Adaptive immediate feedback can improve novice programming engagement and intention to persist in computer science. In Proceedings of the 2020 ACM Conference on International Computing Education Research (pp. 194-203). ACM. https://doi.org/10.1145/3372782.3406264

28. Matcha, W., Uzir, N. A., Gašević, D., & Pardo, A. (2020). A systematic review of empirical studies on learning analytics dashboards: A self-regulated learning perspective. IEEE Transactions on Learning Technologies, 13(2), 226-245. https://doi.org/10.1109/TLT.2019.2916802

29. Molenaar, I. (2022). Towards hybrid human-AI learning technologies. European Journal of Education, 57(4), 632-645. https://doi.org/10.1111/ejed.12527

30. Pardo, A., Jovanovic, J., Dawson, S., Gašević, D., & Mirriahi, N. (2019). Using learning analytics to scale the provision of personalised feedback. British Journal of Educational Technology, 50(1), 128-138. https://doi.org/10.1111/bjet.12592

31. Pashler, H., McDaniel, M., Rohrer, D., & Bjork, R. (2008). Learning styles: Concepts and evidence. Psychological Science in the Public Interest, 9(3), 105-119. https://doi.org/10.1111/j.1539-6053.2009.01038.x

32. Pelánek, R. (2017). Bayesian knowledge tracing, logistic models, and beyond: An overview of learner modeling techniques. User Modeling and User-Adapted Interaction, 27(3-5), 313-350. https://doi.org/10.1007/s11257-017-9193-2

33. Prather, J., Denny, P., Leinonen, J., Becker, B. A., Albluwi, I., Craig, M., Keuning, H., Kiesler, N., Kohn, T., Luxton-Reilly, A., MacNeil, S., Petersen, A., Pettit, R., Reeves, B. N., & Savelka, J. (2023). The robots are here: Navigating the generative AI revolution in computing education. In Proceedings of the 2023 Working Group Reports on Innovation and Technology in Computer Science Education (pp. 108-159). ACM. https://doi.org/10.1145/3623762.3633499

34. Qian, Y., & Lehman, J. (2017). Students' misconceptions and other difficulties in introductory programming: A literature review. ACM Transactions on Computing Education, 18(1), 1-24. https://doi.org/10.1145/3077618

35. Robins, A., Rountree, J., & Rountree, N. (2003). Learning and teaching programming: A review and discussion. Computer Science Education, 13(2), 137-172. https://doi.org/10.1076/csed.13.2.137.14200

36. Siemens, G., & Baker, R. S. J. d. (2012). Learning analytics and educational data mining: Towards communication and collaboration. In Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (pp. 252-254). ACM. https://doi.org/10.1145/2330601.2330661

37. Slade, S., & Prinsloo, P. (2013). Learning analytics: Ethical issues and dilemmas. American Behavioral Scientist, 57(10), 1510-1529. https://doi.org/10.1177/0002764213479366

38. Susnjak, T. (2024). Beyond predictive learning analytics modelling and onto explainable artificial intelligence with prescriptive analytics and ChatGPT. International Journal of Artificial Intelligence in Education, 34(2), 452-482. https://doi.org/10.1007/s40593-023-00336-3

39. Viberg, O., Hatakka, M., Bälter, O., & Mavroudi, A. (2018). The current landscape of learning analytics in higher education. Computers in Human Behavior, 89, 98-110. https://doi.org/10.1016/j.chb.2018.07.027

БАҒДАРЛАМАЛАУҒА ОҚЫТУДЫ ДЕРБЕСТЕНДІРУДЕ ОҚУ АНАЛИТИКАСЫН ПАЙДАЛАНУ

[1]Боранкулов Б.А., [2]Қуатбек Н.Б., [3]Нахипова В.И.

[1]*https://orcid.org/0009-0009-8168-948X*

техника ғылымдарының магистрі, «IT және цифрлық технологиялар» кафедрасының оқытушысы, Ж.А.Ташенев атындағы университет,

Шымкент, Қазақстан

borankulovb@gmail.com

[2]*https://orcid.org/0009-0003-6725-2245*

педагогика ғылымдарының магистрі, «IT және цифрлық технологиялар» кафедрасының аға оқытушысы, Ж.А.Ташенев атындағы университет

tlgtmrv@gmail.com

[3]*https://orcid.org/0000-0002-4248-8943*

PhD, «IT және цифрлық технологиялар» кафедрасының аға оқытушысы, Ж.А.Тәшенев атындағы университет, Шымкент, Қазақстан

nakhipovavenera@mail.ru

Аңдатпа. Бағдарламалау курстары оқу үдерісінің бай цифрлық іздерін қалдырады: компиляциялар, сәтсіз тестер, кодты қайта өңдеу және кеңес сұрау. Алайда бұл саладағы оқу аналитикасы зерттеулері негізінен курс нәтижелерін болжауға бағытталған, ал талдау нәтижелерінің педагогикалық шешімдерге айналуы және олардың оқуға әсері сирек қарастырылады. Оқу аналитикасы, компьютерлік білім беру, зияткерлік оқыту жүйелері және білім беру деректерінің этикасы бойынша зерттеулерге интегративті шолуға негізделген осы тұжырымдамалық зерттеу жоғары оқу орнында бағдарламалауға оқытуды оқу аналитикасы арқылы дербестендіру жолдарын қарастырады.

Талдау құзыреттілік туралы қорытынды жасауға мүмкіндік беретін бағдарламалауға тән дәлелдерді (тест нәтижелері, қателерді түзету, кодты қайта өңдеу реттілігі, білім алушының кодты түсіндіруі) мағынасы екіұшты мінез-құлық іздерінен (тапсырмаға жұмсалған уақыт, платформадағы белсенділік) ажыратады.

Осы негізде деректерді жинау мен дайындауды, білім алушының күйін бағалауды, педагогикалық шешім қабылдауды, дербестендірілген әсерді, кейінгі нәтижелерді бағалауды және бағалаулар мен шешім ережелерін қайта қарайтын кері байланыс циклін біріктіретін жеті кезеңді үлгі ұсынылады. Үлгі әзірге эмпирикалық тұрғыда тексерілмеген.

Түйін сөздер: оқу аналитикасы, дербестендірілген оқыту, бағдарламалауға оқыту, білім алушыны модельдеу, білімді қадағалау, қалыптастырушы кері байланыс, шешім қабылдаудағы адамның рөлі.

ИСПОЛЬЗОВАНИЕ УЧЕБНОЙ АНАЛИТИКИ ДЛЯ ПЕРСОНАЛИЗАЦИИ ОБУЧЕНИЯ ПРОГРАММИРОВАНИЮ

[1]Боранкулов Б.А., [2]Нахипова В.И., [3]Қуатбек Н.Б.
[1]https://orcid.org/0009-0009-8168-948X
магистр технических наук, преподаватель кафедры «IT и цифровых технологий» университет имени Ж.А. Ташенева, Шымкент, Казахстан
borankulovb@gmail.com
[2]https://orcid.org/0000-0002-4248-8943
PhD, старший преподаватель кафедры «IT и цифровых технологий» университет имени Ж.А. Ташенева, Шымкент, Казахстан
nakhipovavenera@mail.ru
[3]https://orcid.org/0009-0003-6725-2245
магистр педагогических наук, старший преподаватель кафедры «IT и цифровых технологий» университет имени Ж.А. Ташенева, Шымкент, Казахстан
tlgtmrv@gmail.com

Аннотация. Курсы программирования оставляют богатый цифровой след учебной деятельности: компиляции, непройденные тесты, правки кода и запросы подсказок. Однако исследования учебной аналитики в этой области в основном направлены на прогнозирование результатов курса, тогда как превращение результатов анализа в педагогические решения и их влияние на обучение рассматриваются редко.

Настоящее концептуальное исследование, основанное на интегративном обзоре работ по учебной аналитике, компьютерному образованию, интеллектуальным обучающим системам и этике образовательных данных, рассматривает пути персонализации обучения программированию в вузе с помощью учебной аналитики. В работе разграничиваются специфичные для программирования данные, позволяющие делать выводы о сформированности компетенций (результаты тестов, устранение ошибок, последовательности правок, объяснения кода обучающимися), и неоднозначные поведенческие следы (время выполнения задания, активность на платформе).

На этой основе предложена семиэтапная модель, объединяющая сбор и подготовку данных, оценку состояния обучающегося, принятие педагогического решения, персонализированное воздействие, оценку последующих результатов и цикл обратной связи, в котором пересматриваются оценки и правила принятия решений. Модель пока не прошла эмпирическую проверку.

Ключевые слова: учебная аналитика, персонализированное обучение, обучение программированию, моделирование обучающегося, отслеживание знаний, формирующая обратная связь, участие человека в принятии решений.

ӘОЖ 004.738.5

ВАЙБ-КОДИНГ: ЖАСАНДЫ ИНТЕЛЛЕКТ КӨМЕГІМЕН БАҒДАРЛАМАЛАУДЫҢ АРТЫҚШЫЛЫҚТАРЫ МЕН ТӘУЕКЕЛДЕРІ

[1]Рахметуллақызы А., [2]Баязиева М.Н., [3]Базарбекова Н.
[1]IT және цифрлық технологиялар кафедрасының аға оқытушысы,магистр
Ж.А.Тәшенев атындағы университет, Шымкент қ
Aisulu.rakhmetullakyzy@gmail.com, https://orcid.org/0009-0006-5899-7634
[2]IT және цифрлық технологиялар кафедрасының оқытушысы,магистр
Ж.А.Тәшенев атындағы университет, Шымкент қ
madi_14.1c@mail.ru , https://orcid.org/0009-0008-1776-1232
[3]IT және цифрлық технологиялар кафедрасының оқытушысы,магистр
Ж.А.Тәшенев атындағы университет, Шымкент қ
Bazarbekova.nn@mail.ru, https://orcid.org/0009-0003-7094-9182

Аңдатпа. Мақалада үлкен тілдік модельдер (LLM) негізінде бағдарламалық кодты табиғи тілдегі сипаттама бойынша жасау тәжірибесі — вайб-кодинг (vibe coding) — әдебиеттік шолу тұрғысынан талданады. Шолу 2021–2025 жылдары жарияланған, код генерациялайтын жасанды интеллект құралдарының өнімділікке, код дұрыстығына, қауіпсіздікке және оқыту нәтижелеріне әсерін эмпирикалық зерттеген жұмыстарға сүйенеді. Артықшылықтар қатарына нақты тұжырымдалған шағын тапсырмада орындау уақытының қысқаруы (бақыланған экспериментте шамамен 56%-ға жылдам), прототиптеу жылдамдығы және бағдарламалауға кіру кедергісінің төмендеуі жатады. Тәуекелдер қатарында осал кодтың пайда болуы, пайдаланушының өз кодына шамадан тыс сенімі, тәжірибелі әзірлеушілердің нақты жобаларда баяулауы (бір рандомизацияланған зерттеуде шамамен 19%) және дағдылардың әлсіреу қаупі бар. Зерттеулер әртүрлі тапсырмалар мен модель нұсқаларында жүргізілгендіктен, олардың нәтижелері тікелей салыстырылмайды. Мақалада вайб-кодингті қолдану аймақтарын (бір реттік прототиптер, жеке құралдар) қауіпсіздікке сыни маңызды жүйелерден ажырататын шарттар және жоғары оқу орнының IT бағдарламаларына арналған практикалық ұсыныстар берілген. Мақала жүйелі шолу емес, баяндаушы шолу болып табылады.

Түйін сөздер: вайб-кодинг, жасанды интеллект, үлкен тілдік модельдер, кодты генерациялау, бағдарламалық қауіпсіздік, IT білім беру, өнімділік.

Кіріспе

2025 жылдың ақпанында жасанды интеллект саласының танымал зерттеушісі Андрей Карпати өзі «вайб-кодинг» (vibe coding) деп атаған тәжірибені сипаттады: әзірлеуші кодты жолма-жол оқымайды, тапсырманы табиғи тілде модельге айтады, нәтиже жұмыс істесе қабылдайды, қате шықса қате хабарламасын модельге қайта береді (Karpathy, 2025). Мұнда өзгеретін тек код жазу жылдамдығы емес, әзірлеушінің кодқа қатынасы да: код мұқият жасалып, түсініліп отыратын артефакт емес, нәтижесі көзбен тексерілетін өнім ретінде қабылданады.

Тәжірибенің техникалық негізі — трансформер архитектурасы (Vaswani және т.б., 2017) және бағдарламалық кодтың үлкен көлемінде оқытылған тілдік модельдер (Chen және т.б., 2021). Алғашқы буын құралдар келесі жолды автотолықтырумен шектелсе, қазіргі агенттік жүйелер бірнеше файлды өңдейді, терминал командаларын орындайды және тесттерді өздері іске қосады. Нәтижесінде әзірлеушінің рөлі кодты қолмен жазушыдан тапсырма қоюшы және алынған нәтижені бағалаушы рөліне ығысып келеді (Sarkar және т.б., 2022).

Жоғары оқу орны үшін бұл мәселе екі жағынан өзекті. Біріншіден, генеративті модельдер кіріспе бағдарламалау тапсырмаларын студенттердің жоғарғы квартилі деңгейінде шеше алатыны көрсетілген (Finnie-Ansley және т.б., 2022), ал білім беру саласындағы шолулар оқыту мен бағалау тәжірибесін қайта қарау қажеттігін атап өтеді (Prather және т.б., 2023). Екіншіден,

IT мамандарын даярлайтын оқытушы студенттерге мұндай құралдарды қашан, қалай және қандай бақылаумен қолдануға болатынын түсіндіруі керек, ал бұл үшін дәлелді негіз қажет. Қолда бар зерттеулердің нәтижелері біркелкі емес: біреулері өнімділіктің айтарлықтай артқанын, басқалары керісінше баяулағанын хабарлайды. Сондықтан біз нәтижелерді жай тізіп шығумен шектелмей, олардың неге әртүрлі екенін түсіндіруге тырыстық.

Зерттеудің мақсаты — вайб-кодингтің және онымен іргелес жасанды интеллект көмегімен бағдарламалау тәжірибесінің артықшылықтары мен тәуекелдерін эмпирикалық әдебиет негізінде бағалап, оны қолдануға болатын және болмайтын жағдайларды ажырату. Міндеттер: (1) вайб-кодинг ұғымын нақтылап, дәстүрлі тәсілдермен салыстыру; (2) артықшылықтарын дәлелдер негізінде талдау; (3) тәуекелдерін талдау; (4) жоғары оқу орнының IT бағдарламаларына арналған практикалық ұсыныстар тұжырымдау.

Әдістер

Зерттеу баяндаушы (narrative) әдебиеттік шолу форматында орындалды; ол жүйелі шолудың қатаң хаттамасын (PRISMA) қамтымайды. Талдауға мына өлшемдерге сәйкес келетін жұмыстар іріктелді: (а) код генерациялайтын жасанды интеллект құралы эмпирикалық түрде (эксперимент, зерттеу, бенчмарк) бағаланған; (ә) нәтиже өнімділікке, код дұрыстығына, қауіпсіздікке немесе оқыту нәтижелеріне қатысты; (б) жұмыс 2021–2025 жылдар аралығында, яғни код генерациялайтын үлкен тілдік модельдер кеңінен тарала бастаған кезеңде жарияланған. Пікір мақалалары мен өндірушілердің маркетингтік материалдары талдау негізі ретінде пайдаланылмады.

«Вайб-кодинг» термині 2025 жылы ғана пайда болғандықтан, оған тікелей арналған рецензияланған эмпирикалық зерттеулер әлі аз. Сондықтан шолуда көбіне іргелес құралдар — GitHub Copilot, Codex және чат-көмекшілер — бойынша деректер қолданылды, ал вайб-кодингке қатысты тұжырымдар осы деректерден жасалған экстраполяция болып табылады. Әр зерттеу үшін қатысушылар саны, тапсырма түрі және құрал нұсқасы көрсетіледі, себебі нәтижелердегі айырмашылықтың басым бөлігі осы жағдайлармен түсіндіріледі.

Шолу нәтижелері

Вайб-кодинг ұғымы және оның орны

Әдебиетте бағдарламалауда жасанды интеллектті пайдалану бақылау деңгейі әртүрлі бірнеше режим ретінде сипатталады. Barke және т.б. (2023) бақылау зерттеуінде бағдарламашылардың Copilot-пен екі режимде жұмыс істейтінін көрсетті: «үдету» режимінде әзірлеуші келесі қадамды біледі, ал құрал оны тездетеді; «зерттеу» режимінде әзірлеуші қалай жалғастыруды білмейді де, модельден нұсқалар сұрайды. Вайб-кодингті осы спектрдің шеткі нүктесі деп қарастыруға болады: зерттеу режимі кодты оқудан толық бас тартуға дейін барады, ал тексеру бағдарламаны іске қосып көру арқылы ғана жүреді (Karpathy, 2025). Айырмашылықтар 1-кестеде жинақталған; кесте автордың жалпылауы болып табылады.

1-кесте. Бағдарламалау тәсілдерінің салыстырмалы сипаттамасы

Белгі	Дәстүрлі бағдарламалау	AI-көмекшімен бағдарламалау	Вайб-кодинг
Кодты кім жазады	Әзірлеуші	Әзірлеуші мен модель бірге; ұсынысты әзірлеуші таңдайды	Негізінен модель
Кодты оқу және түсіну	Толық	Таңдамалы; әзірлеуші жауапты	Жиі жүргізілмейді
Тексеру тәсілі	Код шолу, тесттер	Код шолу, тесттер	Негізінен іске қосып көру
Жауапкершілік	Әзірлеуші	Әзірлеуші	Формалды түрде әзірлеуші, тәжірибеде әлсіз бақыланады

Белгі	Дәстүрлі бағдарламалау	AI-көмекшімен бағдарламалау	Вайб-кодинг
Тиімді аймақ	Кез келген жоба	Өнімдік жобалар	Прототип, жеке құрал

Ескерту: кесте шолынған дереккөздердің негізінде автор жасаған жалпылау болып табылады.

Осылайша, айырмашылықтың өзегі модельдің бар-жоғында емес, әзірлеуші нәтижені түсініп, тексеретінінде. Бұл ой кейінгі бөлімдерде қайталанады.

Артықшылықтары

Жұмыс жылдамдығы. Ең жиі келтірілетін дәлел — Peng және т.б. (2023) бақыланған экспериментінің нәтижесі: 95 әзірлеуші JavaScript тілінде HTTP-сервер жазу тапсырмасын орындады, Copilot қолданған топ тапсырманы бақылау тобынан шамамен 55,8%-ға жылдам аяқтады. Алайда мұны жалпылау қиын: тапсырма нақты тұжырымдалған, оқшауланған және қысқа болды, яғни жаңадан жазылатын шағын код үшін тән жағдай. Нәтиже «сипаттамасы анық шағын тапсырмада жылдамдық артады» дегенді көрсетеді, ал күрделі жүйелерді жалпы жылдамдатады дегенді емес.

Прототиптеу және зерттеу. Вайб-кодингтің ең күшті жағы — идеядан жұмыс істейтін үлгіге дейінгі жолдың қысқаруы. Barke және т.б. (2023) сипаттаған «зерттеу» режимі осыған негізделген: әзірлеуші бейтаныс кітапхана мен API-мен модельден бірнеше нұсқа сұрап, олардың ішінен таңдау арқылы тез танысады. Прототиптің өмір сүру мерзімі қысқа, қателігінің құны төмен болса, кодты толық түсінбеу тәуекелі де төмен. Бұл эмпирикалық нәтиже емес, инженерлік қисын; ол Karpathy (2025) жазбасындағы бір реттік, демалыс күнгі жобалар үшін жарайды деген бағамен үйлеседі.

Кіру кедергісінің төмендеуі. Kazemitabaar және т.б. (2023) 69 жасөспірім бастаушымен жүргізген зерттеуінде Codex негізіндегі код генераторы бар топ кодты өздері жазу тапсырмаларында жоғары нәтиже көрсетті, ал кейінгі, қолмен орындалатын тапсырмада бақылау тобынан нашарлаған жоқ. Дегенмен зерттеу қысқа мерзімді болды, ұзақ мерзімді әсер белгісіз. Сапалық тұрғыдан қарағанда, бағдарламалау білімі шектеулі мамандар (ғалымдар, мұғалімдер) өз қажеттіліктеріне арналған шағын құралдарды өздері жасай алады; бұл тұжырым тікелей өлшенген дерекке емес, пайымға сүйенеді.

Кемшіліктері мен тәуекелдері

Қауіпсіздік. Pearce және т.б. (2022) Copilot-ты осалдығы белгілі 89 сценарийде тексеріп, жасалған 1 689 бағдарламаның шамамен 40%-ында осалдық тапты. Perry және т.б. (2023) пайдаланушылық зерттеуінде (47 қатысушы) AI-көмекшіні қолданғандар қауіпсіздігі төмен код жазды және өз кодын қауіпсіз деп санауға бейім болды. Екінші нәтиже маңыздырақ: мәселе тек модельдің қатесінде емес, адамның оны байқамауында. Pearce жұмысы 2021 жылғы модельге қатысты екенін ескеру керек; қазіргі модельдер жақсарған болуы мүмкін, бірақ бұл шолуға енген дереккөздерде осы жақсарудың қауіпсіздікке әсері өлшенбеген.

Дұрыстық. Chen және т.б. (2021) модельдің берілген есептің тек бір бөлігін ғана бірінші әрекетте шеше алатынын көрсетті. Liu және т.б. (2023) бенчмарктардағы бастапқы тесттер жеткіліксіз екенін, тесттерді кеңейткенде модельдердің өлшенетін дұрыстығы төмендейтінін анықтады, яғни «жұмыс істейтін» көрінген код жасырын қате жасауы мүмкін. SWE-bench жұмысы нақты GitHub мәселелерін шешуді тексерді: жарияланған кезде үздік модель тапсырмалардың шамамен 2%-ын ғана шешті (Jimenez және т.б., 2024). Кейінгі модельдер нәтижені айтарлықтай жақсартты, бірақ бенчмарктан өту автоматты тесттерден өтуді ғана өлшейді, ол талаптарға сәйкестікті, оқылымдылықты немесе қолдауға жарамдылықты кепілдемейді. Вайб-кодингте тесттер болмаса, бағдарламаны көзбен көріп тексеру дұрыстықтың әлсіз өлшемі.

Нақты жобалардағы өнімділік парадоксы. Becker және т.б. (2025) тәжірибелі ашық бастапқы код әзірлеушілерімен рандомизацияланған зерттеу жүргізді: 16 әзірлеуші өздері жақсы білетін ірі репозиторийлерде 246 нақты тапсырманы кездейсоқ түрде AI-мен және AI-

сыз орындады. AI рұқсат етілген тапсырмалар шамамен 19%-ға ұзағырақ орындалды. Әзірлеушілер алдын ала 24%-ға жылдамдау күтті, ал жұмыстан кейін өздерін шамамен 20%-ға жылдамдаймыз деп есептеді. Демек, өнімділікті өз сезімімен бағалау сенімсіз болуы мүмкін; ал вайб-кодингтің өзі «сезімге» («vibe») сүйенетіні бұл деректі ерекше маңызды етеді.

Дағдылардың әлсіреуі және автоматтандыруға шамадан тыс сенім. Bainbridge (1983) автоматтандырудың парадоксын сипаттады: жүйе неғұрлым автоматты болған сайын, оның ерекше жағдайларын басқаратын адамның біліктілігі соғұрлым маңызды болады, бірақ сол біліктілік жаттығусыз әлсірейді. Parasuraman мен Riley (1997) автоматтандыруды дұрыс пайдаланбаудың түрлерін (шамадан тыс сенім және негізсіз бас тарту) жүйелеген. Бұл еңбектер бағдарламалау туралы емес, сондықтан оларды теориялық шеңбер ретінде ғана қолданамыз; алайда Perry және т.б. (2023) тапқан шамадан тыс сенім осы құбылыстың бағдарламалаудағы көрінісі болуы мүмкін.

Қолдау және техникалық қарыз. Түсінілмеген кодты өзгерту, қатесін іздеу және жаңа талаптарға бейімдеу қиын. Бұл мәлімдеме де тікелей эмпирикалық дерекке емес, инженерлік пайымға сүйенеді, сондықтан оны болашақ зерттеулерде тексеру қажет.

Оқыту нәтижелері. Prather және т.б. (2024) кіріспе курс студенттерін зерттегенде, метакогнитивті қиындығы бар студенттер генеративті AI-ды қолданған кезде өз түсінігін асыра бағалауға бейім екенін, ал дайындығы жақсы студенттер одан көбірек пайда алатынын көрсетті; авторлар мұны «ұлғаятын алшақтық» деп сипаттады.

2-кесте. Артықшылықтар мен тәуекелдердің дәлелдік негізі

Фактор	Нәтиже	Дереккөз	Негізгі шектеу
Жылдамдық (+)	Шамамен 55,8%-ға жылдам	Peng және т.б., 2023	Бір қысқа, жаңа тапсырма; 95 әзірлеуші
Бастаушылар (+)	Авторлық тапсырмада жоғары нәтиже, қолмен тапсырмада төмендеу жоқ	Kazemitabaar және т.б., 2023	Қысқа мерзім; 69 қатысушы
Қауіпсіздік (−)	Бағдарламалардың шамамен 40%-ында осалдық	Pearce және т.б., 2022	2021 жылғы модель; белгілі сценарийлер
Сенім (−)	AI қолданғандар кодын қауіпсіз деп жиі санады	Perry және т.б., 2023	Зертханалық; 47 қатысушы
Нақты жоба (−)	Шамамен 19%-ға баяу	Becker және т.б., 2025	16 әзірлеуші; 2025 жылдың басындағы құралдар
Оқыту (±)	Әлсіз метакогнитивті студенттерге қауіп	Prather және т.б., 2024	Кіріспе курс; нәтиже контекстке тәуелді

Ескерту: «+» артықшылық, «−» тәуекел, «±» контекстке тәуелді нәтиже.

Талқылау

Peng және т.б. (2023) пен Becker және т.б. (2025) нәтижелері бір-біріне қайшы көрінеді, бірақ екеуі де шын болуы мүмкін. Айырмашылық тапсырма сипатында: біріншісінде шағын, жаңадан жазылатын, нақты тұжырымдалған тапсырма, екіншісінде әзірлеуші жақсы білетін ірі әрі жетілген кодтық база мен жоғары сапа талабы. Біздің болжамымыз бойынша, модельдің пайдасы әзірлеушінің тапсырмаға байланысты білімі мен кодтың күрделілігіне кері тәуелді, бірақ бұл болжамды осы шолудағы деректер тікелей тексермейді. Екі зерттеу де вайб-кодингті емес, құрал қолдануды өлшегенін ескеру қажет: вайб-кодингте кодты түсіну азырақ болатындықтан, оның қателіктері зерттелген режимдегіден күштірек болуы мүмкін.

Практикалық тұрғыдан шешім «қолдануға бола ма» деген сұрақпен емес, «қандай бақылаумен қолдануға болады» деген сұрақпен қабылдануы тиіс. 3-кестеде вайб-кодингті қолдану аймақтары қателіктің құнына қарай жіктелген.

3-кесте. Қолдану аймақтары және ұсынылатын бақылау деңгейі

Аймақ	Мысал	Ұсынылатын бақылау
Қолайлы	Бір реттік скрипт, интерфейс макеті, жеке автоматтандыру, оқуда идеяны тексеру	Іске қосып көру жеткілікті; нәтиже өнімге бармайды
Шартты	Ішкі құралдар, оқу жобалары, деректерді талдау	Автоматты тесттер, кодты қысқаша оқу, нұсқаларды басқару
Қолайсыз	Қауіпсіздікке сыни жүйелер, қаржы, медицина, дербес деректер, ұзақ өмірлі өнімдер	Толық код шолу, статикалық талдау, адамның түсінуі міндетті

Ескерту: кесте автордың жалпылауы; шекаралар жобаның контекстіне қарай өзгереді.

Жоғары оқу орнының IT бағдарламалары үшін шолудан мынадай ұсыныстар шығады. Біріншіден, жасанды интеллектті тыйым салудың орнына оқыту нысанына айналдыру: тапсырмалар дайын кодты түсіндіруді, қатесін табуды және тесттер жазуды талап етсін. Екіншіден, бағалауды өзгерту: ауызша қорғау, қолмен код оқу және нұсқалар тарихын (git) көрсету студенттің нәтижені шын түсінетінін тексеруге көмектеседі. Үшіншіден, оқу жоспарына AI-мен жасалған кодтың қауіпсіздігін тексеру (статикалық талдау, код шолу) модулін енгізу, өйткені қауіпсіздік бойынша дәлелдер ең жеткілікті. Төртіншіден, студенттің AI қолдануын декларациялау және сұраныстар журналын жүргізу практикасын енгізу. Бесіншіден, Bainbridge (1983) ойына сәйкес, негізгі бағдарламалау дағдыларын алдымен қалыптастыру: AI-дың нәтижесін тексеру үшін адамның өзі кодты оқи және жаза білуі тиіс.

Зерттеудің шектеулері

Біріншіден, бұл баяндаушы шолу, сондықтан дереккөздердің толық қамтылуына кепілдік жоқ, іріктеуде автордың субъективті таңдауы болуы мүмкін. Екіншіден, вайб-кодингке тікелей арналған эмпирикалық зерттеулер аз, көп тұжырым іргелес құралдардан экстраполяцияланды. Үшіншіден, модельдер өте жылдам өзгереді: 2021–2025 жылдардағы нәтижелер қазіргі құралдарға толық көшірілмеуі мүмкін. Төртіншіден, кейбір дереккөздер препринт ретінде (arXiv) қолжетімді. Бесіншіден, шолынған зерттеулердің көбі ағылшын тілді ортада, бөлек бағдарламалау тілдерінде жүргізілген; олардың Қазақстан жоғары оқу орындарының жағдайына сәйкестігі тексерілмеген.

Қорытынды

Шолу көрсеткендей, вайб-кодинг пен жасанды интеллект көмегімен бағдарламаудың пайдасы нақты, бірақ шартты: ол сипаттамасы анық шағын тапсырмаларда, прототиптеуде және оқуға кіру сатысында көрінеді. Тәуекелдер де нақты дәлелденген: осал код, адамның өз кодына шамадан тыс сенімі және тәжірибелі әзірлеушілердің нақты жобаларда баяулауы мүмкін екені. Шешуші факторлар — тапсырма түрі, кодтың өмір сүру мерзімі және әзірлеушінің нәтижені түсініп тексере алуы. Жоғары оқу орны үшін қисынды бағыт — вайб-кодингке тыйым салу не оны бақылаусыз енгізу емес, бақылау деңгейін жобаның тәуекеліне сәйкестендіру және студенттің түсіну дағдысын бағалау.

Келесі зерттеулерде (а) Қазақстан университеттерінде студенттердің AI-мен және AI-сыз орындаған тапсырмаларын салыстыратын бақыланатын эксперимент жүргізу, (ә) вайб-кодингпен жасалған жобалардың қолдау құнын өлшеу және (б) қауіпсіздік көрсеткіштерін қазіргі модельдерде қайта бағалау орынды болар еді.

Әдебиеттер тізімі:

1. Karpathy A. There's a new kind of coding I call "vibe coding" [Social media post]. X (Twitter). 2 February 2025.

2. Vaswani A., Shazeer N., Parmar N., et al. Attention is all you need // Advances in Neural Information Processing Systems. 2017. Vol. 30.

3. Chen M., Tworek J., Jun H., et al. Evaluating large language models trained on code // arXiv preprint arXiv:2107.03374. 2021.

4. Sarkar A., Gordon A.D., Negreanu C., et al. What is it like to program with artificial intelligence? // Proceedings of the 33rd Annual Workshop of the Psychology of Programming Interest Group (PPIG). 2022. arXiv:2208.06213.

5. Finnie-Ansley J., Denny P., Becker B.A., Luxton-Reilly A., Prather J. The robots are coming: Exploring the implications of OpenAI Codex on introductory programming // Proceedings of the 24th Australasian Computing Education Conference (ACE '22). 2022. P. 10–19.

6. Prather J., Denny P., Leinonen J., et al. The robots are here: Navigating the generative AI revolution in computing education // Proceedings of the 2023 Working Group Reports on Innovation and Technology in Computer Science Education (ITiCSE-WGR). 2023. P. 108–159.

7. Peng S., Kalliamvakou E., Cihon P., Demirer M. The impact of AI on developer productivity: Evidence from GitHub Copilot // arXiv preprint arXiv:2302.06590. 2023.

8. Barke S., James M.B., Polikarpova N. Grounded Copilot: How programmers interact with code-generating models // Proceedings of the ACM on Programming Languages. 2023. Vol. 7, OOPSLA1. Article 78.

9. Kazemitabaar M., Chow J., Ma C.K.T., Ericson B.J., Weintrop D., Grossman T. Studying the effect of AI code generators on supporting novice learners in introductory programming // Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems. 2023. Article 455.

10. Pearce H., Ahmad B., Tan B., Dolan-Gavitt B., Karri R. Asleep at the keyboard? Assessing the security of GitHub Copilot's code contributions // 2022 IEEE Symposium on Security and Privacy (SP). 2022. P. 754–768.

11. Perry N., Srivastava M., Kumar D., Boneh D. Do users write more insecure code with AI assistants? // Proceedings of the 2023 ACM SIGSAC Conference on Computer and Communications Security (CCS '23). 2023. P. 2785–2799.

12. Liu J., Xia C.S., Wang Y., Zhang L. Is your code generated by ChatGPT really correct? Rigorous evaluation of large language models for code generation // Advances in Neural Information Processing Systems. 2023. Vol. 36.

13. Jimenez C.E., Yang J., Wettig A., et al. SWE-bench: Can language models resolve real-world GitHub issues? // The Twelfth International Conference on Learning Representations (ICLR). 2024.

14. Becker J., Rush N., Barnes E., Rein D. Measuring the impact of early-2025 AI on experienced open-source developer productivity // arXiv preprint arXiv:2507.09089. 2025.

15. Bainbridge L. Ironies of automation // Automatica. 1983. Vol. 19, No. 6. P. 775–779.

16. Parasuraman R., Riley V. Humans and automation: Use, misuse, disuse, abuse // Human Factors. 1997. Vol. 39, No. 2. P. 230–253.

17. Prather J., Reeves B.N., Denny P., et al. The widening gap: The benefits and harms of generative AI for novice programmers // Proceedings of the 2024 ACM Conference on International Computing Education Research (ICER '24). 2024.

ВАЙБ-КОДИНГ: ПРЕИМУЩЕСТВА И РИСКИ ПРОГРАММИРОВАНИЯ С ПОМОЩЬЮ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

[1]Рахметуллакызы А., [2]Баязиева М.Н., [3]Базарбекова Н.
[1]Старший преподаватель кафедры IT и цифровых технологий, магистр
Университет имени Ж.А. Ташенева, г. Шымкент
Aisulu.rakhmetullakyzy@gmail.com, https://orcid.org/0009-0006-5899-7634
[2]Преподаватель кафедры IT и цифровых технологий, магистр
Университет имени Ж.А. Ташенева, г. Шымкент
madi_14.1c@mail.ru , https://orcid.org/0009-0008-1776-1232
[3]Преподаватель кафедры IT и цифровых технологий, магистр
Университет имени Ж.А. Ташенева, г. Шымкент
Bazarbekova.nn@mail.ru, https://orcid.org/0009-0003-7094-9182

Аннотация. В статье в формате литературного обзора анализируется практика создания программного кода по описанию на естественном языке с помощью больших языковых моделей — вайб-кодинг (vibe coding). Обзор опирается на работы 2021–2025 годов, в которых эмпирически изучено влияние инструментов генерации кода на продуктивность, корректность и безопасность кода, а также на результаты обучения. К преимуществам относятся сокращение времени выполнения чётко сформулированных небольших задач (в контролируемом эксперименте — примерно на 56%), быстрое прототипирование и снижение порога входа в программирование. К рискам — появление уязвимого кода, чрезмерное доверие пользователя к собственному коду, замедление опытных разработчиков на реальных проектах (в одном рандомизированном исследовании — примерно на 19%) и угроза ослабления навыков. Поскольку исследования выполнены на разных задачах и версиях моделей, их результаты напрямую несопоставимы. Предложены условия применения вайб-кодинга и практические рекомендации для ИТ-программ вузов. Статья представляет собой нарративный, а не систематический обзор.

Ключевые слова: вайб-кодинг, искусственный интеллект, большие языковые модели, генерация кода, безопасность программного обеспечения, ИТ-образование, продуктивность.

VIBE CODING: ADVANTAGES AND RISKS OF AI-ASSISTED PROGRAMMING

[1]Rakhmetullakyzy A., [2]Bayaziyeva M., [3]Bazarbekova N.
[1]Senior Lecturer of the Department of IT and Digital Technologies, Master's degree
Zh.A. Tashenev University, Shymkent
Aisulu.rakhmetullakyzy@gmail.com, https://orcid.org/0009-0006-5899-7634
[2]Lecturer of the Department of IT and Digital Technologies, Master's degree
Zh.A. Tashenev University, Shymkent
madi_14.1c@mail.ru , https://orcid.org/0009-0008-1776-1232
[3]Lecturer of the Department of IT and Digital Technologies, Master's degree
Zh.A. Tashenev University, Shymkent
Bazarbekova.nn@mail.ru, https://orcid.org/0009-0003-7094-9182

Abstract. This article presents a narrative literature review of vibe coding, the practice of producing program code from natural-language descriptions with large language models. The review draws on studies published between 2021 and 2025 that empirically examined the effects of code-generating AI tools on productivity, code correctness, security and learning outcomes. The advantages include shorter completion time for well-specified small tasks (about 56% faster in a controlled experiment), rapid prototyping and a lower barrier to entry into programming. The risks

include vulnerable code, users' overconfidence in their own code, slower work by experienced developers on real projects (about 19% in one randomized study) and possible erosion of skills. Because the studies used different tasks and model versions, their results are not directly comparable. The article proposes conditions under which vibe coding is appropriate and practical recommendations for university IT programs. It is a narrative, not a systematic, review.

Keywords: vibe coding, artificial intelligence, large language models, code generation, software security, IT education, productivity.

ҒТАМР 14.35.07

ЖАСАНДЫ ИНТЕЛЛЕКТ ТЕХНОЛОГИЯЛАРЫН БІЛІМ БЕРУ ЖҮЙЕСІНЕ ИНТЕГРАЦИЯЛАУДЫҢ ТЕОРИЯЛЫҚ ЖӘНЕ ПРАКТИКАЛЫҚ АСПЕКТІЛЕРІ

[1]Юртсевен М.К., [2]Ермурзаева А.Ш., [3]Тажибаева Б.Т.
[1]IT және цифрлық технологиялар кафедрасының аға оқытушысы, PhD
Ж.А.Тәшенев атындағы университет, Шымкент қ
https://orcid.org/57225244254 , meruert_diana@mail.ru
[2]IT және цифрлық технологиялар кафедрасының аға оқытушысы, магистр
Ж.А.Тәшенев атындағы университет, Шымкент қ
https://orcid.org/0009-0001-8625-4874, a_i_j_a_n_88@mail.ru
[3]IT және цифрлық технологиялар кафедрасының аға оқытушысы, магистр
Ж.А.Тәшенев атындағы университет, Шымкент қ
https://orcid.org/0009-0007-2973-0065 ,b.tasbulatovna@mail.ru

Аңдатпа. Мақалада жасанды интеллект технологияларын білім беру жүйесіне интеграциялаудың теориялық негіздері мен практикалық іске асырылу шарттары талданады. Зерттеу баяндаушы шолу форматында жүргізілді: әдебиет мақсатты түрде іріктелді, ал қазақстандық контекст үшін нормативтік құжаттарға мазмұндық талдау жасалды. Интеллектуалды оқыту жүйелері, адаптивті платформалар және генеративті модельдер білімнің ұсынылуы, кері байланыс көзі, мұғалімнің рөлі және дәлелдік база өлшемдері бойынша салыстырылды. Талдау көрсеткендей, интеграцияның нәтижесін технологияның түрі емес, оның дидактикалық дизайны анықтайды: көмекті біртіндеп азайтуды қарастырмайтын генеративті құралдар қысқа мерзімді нәтижені жақсартып, өз бетінше меңгеруге кері әсер етуі мүмкін. Негізгі тәуекелдер ретінде академиялық адалдық, тілдік біржақтылық, деректер құпиялығы және цифрлық теңсіздік анықталды. Қазақстанда нормативтік база қалыптасты, бірақ оның тиімділігі туралы эмпирикалық дәлел әзірше жоқ. Мақала эмпирикалық эксперимент жүргізбейді, қорытындылар аналитикалық сипатта.

Түйін сөздер: жасанды интеллект; білім беру; интеллектуалды оқыту жүйелері; генеративті модельдер; адаптивті оқыту; педагогикалық дизайн; академиялық адалдық.

Кіріспе

Жасанды интеллект идеясы білім беруге кеше келген жоқ. Алғашқы компьютерлік тьюторлық жүйелер, мысалы Дж. Карбонеллдің SCHOLAR бағдарламасы, өткен ғасырдың 70-жылдары-ақ пайда болған. Алайда соңғы жылдары жағдай сапалық тұрғыдан өзгерді. Үлкен тілдік модельдер мамандандырылған бағдарламалық қамтаманы қажет етпейді: кез келген оқушы немесе студент оларға жай ғана сұрақ қоя алады. Нәтижесінде технология оқу орындарының ресми шешімінен бұрын сынып пен аудиторияға кіріп кетті, ал оны қалай қабылдау керектігі туралы келісім әлі қалыптасқан жоқ.

Зерттеушілер арасындағы пікір де біркелкі емес. Бір топ авторлар жеке траекториямен оқытудың, лезде кері байланыстың және мұғалімнің рутиналық жүктемесін азайтудың мүмкіндігін алға тартады [1]. Екінші топ технологиялық оптимизмге сақтықпен қарайды: алгоритмдердің «қара жәшік» сипаты, деректер құпиялығы, оқушылардың өз бетінше ойлау дағдысының әлсіреуі және мұғалімнің кәсіби рөлінің өзгеруі қауіп тудырады деп есептейді [2]. Бұл екі ұстанымның арасындағы алшақтық ішінара эмпирикалық дәлелдердің әркелкілігінен туындайды. Мысалы, интеллектуалды оқыту жүйелерінің тиімділігін салыстырған VanLehn жұмысында олардың нәтижесі белгілі бір жағдайларда жеке тьюторлық оқытуға жуық екені көрсетілген [3]. Бірақ бұл қорытынды негізінен құрылымдалған, жабық типті пәндік салаларға (математика, физика) қатысты. Ашық сипаттағы тапсырмалар мен генеративті модельдер үшін бұлай нық қорытынды жасауға әзірше негіз аз.

Мәселенің тағы бір қыры бар, ол ғылыми әдебиеттің өзіне қатысты. Жоғары білім берудегі жасанды интеллект қолданысына арналған зерттеулерге жүргізілген жүйелі шолуда авторлардың басым бөлігі педагогика саласынан емес, техникалық бағыттардан екені көрсетілген. Шолу авторлары зерттеулердің педагогикалық теориямен байланысы әлсіз екенін де атап өтеді [4]. Басқаша айтқанда, технология «не істей алады?» деген сұрақпен жиі талқыланады да, «не үшін және қандай дидактикалық логикамен?» деген сұрақ екінші орынға ығысады. Қазақстандық педагогикалық әдебиетте бұл олқылық қосымша тереңдейді: цифрландыру мен жасанды интеллект туралы жұмыстардың көбі нормативтік-сипаттамалық деңгейде қалады, ал интеграцияның теориялық моделі мен оны іске асырудың нақты тетіктері жүйелі түрде сирек талданады.

Осыған байланысты зерттеудің мақсаты жасанды интеллект технологияларын білім беру жүйесіне интеграциялаудың теориялық негіздерін жүйелеу және оның практикалық іске асырылу шарттарын, сондай-ақ тәуекелдерін қазақстандық контексті ескере отырып талдау болып табылады. Мақсатқа жету үшін үш міндет қойылды: біріншіден, қолданыстағы теориялық тәсілдерді (интеллектуалды оқыту жүйелері, адаптивті оқыту, генеративті модельдерге негізделген оқыту) дидактикалық тұрғыдан салыстыру; екіншіден, практикадағы негізгі қолдану бағыттарын (бағалау, кері байланыс, оқытуды даралау, мұғалім жұмысын қолдау) және олардың шектеулерін анықтау; үшіншіден, интеграцияға байланысты этикалық және институционалдық тәуекелдерді қазақстандық білім беру жүйесінің жағдайымен байланыстыра қарастыру.

Әдістер

Зерттеу теориялық-аналитикалық шолу форматында жүргізілді. Эмпирикалық деректер жиналған жоқ: мақсат бар ғылыми және нормативтік материалды жүйелеп, салыстырып, қайта пайымдау болды. Жүйелі шолудың қатаң хаттамасынан (мысалы, PRISMA) саналы түрде бас тарттық. Тақырып ауқымы кең, ал генеративті модельдерге қатысты әдебиет жылдам өсуде, сондықтан қатаң хаттама іріктеуді жасанды түрде тарылтып жіберер еді. Сол себепті баяндаушы (нарративті) шолу тәсілін қолдандық: әртүрлі пәндік салалардағы жұмыстар бір ұғымдық өріске жиналады, ал айқын кемшілік, яғни іріктеудің белгілі бір субъективтілігі, төменде көрсетіледі.

Әдебиет мақсатты түрде іріктелді. Таңдау өлшемдері: жұмыс рецензияланатын басылымда немесе танымал академиялық баспада шыққан, білім беру контекстін айқын көрсететін, теориялық, концептуалды немесе эмпирикалық сипатта болуы керек. Педагогикалық қолданысы жоқ таза алгоритмдік мақалалар мен жарнамалық, блог түріндегі материалдар талдауға кірмеді. Интеллектуалды оқыту жүйелері бойынша іргелі жұмыстар соңғы онжылдықтан ерте шықса да, олар теориялық негіз ретінде бөлек қарастырылды. Генеративті модельдерге қатысты зерттеулер негізінен 2022 жылдан кейінгі жұмыстардан алынды.

Талдау үш сатыда жүрді. Алдымен жұмыстар теориялық тәсіліне қарай кодталды: интеллектуалды оқыту жүйелері, адаптивті оқыту, генеративті модельдерге негізделген оқыту. Екінші сатыда тәсілдер төрт өлшем бойынша салыстырылды: білім алушы мен мұғалімнің рөлі, кері байланыстың көзі, білімнің ұсынылу тәсілі және тиімділіктің дәлелдік базасы. Соңғы

өлшемді бөлек алдық, себебі әдебиетте технологияның мүмкіндігі мен оның дәлелденген әсері жиі араласып кетеді. Үшінші сатыда нәтижелер практикалық қолдану бағыттарымен және тәуекелдермен байланыстырылды.

Қазақстандық контекст үшін нормативтік құжаттарға мазмұндық талдау жасалды: «Жасанды интеллект туралы» 2025 жылғы 17 қарашадағы № 230-VIII ҚРЗ Заңы [5], орта білім беру жүйесіне жасанды интеллектіні ендіру жөніндегі Президент Жарлығы [6], осы Жарлыққа сәйкес әзірленетін 2026–2029 жылдарға арналған кешенді іс-шаралар жоспары, сондай-ақ жаңартылған білім беру стандарты мен үлгілік оқу бағдарламалары. Құжаттардың бір бөлігі әлі іске асырылу сатысында тұр, сондықтан олар бойынша нәтиже туралы емес, жария етілген бағыт пен міндеттемелер туралы ғана айтуға болады.

Зерттеудің шектеулері мынадай. Іздеу қазақ, орыс және ағылшын тілдерімен шектелді, сондықтан өзге тілдердегі ауқымды жұмыстар шолудан тыс қалған болуы мүмкін. Жарияланым ығысуы (publication bias) сақталады, өйткені сәтсіз немесе нөлдік нәтиже беретін жобалар әдебиетте сирек көрінеді. Генеративті модельдер бойынша дәлелдер әлі ерте сатыда, көптеген жұмыс шағын іріктемеге және қысқа бақылау мерзіміне сүйенеді. Ақырында, жеке эмпирикалық деректің болмауы қорытындылардың жалпылану деңгейін шектейді.

Нәтижелер мен талқылау

Теориялық негіздер

Жасанды интеллектіні оқытуға енгізудің әртүрлі тәсілдерін бір тізімге тізіп шығу оңай, бірақ олардың арасындағы айырмашылық технологияда емес, «білім» мен «көмек» дегенді қалай түсінетінінде жатыр. Үш тәсіл қарастырылады: интеллектуалды оқыту жүйелері, адаптивті оқыту платформалары және генеративті модельдерге сүйенетін құралдар. Төменде олар осы тұрғыдан салыстырылады.

Интеллектуалды оқыту жүйелерінің идеялық бастауы Блумның «екі сигма мәселесінде» жатыр. Ол жеке тьюторлық оқыту қалыпты сыныптық сабақпен салыстырғанда нәтижені шамамен екі стандартты ауытқуға жақсартатынын көрсетіп, дәл осындай әсерді жаппай оқытуда қалай алуға болады деген сұрақ қойды [7]. Жауап ретінде когнитивті тьюторлар пайда болды. Олар білімді нақты өндіріс ережелері (production rules) жиынтығы ретінде модельдейді, ал білім алушының әрбір қадамын осы ережелермен салыстырып, меңгеру ықтималдығын жаңартып отырады [8]. Мұнда «көмек» дегеніміз қадамды диагностикалау және дәл сол сәтте нұсқау беру. Тәсілдің мықты жағы да, әлсіз жағы да осы жерде: домендік модель адам қолымен жасалатындықтан, ол алгебра немесе физика есептері сияқты құрылымдалған салада жақсы жұмыс істейді, ал эссе жазу, дебат немесе пәнаралық жоба секілді ашық тапсырмаларда сирек қолданылады. VanLehn жүргізген салыстыруда нәтиже кері байланыстың «түйіршіктігіне» тәуелді болды: қадамдық жүйелердің әсері жауап деңгейінде ғана көмек беретін жүйелерден айтарлықтай жоғары, ал жеке адам тьюторына жақын болды [3]. Дегенмен бұл қорытындыны кең жалпылауға болмайды, оған бастапқы зерттеулердің негізінен математика мен физикаға қатысты екенін ескеру керек.

Адаптивті оқыту туралы әңгіме ең күрделі, себебі мұнда терминнің өзі бұлыңғыр. Көпшілік платформалар «адаптивті» деп аталғанымен, іс жүзінде тапсырмалардың қиындығы мен реттілігін алдын ала жазылған ережемен немесе қарапайым статистикалық моделмен ауыстырады. Бұл білім алушының қарқынына бейімделу болуы мүмкін, бірақ педагогикалық стратегияның өзі, яғни қалай түсіндіру, қашан араласу, қашан араласпау, әдетте өзгермейді. Сондықтан адаптивтілік пен даралауды теңестіруге болмайды. Бір дау бар: кейбір платформалар бейімделуді «оқу стильдеріне» негіздейді, ал бұл болжамның эмпирикалық дәлелі әлсіз екені әдебиетте жақсы құжатталған [9]. Яғни жақсы мақсатты, бірақ нақты негізі жоқ даралау нұсқасы пайда болады.

Генеративті модельдер бұл екі тәсілден принципті түрде өзгеше, өйткені оларда айқын домендік модель де, білім алушы моделі де жоқ. Олар сенімді, жатық жауап береді, бірақ жауаптың дұрыстығына кепілдік жоқ. Бұл олардың мүмкіндігі де, қауіпі де. Мүмкіндік жағынан ашық тапсырмаларда, әртүрлі тақырыптарда түсіндіру беру қабілеті бұрынғы жүйелерде болған жоқ [1]. Қауіп жағынан, модель «тьютор» ретінде емес, жауап беретін құрал

ретінде жұмыс істеуі мүмкін. Бұл жерде когнитивті психологиядағы «scaffolding» (қолдау тірегі) идеясы маңызды: көмек білім алушының жақын даму аймағында берілуі және оның меңгерген сайын біртіндеп азайтылуы керек [10]. Жауапты дайын түрде беру бұл логиканы бұзады.

Бұл жерде терминологиялық дау бар. Кейбір авторлар үлкен тілдік модельдерді интеллектуалды оқыту жүйелерінің жаңа буыны ретінде қарастырады, өйткені олар да диалог арқылы көмек береді. Екінші көзқарас бойынша, білім алушы моделі мен домендік білімнің айқын көрінісі болмағандықтан, оларды тьюторлық жүйе деп атауға болмайды: олар тек тьютор рөлін ойнай алады, ал бұл рөлді нақты тьюторлыққа айналдыру дизайнға тәуелді. Біз екінші ұстанымға жақынбыз, бірақ мәселе жабылған жоқ, әсіресе домендік модельмен біріктірілген гибридтік жүйелер көбейген сайын.

Эмпирикалық мысал осыны көрсетеді. Түркиядағы бір орта мектепте шамамен мың оқушымен жүргізілген далалық эксперименттің нәтижесінде GPT-4-ке қолжетімділік есеп шығару кезінде нәтижені жақсартты (GPT Base тобында 48%, GPT Tutor тобында 127%). Бірақ қолжетімділік алынып тасталғаннан кейін GPT Base қолданған оқушылар ешқашан қолданбағандарға қарағанда нашар нәтиже көрсетті (17%-ға төмен), ал GPT Tutor-дағы қорғаныс шектеулері бұл теріс әсерді көбінесе жойды [11]. GPT Tutor моделіне есептің шешімі мен жиі қателіктер беріліп, ол оқушыға толық шешімді емес, біртіндеп кеңес беруге нұсқау алған. Басқаша айтқанда, нәтижені модельдің «ақылдылығы» емес, оның дидактикалық бағдарламалануы анықтады. Мұны мұқият оқу керек: зерттеу бір мектепте, математика бойынша, чат-боттар жаңа болған кезеңде жүргізілген, сондықтан нәтижені басқа пәндерге немесе жасқа автоматты түрде көшіруге болмайды.

Үш тәсілді салыстырудың нәтижесі 1-кестеде жинақталған.

1-кесте. Негізгі теориялық тәсілдердің салыстырмалы сипаттамасы

Өлшем	**Интеллектуалды оқыту жүйелері**	**Адаптивті платформалар**	**Генеративті модельдер**
Білімнің ұсынылуы	Нақты домендік модель (ережелер)	Тапсырмалар базасы мен қарапайым модель	Айқын модель жоқ, статистикалық
Кері байланыс көзі	Қадамдық диагностика	Нәтижеге байланысты бағыттау	Еркін мәтіндік жауап
Мұғалімнің рөлі	Мазмұнды әзірлеуші, бақылаушы	Бағыттаушы, мониторинг	Дизайнер, сын көзімен тексеруші
Дәлелдік база	Жақсы зерттелген, шектеулі салада	Әркелкі, әдісі әртүрлі	Қалыптасып келеді, шағын іріктемелер

Бұл кесте үшеуін бір шкалада «жақсы–нашар» деп орналастырмайды, өйткені әрқайсысы әртүрлі міндетке жарайды. Бір ашық сұрақ қалады: генеративті модельдің икемділігін интеллектуалды оқыту жүйелерінің құрылымдық бақылауымен біріктіруге бола ма. Мұндай гибридтік тәсіл логикалық тұрғыдан тартымды, бірақ қазіргі дәлелдер бұл туралы нақты қорытынды жасауға жеткіліксіз. Сондықтан оны әзірге дәлелденген шешім емес, зерттеу гипотезасы ретінде қарастырған жөн.

Интеграцияның дидактикалық шарттары

Жоғарыда талданған тәсілдерді салыстыру бір практикалық сұраққа әкеледі: интеграция қандай жағдайда оқуға көмектеседі, ал қандай жағдайда оны жеңілдетіп, бірақ тайыздатып жібереді. Әдебиеттегі дәлелдерді жинақтап, төрт шартты бөліп көрсетуге болады. Олар дайын модель емес, талдаудан шыққан жұмыс жүйесі ретінде ұсынылады.

Біріншісі көмектің қызметіне қатысты. Технологияны оқу тапсырмасының орындаушысы ретінде емес, тірек ретінде қою керек. Тірек идеясына сәйкес көмектің мөлшері білім алушы үйренген сайын азаюы тиіс [10]. Қарапайым тексеру тәсілі бар: тапсырма

аяқталған соң білім алушы ұқсас тапсырманы құралсыз орындай ала ма. Орындай алмаса, құрал оқытқан жоқ, тек тапсырманы орындады. Бастани мен әріптестерінің нәтижесі дәл осы тексеруге сәйкес келеді [11].

Екінші шарт педагогикалық мақсатқа сәйкестік. Бір құрал бір мақсатқа тиімді, екіншісіне зиянды болуы мүмкін. Мысалы, ақпаратты жүйелеуге немесе тілдік қателерді түзетуге көмектесетін құрал шығарма жазғанда ойды қалыптастыру жұмысын алмастырып жіберуі ықтимал. Сондықтан мақсаттың түрін (білімді меңгеру, дағды қалыптастыру, жоғары деңгейлі ойлау) алдын ала айқындап, соған қарай рұқсат етілетін көмек деңгейін белгілеген жөн. Бұл тұжырым логикалық талдауға сүйенеді, нақты пәндер бойынша оны эмпирикалық тексеру қажет.

Үшіншісі бағалаумен үйлесім. Оқыту мен бағалау әртүрлі ережемен жүрсе, мысалы оқу кезінде ЖИ рұқсат етіліп, бағалауда үнсіз тыйым салынса, білім алушы өз тактикасын бағалауға қарап таңдайды. Бағалау тек соңғы өнімді (мәтінді) тексерсе, ол өнімді кім немесе не жасағанын айыра алмайды. Сондықтан бағалауды процеске жылжыту интеграцияның жанама салдары емес, оның құрамдас бөлігі.

Төртіншісі мұғалімнің құзыреті мен автономиясы. Жүйе мұғалімнің бақылауынан тыс жұмыс істесе, педагогикалық шектеулерді енгізу мүмкіндігі жоғалады. Керісінше, мұғалім құралдың жауабын тексеруге, оған нұсқау жазуға және нәтижені түсіндіруге дайын болса, технологияның мүмкіндігі нақты қолданылады [2].

Практикалық аспектілер

Теориялық айырмашылықтар практикада төрт бағытта көрінеді: бағалау, кері байланыс, даралау және мұғалімнің жұмысы. Олар бір-бірімен тығыз байланысты, бірақ әрқайсысының өз түйіні бар.

Кері байланыс мәселесіне Хэтти мен Тимперли ұсынған көзқарас өте жақсы сәйкес келеді. Олардың пікірінше, кері байланыс тапсырма, процесс, өзін-өзі реттеу және тұлға деңгейінде берілуі мүмкін, ал процесс пен өзін-өзі реттеуге бағытталған байланыс тиімдірек [12]. Генеративті модель үшін «қате мынау, дұрысы мынау» деп жауап беру ең оңай жол, бірақ бұл тапсырма деңгейінен аспайды. Процесске бағытталған сұрақ қойдыру, мысалы «бұл қадамды не үшін таңдадың?», арнайы дидактикалық дизайнды қажет етеді. Жоғарыда сөз болған GPT Tutor мен GPT Base арасындағы айырмашылық дәл осы жерден шығады [11].

Даралауға келгенде, оны қарқынға бейімделумен шектеп алу қателік болар еді. Жүйе білім алушыны «өз деңгейінде» ұстап қалса, ол деңгейден шығуға итермелейтін қиындық жетіспей қалуы мүмкін. Бұл әзірге эмпирикалық дәлелдермен толық расталмаған болжам, бірақ ескеруге тұрарлық. Ашық чат құралдарын тиімді қолдану үшін оқушы өз білімінің шекарасын дұрыс бағалай алуы тиіс. Бастани мен әріптестері оқушылардың өз нәтижесін шындыққа қарағанда оптимистік бағалағанын да атап өтеді [11]. Яғни өзін-өзі реттеу дағдысы әлсіз оқушылар үшін еркін қолжетімділік тең мүмкіндік емес, керісінше, жаңа қауіп көзі болуы ықтимал.

Мұғалімнің рөлі туралы дау «алмастырады ма, алмастырмай ма» деген сұрақтан гөрі нәзік. Селвин жасанды интеллект мұғалімді толық алмастыруға әзірше жақын емес екенін, бірақ шын мәнінде жоғалуы мүмкін нәрсе, яғни педагогикалық қарым-қатынас пен кәсіби пайымның мәні екенін көрсетеді [2]. Практикалық тұрғыдан мұғалімге жаңа міндеттер жүктеледі: құралды таңдау, оның «қорғаныс шектеулерін» орнату, жауапты тексеру, аналитиканы түсіндіру. Рутиналық жұмыс (материал дайындау, тапсырмаларды саралау) азаюы мүмкін, бірақ оның орнына тексеру жұмысы келеді, ал таза уақыт үнемі туралы сенімді эмпирикалық дәлел аз. Мұғалімдердің жасанды интеллект бойынша құзыреттілігі бұл жерде шешуші шарт болып қалады.

Тәуекелдер

Тәуекелдерді техникалық және институционалдық деп бөлу ыңғайлы, бірақ іс жүзінде олар араласып жатады. Төменде төртеуі қарастырылады.

Академиялық адалдық мәселесі ең көп талқыланады. Дайын мәтін беретін модель дәстүрлі үй тапсырмасының дәлелдік мәнін төмендетті. Жауап ретінде көбіне «детекторлар»

ұсынылады, бірақ олардың сенімділігі күмәнді. Лян және әріптестері бірнеше детектордың ағылшын тілі ана тілі емес авторлардың мәтінін жиі жасанды деп қате жіктейтінін көрсеткен [13]. Нәтижені қазақ тіліндегі мәтіндерге тікелей көшіруге болмайды, бірақ тәуекелдің бағытын көрсетеді, әсіресе оқыту тілі қазақ, орыс және ағылшын арасында ауысатын көптілді ортада. Сондықтан детекторға сүйенгеннен гөрі бағалауды қайта жобалаған жөн: жұмыс барысын (жоба нұсқалары, жазбалар) бағалау, ауызша қорғау, сабақтағы орындалатын тапсырмалар.

Деректер құпиялығы білім беруде ерекше өткір, себебі пайдаланушылардың едәуір бөлігі кәмелетке толмағандар. Оқушының сұраулары оның білім деңгейі, қиындықтары және мінез-құлқы туралы көп нәрсе айтады, ал үшінші тарап платформасына жіберілген мұндай деректердің қайда сақталатыны әрдайым айқын емес. Қазақстандық кешенді жоспарда білім алушылардың жеке мәліметтерін қорғау бөлек бағыт ретінде көрсетілген [14], бірақ нақты тетіктер (келісім, сақтау мерзімі, шетелдік серверлерге беру) жеке нормативтік актілерде нақтылануы тиіс.

Цифрлық теңсіздікті жабдықпен қамтамасыз етумен шектеуге болмайды. Технологияға қолжетімділік тең болған күннің өзінде оны пайдалану дағдысы мен сапасы әртүрлі болуы мүмкін, және бұл айырмашылық оқушының отбасылық ортасы мен тілдік дайындығына байланысты тереңдеуі ықтимал. Генеративті құралдарға бұл ерекше қатысты, өйткені олардан көп пайда алу үшін дұрыс сұрақ қоя білу және жауапты сынай білу керек. Яғни интернет пен құрылғы бар мектептің өзінде нәтиже әртүрлі шығуы мүмкін.

Қазақстандық контекст

Қазақстанда 2026 жыл Цифрландыру және жасанды интеллект жылы деп жарияланды, ал құқықтық негіз 2025–2026 жылдары жылдам қалыптасты. Негізгі құжат «Жасанды интеллект туралы» 2025 жылғы 17 қарашадағы № 230-VIII ҚРЗ Заңы [5]. Орта білім беру үшін 2026 жылғы мамырда Президент Жарлығы қабылданды [6; 14]. Ақорда мәліметі бойынша, Жарлыққа сәйкес Үкімет 2026–2029 жылдарға арналған кешенді іс-шаралар жоспарын бекітуі тиіс, онда дербес оқыту тетігі, цифрлық инфрақұрылым, педагог кадрларды даярлау және білім алушылардың жеке мәліметтерін қорғау көзделген [14]. Ресми хабарламаларға қарағанда, Жарлықта мектептерді техникалық жабдықтау (оның ішінде тұрақты жоғары жылдамдықтағы интернетпен қамту), орта білім беруде жасанды интеллектіні қолдану стандарттарын және мұғалімдердің үздіксіз кәсіби дамуы жоспарын 2026 жылғы 1 қыркүйекке дейін бекіту межеленген, сонымен бірге жасанды интеллект мұғалімнің кәсіби қызметін алмастырмауы тиіс деген қағида көрсетілген [6].

Оқу мазмұнына енген өзгерістер де нақты. Оқу-ағарту министрлігінің мәліметінше, 1–4-сыныптардағы «Цифрлық сауаттылық» пәні «Цифрлық сауаттылық және жасанды интеллект» болып, 5–11-сыныптардағы «Информатика» «Информатика және жасанды интеллект» болып өзгертілді, бағдарламаларға ЖИ бойынша жаңа бөлімдер мен 43 оқу мақсаты қосылды [15].

Үшінші байқау нәтижелер туралы. Іске асыру тек 2025–2026 жылдары басталғандықтан, біздің білуімізше, қазақстандық мектептердегі оқу нәтижелеріне әсері туралы рецензияланған эмпирикалық зерттеулер әлі жоқ. Сондықтан бұл бөлімдегі тұжырымдар шынайы әсер туралы емес, жария етілген бағыттар мен олардың теориялық мүмкіндіктері туралы. Пилоттық жобаларды бағалау кезінде тек қанағаттану немесе қолдану жиілігін емес, кейінге қалдырылған тестілеу арқылы дербес меңгеруді өлшеу маңызды, өйткені Бастани мен әріптестерінің нәтижесі дәл осы айырмашылықты көрсетті [11].

Жалпы талқылау

Үш бөлімнің нәтижесін қосқанда бір заңдылық қайталанады: технология әсерінің бағыты оның өз қасиетінде емес, қолдану жағдайында жатыр. Интеллектуалды оқыту жүйелері қадамдық диагностика арқасында жұмыс істейді, адаптивті платформалар дайын тапсырмалар базасына сүйенеді, ал генеративті модель дизайн арқылы шектеу қойылғанда ғана тьюторға ұқсайды. Сондықтан «жасанды интеллект оқуға көмектесе ме?» деген сұрақ дұрыс қойылмаған. Дәлірек сұрақ мынадай: қандай көмек, кімге, қандай мақсат үшін және қандай бақылаумен беріледі.

Нәтижені түсіндірудің балама жолы да бар. Бір көзқарас бойынша, қысқа мерзімді өнімділіктің артуының өзі құнды: кейбір тапсырмалар үшін жасанды интеллект кәдімгі жұмыс құралына айналса, оны өз бетімен орындау қабілеті бұрынғыдай маңызды болмай қалады, ал оқу бағдарламасы осыған сай өзгеруі тиіс. Бұл пікірді толық жоққа шығармаймыз. Бірақ базалық түсінігі жоқ адам құралдың қателігін байқай алмайтынын ескерсек, дағдыны толық «сырттан алуға» беру қауіпті болып көрінеді. Сондықтан бұл дау әзірше ашық.

Нәтижені өлшеу тәсілі де дауды анықтайды. Практика кезіндегі өнімділік пен кейінге қалдырылған, құралсыз тестілеу әртүрлі нәрсені өлшейді, ал қолданыстағы зерттеулердің көбі бірінші көрсеткішпен шектеледі. Қанағаттану сауалнамасы мен қолдану жиілігі де оқу нәтижесінің дәлелі бола алмайды. Сондықтан пилоттық жобаларды бағалауда кемінде екі көрсеткішті бөлек қарастырған жөн: тапсырманы орындау сапасы және кейін, құралсыз көрсетілетін меңгеру деңгейі. Үшінші көрсеткіш ретінде білім алушының өз нәтижесін қаншалықты дәл бағалайтынын да қосуға болады, өйткені асыра бағалау жоғарыда аталған қауіптің белгісі.

Талдаудың шегін де айту керек. Біздің қорытындыларымыз негізінен ағылшын тіліндегі әдебиетке және аз ғана эмпирикалық зерттеуге сүйенеді. Қазақстандық мектептерден алынған бақылау деректері жоқ, сондықтан бұл тұжырымдар жергілікті жағдайда тексерілуі тиіс.

Қорытынды

Жасанды интеллектіні білім беру жүйесіне интеграциялаудың нәтижесін технологияның түрі емес, оның дидактикалық дизайны анықтайды. Интеллектуалды оқыту жүйелері құрылымдалған салада жақсы дәлелденген, бірақ ашық тапсырмаларға икемсіз. Адаптивті платформалардың көбі іс жүзінде қарқын мен реттілікті ғана бейімдейді және даралаумен тең емес. Генеративті модельдер ең үлкен мүмкіндік береді, бірақ көмекті біртіндеп азайту қарастырылмаса, қысқа мерзімді нәтижені жақсартып, өз бетінше меңгеруге зиян келтіруі мүмкін.

Практикалық тұрғыдан бағалауда модельді формативті, мұғалім бақылайтын рөлде қолдану, кері байланыста процеске бағытталған сұрақтарды алға шығару, мұғалімді жаңа міндеттерге (құралды таңдау, тексеру, шектеу орнату) дайындау негізгі бағыттар болып көрінеді. Басты тәуекелдер академиялық адалдықты бағалауды қайта жобалау қажеттігі, көптілді ортадағы тілдік біржақтылық, оқушылардың деректері және цифрлық теңсіздік.

Қазақстанда құқықтық және бағдарламалық негіз қалыптасты, алайда оның тиімділігі туралы эмпирикалық дәлел әзірше жоқ. Зерттеудің шектеуі де осында: мақала эмпирикалық деректерге емес, әдебиет пен нормативтік құжаттарды талдауға сүйенеді, ал генеративті модельдер бойынша дәлелдер бастапқы сатыда. Келесі қадам ретінде қазақ тілінде оқытылатын сыныптарда кейінге қалдырылған тестілеуі бар бақыланатын пилоттарды, сондай-ақ мұғалімдерді даярлау бағдарламаларының әсерін бағалауды ұсынамыз.

Әдебиеттер:

1. Kasneci E. et al. ChatGPT for good? On opportunities and challenges of large language models for education // Learning and Individual Differences. 2023. Vol. 103, 102274.

2. Selwyn N. Should Robots Replace Teachers? AI and the Future of Education. Cambridge: Polity, 2019.

3. VanLehn K. The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems // Educational Psychologist. 2011. Vol. 46, № 4.

4. Zawacki-Richter O. et al. Systematic review of research on artificial intelligence applications in higher education – where are the educators? // International Journal of Educational Technology in Higher Education. 2019. Vol. 16, Article 39.

5. «Жасанды интеллект туралы» Қазақстан Республикасының 2025 жылғы 17 қарашадағы № 230-VIII ҚРЗ Заңы. URL: https://adilet.zan.kz/kaz/docs/Z2500000230

6. «Қазақстан Республикасының орта білім беру жүйесіне жасанды интеллектіні ендіру жөніндегі шаралар туралы» ҚР Президентінің Жарлығы, 2026 ж. мамыр adilet.zan.kz.

7. Bloom B.S. The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring // Educational Researcher. 1984. Vol. 13, № 6. P. 4–16.
8. Anderson J.R., Corbett A.T., Koedinger K.R., Pelletier R. Cognitive tutors: Lessons learned // Journal of the Learning Sciences. 1995. Vol. 4, № 2. P. 167–207.
9. Pashler H., McDaniel M., Rohrer D., Bjork R. Learning styles: Concepts and evidence // Psychological Science in the Public Interest. 2008. Vol. 9, № 3. P. 105–119.
10. Wood D., Bruner J.S., Ross G. The role of tutoring in problem solving // Journal of Child Psychology and Psychiatry. 1976. Vol. 17, № 2. P. 89–100.
11. Bastani H., Bastani O., Sungu A., Ge H., Kabakcı Ö., Mariman R. Generative AI without guardrails can harm learning: Evidence from high school mathematics // Proceedings of the National Academy of Sciences. 2025. Vol. 122, № 26, e2422633122. https://doi.org/10.1073/pnas.2422633122
12. Hattie J., Timperley H. The power of feedback // Review of Educational Research. 2007. Vol. 77, № 1. P. 81–112.
13. Liang W., Yuksekgonul M., Mao Y., Wu E., Zou J. GPT detectors are biased against non-native English writers // Patterns. 2023. Vol. 4, № 7, 100779.
14. Президент орта білім беруге жасанды интеллектіні енгізу шаралары туралы Жарлыққа қол қойды // 24.kz.
15. Жасанды интеллект мектеп бағдарламасына енді // 24.kz.

ТЕОРЕТИЧЕСКИЕ И ПРАКТИЧЕСКИЕ АСПЕКТЫ ИНТЕГРАЦИИ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В СИСТЕМУ ОБРАЗОВАНИЯ

[1]Юртсевен М.К., [2]Ермурзаева А.Ш., [3]Тажибаева Б.Т.
[1]Старший преподаватель кафедры IT и цифровых технологий, PhD
Университет имени Ж.А. Ташенева, г. Шымкент
https://orcid.org/57225244254 , meruert_diana@mail.ru
[2]Старший преподаватель кафедры IT и цифровых технологий, магистр
Университет имени Ж.А. Ташенева, г. Шымкент
https://orcid.org/0009-0001-8625-4874, a_i_j_a_n_88@mail.ru
[3]Старший преподаватель кафедры IT и цифровых технологий, магистр
Университет имени Ж.А. Ташенева, г. Шымкент
https://orcid.org/0009-0007-2973-0065 ,b.tasbulatovna@mail.ru

Аннотация. В статье анализируются теоретические основы и практические условия интеграции технологий искусственного интеллекта в систему образования. Исследование выполнено в формате повествовательного обзора: литература отбиралась целенаправленно, а для казахстанского контекста проведён содержательный анализ нормативных документов. Интеллектуальные обучающие системы, адаптивные платформы и генеративные модели сопоставлены по критериям репрезентации знаний, источника обратной связи, роли преподавателя и доказательной базы. Анализ показывает, что результат интеграции определяется не типом технологии, а её дидактическим дизайном: генеративные инструменты без постепенного сокращения поддержки могут улучшать краткосрочные результаты, но ухудшать самостоятельное усвоение. К основным рискам отнесены академическая честность, языковая предвзятость, конфиденциальность данных и цифровое неравенство. В Казахстане сформирована нормативная база, однако эмпирических данных о её эффективности пока нет. Эмпирический эксперимент в работе не проводился, выводы носят аналитический характер.

Ключевые слова: искусственный интеллект; образование; интеллектуальные обучающие системы; генеративные модели; адаптивное обучение; педагогический дизайн; академическая честность.

THEORETICAL AND PRACTICAL ASPECTS OF INTEGRATING ARTIFICIAL INTELLIGENCE TECHNOLOGIES INTO THE EDUCATION SYSTEM

[1]Yurtseven M.K., [2]Ermurzaeva A., [3]Tazhibaeva B.T.
Senior Lecturer of the Department of IT and Digital Technologies, PhD
Zh.A. Tashenev University, Shymkent
https://orcid.org/57225244254 , meruert_diana@mail.ru
Senior Lecturer of the Department of IT and Digital Technologies, Master's degree
Zh.A. Tashenev University, Shymkent
https://orcid.org/0009-0001-8625-4874, a_i_j_a_n_88@mail.ru
Senior Lecturer of the Department of IT and Digital Technologies, Master's degree
Zh.A. Tashenev University, Shymkent
https://orcid.org/0009-0007-2973-0065 ,b.tasbulatovna@mail.ru

Abstract. The article examines the theoretical foundations and practical conditions for integrating artificial intelligence technologies into education. The study is a narrative review: literature was selected purposively, and a content analysis of regulatory documents was conducted for the Kazakhstani context. Intelligent tutoring systems, adaptive platforms and generative models are compared in terms of knowledge representation, the source of feedback, the teacher's role and the evidence base. The analysis suggests that outcomes depend less on the type of technology than on its instructional design: generative tools that do not gradually fade support may improve short-term performance while undermining independent learning. Academic integrity, language bias, data privacy and the digital divide are identified as the main risks. Kazakhstan has established a regulatory framework, but empirical evidence of its effectiveness is not yet available. No empirical experiment was conducted, so the conclusions are analytical in nature.

Keywords: artificial intelligence; education; intelligent tutoring systems; generative models; adaptive learning; instructional design; academic integrity.

UDC 378:004
IRSTI 14.35.09

DESIGNING INDIVIDUALIZED LEARNING TRAJECTORIES IN PROGRAMMING EDUCATION: AN EVIDENCE-INFORMED CONCEPTUAL FRAMEWORK

[1]Borankulov B.A., [2]Baizakova B.S., [3]Seitkhanova A.B.
[1]https://orcid.org/0009-0009-8168-948X
master of technical sciences, lecturer at the Department of «IT and Digital Technologies»,
Tashenev University, Shymkent, Kazakhstan
borankulovb@gmail.com
[2]https://orcid.org/0009-0008-5189-7774
master of technical sciences, senior lecturer at the Department of «IT and Digital Technologies»,
Tashenev University, Shymkent, Kazakhstan
baizakova72@gmail.com
[3]https://orcid.org/0009-0005-6541-1737
Master of natural sciences, senior lecturer at the Department of «IT and Digital Technologies»,
Tashenev University, Shymkent, Kazakhstan
sejthanovaajgerim1@gmail.com

Abstract. In introductory programming courses, students differ widely in prior knowledge, experience, problem-solving strategies, pace and motivation. Most courses, however, still lead them through one sequence of topics and tasks. Personalized and adaptive approaches have been explored, but research on them is fragmented and the evidence is mixed. The article is conceptual. It draws on an integrative review of work in computing education, educational psychology, intelligent tutoring, learning analytics and the ethics of educational technology, and asks how individualized learning trajectories for programming can be designed.

The analysis identifies five groups of learner characteristics that are relevant to trajectory design: concept-level prior knowledge; separate competences in code tracing, code writing, debugging and problem solving; self-regulation; motivation; and practical constraints. The proposed framework has eight stages. It links entry diagnosis, learner profiling, competency-gap analysis on a prerequisite map, individual objectives, task selection and sequencing, practice with formative feedback, progress evaluation and trajectory adjustment. Learner reflection runs through every stage rather than appearing as a separate final step.

Four revision triggers are specified: mastery, difficulty, dependence and engagement. Decisions are allocated among automated components, the teacher and the learner according to their consequences. The framework has not yet been validated empirically. It offers a structured basis for design and for future empirical testing.

Keywords: individualized learning trajectory, programming education, personalized learning, competency-based progression, formative feedback, learning analytics, self-regulated learning, generative AI.

Introduction

A first-year programming group can look less like one cohort than like several courses running in the same room. Some students have already built applications on their own; others have never written a line of code. Multi-institutional studies have shown that many students finish an introductory course unable to solve problems their teachers consider routine (McCracken et al., 2001), and a substantial share cannot reliably predict what a short code fragment will do (Lister et al., 2004). Reviews confirm that these difficulties are persistent and that there is no settled account of how instruction should respond to learner diversity (Luxton-Reilly et al., 2018; Robins et al., 2003).

Programming knowledge is unusually cumulative and unusually transparent to failure. Novices need a workable model of the notional machine, a formal notation, standard solution structures and the pragmatics of writing, testing and debugging programs (du Boulay, 1986). A student who misunderstands assignment will struggle with loop counters. A student who cannot trace a loop will find it hard to design one. With one common pace and sequence, some students fall behind while others are held back.

Individualization has long been one answer. Bloom's (1984) analysis of tutoring and mastery learning suggested that instruction adjusted to each learner's progress can produce far larger gains than group teaching. Intelligent tutoring systems, some of the earliest built for programming (Corbett & Anderson, 1994), can approach the effectiveness of human tutoring in well-defined domains (VanLehn, 2011). The broader evidence on personalized learning is less conclusive.

The term is used inconsistently (Bernacki et al., 2021), and a large evaluation found modest average gains with wide variation in implementation (Pane et al., 2017). In programming, adaptive systems have concentrated on automated assessment and hints that mostly tell students what is wrong rather than how to proceed (Keuning et al., 2019). Learning analytics has developed rich data sources but paid less attention to how they should inform instruction (Ihantola et al., 2015). Generative AI makes personalized help widely available while raising concerns about over-reliance (Denny et al., 2024; Prather et al., 2023). What is missing is a design account explaining how evidence about a learner should lead to a sequence of tasks, how that sequence should change, and who should decide.

An individualized learning trajectory, as understood here, is a planned but revisable sequence of objectives, tasks, resources and feedback arrangements. It is constructed for a specific learner on the basis of diagnostic evidence and updated as that evidence changes. The study develops and

justifies a conceptual framework for designing and revising such trajectories in university introductory programming courses. Three research questions guide the analysis:

RQ1. Which learner characteristics and programming competencies should be taken into account when designing individualized learning trajectories?

RQ2. How can diagnostic assessment, competency prerequisites and formative feedback be integrated into a coherent process for designing and revising a trajectory?

RQ3. What opportunities and limitations arise when learning analytics and AI-supported tools are used to adapt programming instruction?

The study is conceptual. It reports no new empirical data, and its framework has not yet been validated in a classroom. Its contribution lies in integrating a prerequisite map of programming competencies, a distinction between code-reading, code-writing and debugging evidence, formative feedback principles and an explicit division of decision-making authority between the system, the teacher and the learner.

Methods

The work is conceptual. It rests on an integrative literature review, not a systematic one. That choice follows from the research questions: they cut across fields that use different terminology and different study designs, and the aim was to construct a framework rather than estimate an effect. No PRISMA procedures were followed. No screening counts are reported.

The initial pool came from the author's knowledge of the field's core literature, keyword searches in a general academic search engine, and backward citation tracing from major reviews of introductory programming, automated feedback and personalized learning. Search terms paired individualization concepts - «personalized learning», «learning trajectory», «adaptive learning», «mastery learning» - with the domain («programming», «novice programmers», «CS1») and with mechanisms under study («formative feedback», «knowledge tracing», «learning analytics», «generative AI»).

A source was kept if it met four conditions: it appeared in a peer-reviewed venue, an established academic book or a report from a recognized research organization; it bore directly on one of the research questions; it offered a widely used theoretical contribution or relevant empirical or review evidence; and its metadata could be traced. Bibliographic records were verified in October 2026 against Crossref DOI records or, where those were unavailable, against publisher or repository pages.

Analysis proceeded in three stages. Claims relevant to trajectory design were coded under six headings: learner characteristics, competency structure, diagnosis, sequencing, feedback and support, and governance and ethics. The coded claims were then compared across sources. That comparison paid attention to how strong the evidence behind each claim was. In the final stage, the claims were translated into design decisions. For each stage of a trajectory, the question was: what information does this stage require, which decision follows from it, who takes that decision, and what evidence should trigger a revision? The framework, the triggers and the principles set out here are the author's proposals and hypotheses for empirical testing. They are not validated results.

Results

Learner characteristics and diagnostic evidence

What emerges from the literature is a set of learner characteristics that matter for trajectory design, along with the evidence that can reveal each one (Table 1). Adaptive systems research suggests a practical test for any learner model: it earns its place only if it captures characteristics that can actually change what the instruction does next (Bernacki et al., 2021; Brusilovsky & Millán,

2007). A model that tracks something interesting but leaves the next task unchanged adds little to a trajectory.

Table 1 - Learner characteristics, diagnostic indicators and implications for trajectory design in programming education

Learner characteristic	Diagnostic indicator and method	Interpretation	Implications for trajectory design
Concept-level prior knowledge	Accuracy on items for variables, conditions, loops, functions and lists; short concept inventory	Locates the learner on the prerequisite map; uneven profiles are common	Compress secure units; review weak prerequisites
Code tracing	Predicting output and variable states; tracing tables	Weak tracing indicates a fragile model of program execution	Begin units with tracing before writing tasks
Code writing	Correctness and structure of small solutions checked by unit tests	Separates syntax problems from gaps in solution templates	Choose completion, template-based or open tasks
Debugging competence	Steps and time to locate a seeded fault; submission history	Distinguishes systematic testing from random edits	Explicit debugging tasks with process-level hints
Algorithmic problem solving	Decomposition on a new problem with a planning prompt	Distinguishes knowledge gaps from strategy gaps	Problem-solving scaffolds; project tasks once units are secure
Self-regulation and motivation	Planning before coding, help-seeking pattern, self-efficacy; brief questionnaire	Premature coding, help avoidance or over-reliance; risk of withdrawal	Planning prompts, checkpoint reflection, early achievable successes
Pace and context	Available study time; access to devices; timing of activity	Constrains feasible workload, not learning needs	Adjust milestones and mode of work, not standards

Note: compiled by the author on the basis of Kalyuga et al. (2003), Lister et al. (2004), Robins et al. (2003), Xie et al. (2019), Zimmerman (2002), Prather et al. (2020) and Ihantola et al. (2015).

Concept-level prior knowledge remains the learner characteristic most consistently connected with instructional effects. The expertise reversal effect gives this a sharper edge: guidance that works for a novice can turn redundant, or even harmful, once the learner already knows more (Kalyuga et al., 2003). Programming makes that problem especially visible because prior knowledge is seldom uniform. A student may write loops fluently and still misunderstand parameter passing.

Programming competence also cannot be collapsed into conceptual knowledge. Many students who could not write a solution also could not trace code that had been given to them (Lister et al., 2004). Xie et al. (2019) therefore proposed teaching tracing, syntax, templates, and template-based writing as distinct skills in sequence. Debugging and problem-solving strategies form additional components (Robins et al., 2003).

The practical consequence is that a learner may look competent on one part of the subject while missing another part that instruction assumes.

Self-regulation matters because programming requires planning, monitoring, and evaluation across long episodes (Zimmerman, 2002). Metacognitive difficulties appear in programming-specific forms: students may begin coding before they understand the problem (Prather et al., 2020). Motivation shapes whether they persist after errors. Pace and context set limits on which trajectories

are feasible. These characteristics do not change at the same speed, so a trajectory needs different revision intervals for different parts of the learner profile.

The second result is a prerequisite map that serves as the backbone of trajectories. Its conceptual dimension covers values and variables, expressions and assignment, conditionals, loops, functions and parameters, and collections. A second dimension concerns the type of competence exercised on each topic: tracing, writing, debugging, and problem solving.

Their intersection yields competency units such as «tracing loops with accumulators» or «debugging off-by-one errors». Two ordering rules follow from the literature. Within a topic, tracing should precede writing (Lister et al., 2004; Xie et al., 2019). Across topics, a unit should be attempted only when its prerequisites have been demonstrated, following the logic of mastery learning (Bloom, 1984) and knowledge tracing (Corbett & Anderson, 1994). The map is not a single linear path. That flexibility is precisely what makes individual trajectories possible.

The central result is an eight-stage cycle for designing and revising trajectories. Learner reflection runs through all stages (Figure 1), which addresses RQ2.

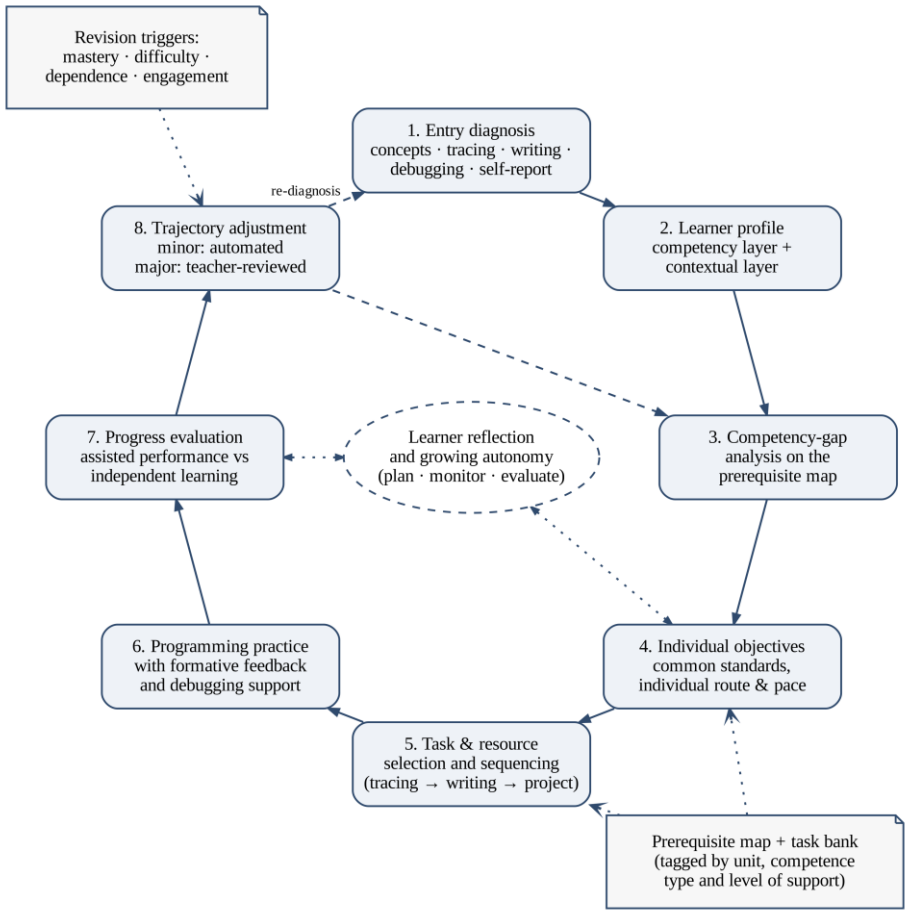


Figure 1 - Proposed framework for designing and revising individualized learning trajectories in programming education

Note: original conceptual diagram developed by the author; it is not a screenshot of an existing system.

The cycle opens with an entry diagnosis. It combines a short concept inventory, tracing items, small writing and debugging tasks, and a brief self-report. The purpose is to locate the learner on the prerequisite map, not to rank learners. Stage two builds a learner profile. Its competency layer is expressed relative to the prerequisite map following the overlay approach (Brusilovsky & Millán,

2007); a contextual layer sits alongside it. Stage three identifies competency gaps and gives priority to missing prerequisites for several later units.

Stage four turns gaps into individual objectives. Standards remain common, while route, pace, and milestones differ. Stage five selects and sequences tasks from a bank tagged by unit, competence type, and level of support. A learner with a gap in loop tracing moves from tracing tables to completion tasks and only then to writing loops from a specification. A fluent learner covers the same unit through a short check and an open task. That contrast follows the expertise reversal effect (Kalyuga et al., 2003).

Stage six is practice with formative feedback from automated tests, tutoring tools or AI assistants, and the teacher. Data-driven tutors can generate next-step hints from earlier students' solutions (Rivers & Koedinger, 2017).

Feedback should tell learners where they are going, how they are progressing, and what comes next, at the levels of task, process, and self-regulation (Hattie & Timperley, 2007). Its timing can itself be individualized (Shute, 2008). Debugging hints should first help the learner locate the fault and form a hypothesis before any correction is offered.

Stage seven evaluates progress at agreed checkpoints, distinguishing performance on assisted tasks from learning shown on unassisted transfer tasks. Stage eight adjusts the trajectory: minor changes such as adding practice items can be automated, while major changes such as returning to an earlier unit are reviewed by the teacher and discussed with the learner. Table 2 summarizes the decisions and revision conditions of each stage.

Table 2 - Stages of individualized learning trajectory design in programming education

Stage and objective	**Required input data**	**Instructional decision**	**Conditions for revising the trajectory**
1. Entry diagnosis	Concept, tracing, writing and debugging items; self-report	Starting point on each strand of the map	Diagnosis contradicts early practice
2. Learner profile	Diagnostic results; self-regulation, motivation, constraints	Which parts of the profile need frequent updating	New evidence changes the status of a unit
3. Competency-gap analysis	Profile; course objectives; prerequisite map	Order of units; prerequisite gaps first	A unit becomes secure or a new gap appears
4. Individual objectives	Gap list; learner goals; time available	Milestones and pace; common standards	Milestones repeatedly missed or reached early
5. Task selection and sequencing	Task bank tagged by unit, competence type and support	Next tasks: tracing → completion → writing → project	Mastery or difficulty trigger
6. Practice with formative feedback	Submissions, test results, hint and AI use, error patterns	Type and timing of feedback; hints locate faults first	Dependence trigger
7. Progress evaluation	Assisted and unassisted results across task formats	Whether a unit is secure	Assisted and unassisted results diverge

Stage and objective	Required input data	Instructional decision	Conditions for revising the trajectory
8. Trajectory adjustment	Evaluation results; triggers; learner reflection	Minor changes automated; major changes teacher-reviewed	Engagement trigger or proposal to return to an earlier unit

Note: the framework and revision conditions are proposed by the author; the underlying principles draw on Bloom (1984), Corbett and Anderson (1994), Hattie and Timperley (2007), Shute (2008), Kalyuga et al. (2003) and Zimmerman (2002).

Decision triggers and the division of authority.

A revision should not follow from a single data point. The evidence has to converge. A mastery trigger fires when the learner succeeds on unassisted tasks for a unit in at least two task formats, after which the unit is marked as secure. A difficulty trigger appears when repeated failure coincides with error patterns that point to a prerequisite. Persistent off-by-one errors, for instance, signal weak loop tracing, and a targeted return is then proposed. A dependence trigger surfaces when the learner succeeds only with heavy hint use or AI assistance and fails on comparable unassisted tasks; support is reduced in steps. An engagement trigger-falling activity, missed deadlines, or lower confidence-calls mainly for a human response: the teacher contacts the learner before any change to content.

Authority follows from the type of trigger. Automated components handle fine-grained, reversible decisions, such as selecting the next item or hint level, where evidence is immediate and errors are cheap. The teacher decides on consequential or ambiguous matters, such as returning to an earlier unit or interpreting a drop in engagement. The learner takes part in all decisions affecting objectives and pace and is gradually encouraged to propose adjustments, which is how the framework aims to build autonomy (Panadero, 2017; Zimmerman, 2002).

Compared with fixed sequencing, differentiated instruction organized around groups and lessons (Tomlinson, 2014) and generic adaptive platforms that leave teachers little visibility (Zawacki-Richter et al., 2019), the framework maintains an individual path across units, task types and support levels while keeping consequential decisions under human review.

Discussion

For RQ1, the synthesis points to concept-level prior knowledge as the primary basis for trajectory design, together with separate estimates of tracing, writing, debugging and problem-solving competence. Self-regulation, motivation and context shape how a learner is taught rather than what. For RQ2, diagnosis, prerequisite structure and formative feedback can be connected in a single cycle with explicit revision conditions. For RQ3, analytics and AI tools are valuable for fine-grained adaptation, but several risks limit their authority.

Programming offers a stronger basis for adaptation by knowledge state than many domains because its concepts are tightly dependent and its performance evidence is rich, which is consistent with the success of knowledge-tracing tutors (Corbett & Anderson, 1994; VanLehn, 2011). That claim needs qualification. Prerequisite maps are themselves hypotheses, and tutoring evidence comes largely from narrowly defined tasks. The tracing-before-writing rule is therefore treated as a default to be relaxed when diagnostic evidence shows that a learner benefits from another route.

The relationship between automation and the teacher remains the most contested design question. Fine-grained automated adaptation can be effective (VanLehn, 2011), yet research on AI in higher education has involved few educators and limited critical reflection on pedagogy and ethics (Zawacki-Richter et al., 2019). Allocating authority by the consequences of a decision and the ambiguity of its evidence is the author's proposal; it assumes that teachers have the time and tools to review consequential decisions, which may not hold in large courses.

Learner data are plentiful but not self-interpreting. Predicting an outcome is not the same as knowing how to improve it (Hellas et al., 2018), and analytics detached from learning theory can

mislead: many submissions may indicate productive iteration in one course and guessing in another (Gašević et al., 2015).

The framework therefore requires convergent evidence and gives priority to purposely designed diagnostic tasks. Generative AI sharpens the problem of assisted performance: assistants can produce explanations and exercises cheaply, but also complete solutions (Denny et al., 2024; Prather et al., 2023). Tools such as CodeAid, which gives conceptual help rather than full code, show both the value of such help and the difficulty of balancing student wishes with educators' concerns (Kazemitabaar et al., 2024). Whether the dependence trigger can reliably separate productive from unproductive reliance is an open empirical question.

Individualized trajectories depend on continuous data collection, which raises questions of consent, transparency and purpose; learning analytics should treat students as active agents rather than objects of measurement (Slade & Prinsloo, 2013). Educational models can perform differently for different groups (Baker & Hawn, 2022), so adaptation rules should be audited, for example for how often they route particular groups back to remedial units. Learners with limited access to devices may generate less data and receive less accurate adaptation. Trajectories are most likely to be effective when the course has an explicit competency map, a task bank tagged by unit, competence type and support level, teachers with time to review consequential decisions, and learners guided to take part in planning; otherwise simpler differentiation may be more realistic.

The study is conceptual and untested; the review was not exhaustive; much of the cited evidence comes from English-speaking universities and narrow tasks; and trigger thresholds require empirical calibration. Future research should validate the prerequisite map and diagnostic instruments for a specific course, refine the framework through design-based iterations, and then compare it with a fixed-sequence course on independent competence, debugging and self-regulation, with particular attention to future informatics teachers.

Conclusion

The article examined how individualized learning trajectories can be designed for programming students who differ in prior knowledge, competence, strategies, pace and motivation. On the first research question, prior knowledge should not be collapsed into a single score, and competence should not be treated as one undifferentiated ability.

On the second, the article proposes an eight-stage cycle linking entry diagnosis, learner profiling, gap analysis, individual objectives, task selection, practice with formative feedback, progress evaluation and trajectory adjustment, relying on explicit revision triggers. On the third, learning analytics and AI-supported tools suit fine-grained, reversible adaptation but should not have final authority over consequential decisions, because learner data are incomplete, models can be biased and assisted performance can be mistaken for learning.

For programming educators, the practical implications are to make the course's prerequisite structure explicit, tag tasks by competence type and level of support, distinguish assisted from independent success and reserve consequential changes for human review. The framework remains a proposal; its next step is a design-based implementation in an introductory programming course, followed by comparative studies of its effects on independent competence, debugging and self-regulation.

References:

1. Baker, R. S., & Hawn, A. (2022). Algorithmic bias in education. International Journal of Artificial Intelligence in Education, 32(4), 1052–1092. https://doi.org/10.1007/s40593-021-00285-9

2. Bernacki, M. L., Greene, M. J., & Lobczowski, N. G. (2021). A systematic review of research on personalized learning: Personalized by whom, to what, how, and for what purpose(s)? Educational Psychology Review, 33(4), 1675–1715. https://doi.org/10.1007/s10648-021-09615-8

3. Bloom, B. S. (1984). The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring. Educational Researcher, 13(6), 4–16. https://doi.org/10.3102/0013189X013006004

4. Brusilovsky, P., & Millán, E. (2007). User models for adaptive hypermedia and adaptive educational systems. In P. Brusilovsky, A. Kobsa, & W. Nejdl (Eds.), The adaptive web: Methods and strategies of web personalization (Lecture Notes in Computer Science, Vol. 4321, pp. 3–53). Springer. https://doi.org/10.1007/978-3-540-72079-9_1

5. Corbett, A. T., & Anderson, J. R. (1994). Knowledge tracing: Modeling the acquisition of procedural knowledge. User Modeling and User-Adapted Interaction, 4(4), 253–278. https://doi.org/10.1007/BF01099821

6. Denny, P., Prather, J., Becker, B. A., Finnie-Ansley, J., Hellas, A., Leinonen, J., Luxton-Reilly, A., Reeves, B. N., Santos, E. A., & Sarsa, S. (2024). Computing education in the era of generative AI. Communications of the ACM, 67(2), 56–67. https://doi.org/10.1145/3624720

7. du Boulay, B. (1986). Some difficulties of learning to program. Journal of Educational Computing Research, 2(1), 57–73. https://doi.org/10.2190/3LFX-9RRF-67T8-UVK9

8. Gašević, D., Dawson, S., & Siemens, G. (2015). Let's not forget: Learning analytics are about learning. TechTrends, 59(1), 64–71. https://doi.org/10.1007/s11528-014-0822-x

9. Hattie, J., & Timperley, H. (2007). The power of feedback. Review of Educational Research, 77(1), 81–112. https://doi.org/10.3102/003465430298487

10. Hellas, A., Ihantola, P., Petersen, A., Ajanovski, V. V., Gutica, M., Hynninen, T., Knutas, A., Leinonen, J., Messom, C., & Liao, S. N. (2018). Predicting academic performance: A systematic literature review. In Proceedings Companion of the 23rd Annual ACM Conference on Innovation and Technology in Computer Science Education (ITiCSE 2018 Companion) (pp. 175–199). ACM. https://doi.org/10.1145/3293881.3295783

11. Ihantola, P., Vihavainen, A., Ahadi, A., Butler, M., Börstler, J., Edwards, S. H., Isohanni, E., Korhonen, A., Petersen, A., Rivers, K., Rubio, M. Á., Sheard, J., Skupas, B., Spacco, J., Szabo, C., & Toll, D. (2015). Educational data mining and learning analytics in programming: Literature review and case studies. In Proceedings of the 2015 ITiCSE on Working Group Reports (pp. 41–63). ACM. https://doi.org/10.1145/2858796.2858798

12. Kalyuga, S., Ayres, P., Chandler, P., & Sweller, J. (2003). The expertise reversal effect. Educational Psychologist, 38(1), 23–31. https://doi.org/10.1207/S15326985EP3801_4

13. Kazemitabaar, M., Ye, R., Wang, X., Henley, A. Z., Denny, P., Craig, M., & Grossman, T. (2024). CodeAid: Evaluating a classroom deployment of an LLM-based programming assistant that balances student and educator needs. In Proceedings of the CHI Conference on Human Factors in Computing Systems (CHI '24). ACM. https://doi.org/10.1145/3613904.3642773

14. Keuning, H., Jeuring, J., & Heeren, B. (2019). A systematic literature review of automated feedback generation for programming exercises. ACM Transactions on Computing Education, 19(1), Article 3. https://doi.org/10.1145/3231711

15. Lister, R., Adams, E. S., Fitzgerald, S., Fone, W., Hamer, J., Lindholm, M., McCartney, R., Moström, J. E., Sanders, K., Seppälä, O., Simon, B., & Thomas, L. (2004). A multi-national study of reading and tracing skills in novice programmers. ACM SIGCSE Bulletin, 36(4), 119–150. https://doi.org/10.1145/1044550.1041673

16. Luxton-Reilly, A., Simon, Albluwi, I., Becker, B. A., Giannakos, M., Kumar, A. N., Ott, L., Paterson, J., Scott, M. J., Sheard, J., & Szabo, C. (2018). Introductory programming: A systematic literature review. In Proceedings Companion of the 23rd Annual ACM Conference on Innovation and Technology in Computer Science Education (ITiCSE 2018 Companion) (pp. 55–106). ACM. https://doi.org/10.1145/3293881.3295779

17. McCracken, M., Almstrum, V., Diaz, D., Guzdial, M., Hagan, D., Ben-David Kolikant, Y., Laxer, C., Thomas, L., Utting, I., & Wilusz, T. (2001). A multi-national, multi-institutional study of assessment of programming skills of first-year CS students. In Working Group Reports from ITiCSE on Innovation and Technology in Computer Science Education (pp. 125–180). ACM. https://doi.org/10.1145/572133.572137

18. Panadero, E. (2017). A review of self-regulated learning: Six models and four directions for research. Frontiers in Psychology, 8, Article 422. https://doi.org/10.3389/fpsyg.2017.00422

19. Pane, J. F., Steiner, E. D., Baird, M. D., Hamilton, L. S., & Pane, J. D. (2017). Informing progress: Insights on personalized learning implementation and effects (Research Report RR-2042-BMGF). RAND Corporation. https://doi.org/10.7249/RR2042

20. Prather, J., Becker, B. A., Craig, M., Denny, P., Loksa, D., & Margulieux, L. (2020). What do we think we think we are doing? Metacognition and self-regulation in programming. In Proceedings of the 2020 ACM Conference on International Computing Education Research (pp. 2–13). ACM. https://doi.org/10.1145/3372782.3406263

21. Prather, J., Denny, P., Leinonen, J., Becker, B. A., Albluwi, I., Craig, M., Keuning, H., Kiesler, N., Kohn, T., Luxton-Reilly, A., MacNeil, S., Petersen, A., Pettit, R., Reeves, B. N., & Savelka, J. (2023). The robots are here: Navigating the generative AI revolution in computing education. In Proceedings of the 2023 Working Group Reports on Innovation and Technology in Computer Science Education (pp. 108–159). ACM. https://doi.org/10.1145/3623762.3633499

22. Rivers, K., & Koedinger, K. R. (2017). Data-driven hint generation in vast solution spaces: A self-improving Python programming tutor. International Journal of Artificial Intelligence in Education, 27(1), 37–64. https://doi.org/10.1007/s40593-015-0070-z

23. Robins, A., Rountree, J., & Rountree, N. (2003). Learning and teaching programming: A review and discussion. Computer Science Education, 13(2), 137–172. https://doi.org/10.1076/csed.13.2.137.14200

24. Shute, V. J. (2008). Focus on formative feedback. Review of Educational Research, 78(1), 153–189. https://doi.org/10.3102/0034654307313795

25. Slade, S., & Prinsloo, P. (2013). Learning analytics: Ethical issues and dilemmas. American Behavioral Scientist, 57(10), 1510–1529. https://doi.org/10.1177/0002764213479366

26. Tomlinson, C. A. (2014). The differentiated classroom: Responding to the needs of all learners (2nd ed.). ASCD.

27. VanLehn, K. (2011). The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. Educational Psychologist, 46(4), 197–221. https://doi.org/10.1080/00461520.2011.611369

28. Xie, B., Loksa, D., Nelson, G. L., Davidson, M. J., Dong, D., Kwik, H., Tan, A. H., Hwa, L., Li, M., & Ko, A. J. (2019). A theory of instruction for introductory programming skills. Computer Science Education, 29(2–3), 205–253. https://doi.org/10.1080/08993408.2019.1565235

29. Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education -where are the educators? International Journal of Educational Technology in Higher Education, 16, Article 39. https://doi.org/10.1186/s41239-019-0171-0

30. Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. Theory Into Practice, 41(2), 64–70. https://doi.org/10.1207/s15430421tip4102_2

БАҒДАРЛАМАЛАУҒА ОҚЫТУДА ЖЕКЕ БІЛІМ БЕРУ ТРАЕКТОРИЯЛАРЫН ЖОБАЛАУ: ДӘЛЕЛДЕРГЕ НЕГІЗДЕЛГЕН ТҰЖЫРЫМДАМАЛЫҚ ҮЛГІ

[1]Боранкулов Б.А., [2]Байзакова Б.С., Сейтханова Ә.Б.

[1]https://orcid.org/0009-0009-8168-948X

техника ғылымдарының магистрі, «IT және цифрлық технологиялар» кафедрасының оқытушысы, Ж.А.Ташенев атындағы университет, Шымкент, Қазақстан

borankulovb@gmail.com

[2]https://orcid.org/0009-0008-5189-7774

техника ғылымдарының магистрі, «IT және цифрлық технологиялар» кафедрасының аға оқытушысы, Ж.А.Ташенев атындағы университет, Шымкент, Қазақстан

baizakova72@gmail.com

[3]https://orcid.org/0009-0005-6541-1737

жаратылыстану ғылымдарының магистрі, «IT және цифрлық технологиялар»
кафедрасының аға оқытушысы,
Ж.А.Тәшенев атындағы университет, Шымкент, Қазақстан
sejthanovaajgerim1@gmail.com

Аңдатпа. Бағдарламалау негіздерін оқитын студенттер алдыңғы білімі, тәжірибесі, есеп шығару стратегиялары, оқу қарқыны және уәждемесі бойынша айтарлықтай ерекшеленеді, алайда курстардың басым бөлігі оларды бірыңғай тақырыптар мен тапсырмалар реті бойынша оқытады. Компьютерлік білім беру, педагогикалық психология, зияткерлік оқыту жүйелері, оқу аналитикасы және білім беру технологияларының этикасы саласындағы зерттеулерге интегративті шолуға негізделген осы тұжырымдамалық зерттеу бағдарламалауға оқытуда жеке білім беру траекторияларын жобалау жолдарын қарастырады. Траекторияны жобалау үшін маңызды білім алушы сипаттамаларының бес тобы анықталды: ұғымдар деңгейіндегі алдыңғы білім; кодты қадағалау, код жазу, ақауларды түзету және есеп шығару құзыреттері; өзін-өзі реттеу; уәждеме; практикалық шектеулер. Осы негізде бастапқы диагностикадан траекторияны түзетуге дейінгі сегіз кезеңді үлгі ұсынылады; білім алушының рефлексиясы барлық кезеңдерді қамтиды. Үлгі түзетудің төрт себебін (меңгеру, қиындық, тәуелділік, белсенділік) айқындайды және шешімдерді салдарына қарай автоматтандырылған құралдар, оқытушы және білім алушы арасында бөледі. Үлгі әзірге эмпирикалық тұрғыда тексерілмеген.

Түйін сөздер: жеке білім беру траекториясы, бағдарламалауға оқыту, дербестендірілген оқыту, құзыреттілікке негізделген оқыту, қалыптастырушы кері байланыс, оқу аналитикасы, өзін-өзі реттеп оқу, генеративті жасанды интеллект.

ПРОЕКТИРОВАНИЕ ИНДИВИДУАЛЬНЫХ ОБРАЗОВАТЕЛЬНЫХ ТРАЕКТОРИЙ ПРИ ОБУЧЕНИИ ПРОГРАММИРОВАНИЮ: КОНЦЕПТУАЛЬНАЯ МОДЕЛЬ, ОСНОВАННАЯ НА НАУЧНЫХ ДАННЫХ

Боранкулов Б.А.., Байзакова Б.С.
https://orcid.org/0009-0009-8168-948X
магистр технических наук, преподаватель кафедры «IT и цифровых технологий»
университет имени Ж.А. Ташенева, Шымкент, Казахстан
borankulovb@gmail.com
https://orcid.org/0009-0008-5189-7774
магистр технических наук, старший преподаватель кафедры «IT и цифровых технологий» университет имени Ж.А. Ташенева,
Шымкент, Казахстан
baizakova72@gmail.com

Аннотация. Студенты, изучающие основы программирования, существенно различаются по предварительным знаниям, опыту, стратегиям решения задач, темпу обучения и мотивации, однако большинство курсов ведёт их по единой последовательности тем и заданий. Настоящее концептуальное исследование, основанное на интегративном обзоре работ в области компьютерного образования, педагогической психологии, интеллектуальных обучающих систем, учебной аналитики и этики образовательных технологий, рассматривает, каким образом можно проектировать индивидуальные образовательные траектории при обучении программированию.

Выделены пять групп характеристик обучающихся, значимых для проектирования траектории: предварительные знания на уровне понятий; компетенции в трассировке кода, написании кода, отладке и решении задач; саморегуляция; мотивация; практические ограничения. На этой основе предложена восьмиэтапная модель от входной диагностики до корректировки траектории; рефлексия обучающегося охватывает все этапы.

Модель определяет четыре основания для пересмотра траектории (освоение, затруднение, зависимость от помощи, вовлечённость) и распределяет решения между автоматизированными средствами, преподавателем и обучающимся в зависимости от их последствий. Модель пока не прошла эмпирическую проверку.

Ключевые слова: индивидуальная образовательная траектория, обучение программированию, персонализированное обучение, компетентностно-ориентированное обучение, формирующая обратная связь, учебная аналитика, саморегулируемое обучение, генеративный искусственный интеллект.

«ТӘШЕНЕВ ХАБАРШЫСЫ – ВЕСТНИК ТАШЕНЕВА» №2(9) 2026

Iztileuova A.Zh., **Yeszhanova G.D.** THE ROLE OF ARTIFICIAL INTELLIGENCE IN ENHANCING ENGLISH LANGUAGE TEACHING AND LEARNING: OPPORTUNITIES, CHALLENGES AND FUTURE PERSPECTIVES.....	**4**
Сматұлла Т.Б., Изханова Б.Е., Сейтханова Ә.Б. ҚАЗАҚСТАН ЖОҒАРЫ ОҚУ ОРЫНДАРЫ ВЕБ-САЙТТАРЫНЫҢ ЖҮКТЕЛУ ЖЫЛДАМДЫҒЫНА ӘСЕР ЕТЕТІН ФАКТОРЛАР: ЭМПИРИКАЛЫҚ ТАЛДАУ.....	**12**
Турсунова Т.Ж., Орынбекова Г.К. КОММУНИКАТИВНЫЙ ПОДХОД К ОБУЧЕНИЮ ПРОИЗНОШЕНИЮ В ИНОЯЗЫЧНОЙ АУДИТОРИИ.....	**20**
Агидилова Е.А. ЭФФЕКТИВНОЕ ИНТЕГРИРОВАНИЕ ИСТОРИЧЕСКИХ МАТЕРИАЛОВ О ЖУМАБЕК АХМЕТУЛЫ ТАШЕНЕВЕ В ЗАНЯТИЯ ПО Р	**26**
Джанпаизова В.М.,. Рахманкулова Ж.А, Камалбаева К.К., Байтелеева Ж.Е. КҮРДЕЛІ ҚҰРЫЛЫМДЫ ЖӘНЕ ПІШІНДІ КИІМДЕРДІ ЖОБАЛАУДА ДӘСТҮРЛІ ЖӘНЕ 3D ЦИФРЛЫҚ ӘДІСТЕРДІ БІРІКТІРУ.....	**38**
Жолшиева А.З., Мұсабекова Б.С., Аббаз Н. Б. МАШИНАЛЫҚ ОҚЫТУ МОДЕЛЬДЕРІНІҢ ТҮСІНДІРМЕЛІЛІГІН БАҒАЛАУ ӘДІСТЕРІН ЗЕРТТЕУ: FEATURE IMPORTANCE ЖӘНЕ SHAP НӘТИЖЕЛЕРІН САЛЫСТЫРУ.....	**47**
Borankulov B.A., Nakhipova V.I., Kuatbek N.B. USING LEARNING ANALYTICS TO PERSONALIZE PROGRAMMING EDUCATION.....	**57**
Рахметуллақызы А., Баязиева М.Н., Базарбекова Н. ВАЙБ-КОДИНГ: ЖАСАНДЫ ИНТЕЛЛЕКТ КӨМЕГІМЕН БАҒДАРЛАМАЛАУДЫҢ АРТЫҚШЫЛЫҚТАРЫ МЕН ТӘУЕКЕЛДЕРІ	**69**
Юртсевен М.К., Ермурзаева А.Ш., Тажибаева Б.Т. ЖАСАНДЫ ИНТЕЛЛЕКТ ТЕХНОЛОГИЯЛАРЫН БІЛІМ БЕРУ ЖҮЙЕСІНЕ ИНТЕГРАЦИЯЛАУДЫҢ ТЕОРИЯЛЫҚ ЖӘНЕ ПРАКТИКАЛЫҚ АСПЕКТІЛЕРІ.....	**76**
Borankulov B.A., Baizakova B.S., Seitkhanova A.B. DESIGNING INDIVIDUALIZED LEARNING TRAJECTORIES IN PROGRAMMING EDUCATION: AN EVIDENCE-INFORMED CONCEPTUAL FRAMEWORK.....	**84**