



YASSAWI

JOURNAL OF ENGINEERING SCIENCE



TURKISTAN 2026

ҚҰРЫЛТАЙШЫ:

Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті

Журнал Қазақстан Республикасы Мәдениет және ақпарат министрлігі Ақпарат комитетінде 2026 жылдың 26 ақпанда тіркелген және «Мерзімді баспасөз басылымдарын, интернет-басылымдарды есепке қою туралы» № KZ44VPY00141439 куәлігі берілген.

Шығу жиілігі: 3 айда 1 рет.

Басылым тілдері: қазақша, түрікше, орысша, ағылшынша
Таралу аумағы: Қазақстан Республикасы, алыс және жақын шетел.

KURUCU:

Hoca Ahmet Yesevi Uluslararası Kazak-Türk Üniversitesi

Dergi, Kazakistan Cumhuriyeti Kültür ve Enformasyon Bakanlığı Enformasyon Komitesi tarafından 26 Şubat 2026 tarihinde tescil edilmiş olup, süreli basılı ve çevrimiçi yayınların kaydına ilişkin KZ44VPY00141439 numaralı sertifikaya sahiptir.

Yayın sıklığı: 3 ayda 1 kez.

Yayın dilleri: Kazakça, Türkçe, İngilizce, Rusça.

Dağıtım alanı: Kazakistan Cumhuriyeti, yakın ve uzak yurt dışı.

УЧРЕДИТЕЛЬ:

Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави

Журнал зарегистрирован в Комитете информации Министерства культуры и информации Республики Казахстан 26 февраля 2026 года и имеет свидетельство № KZ44VPY00141439.

«О регистрации периодических изданий, онлайн-публикаций»

Периодичность выхода: 1 раз в 3 месяца.

Языки издания: казахский, турецкий, английский, русский.

Территория распространения: Республика Казахстан, ближнее и дальнее зарубежье.

FOUNDER:

Khoja Akhmet Yassawi International Kazakh-Turkish University

The journal was registered with the Information Committee of the Ministry of Culture and Information of the Republic of Kazakhstan on February 26, 2026 and was issued the registration certificate № KZ44VPY00141439 for periodical print and online publications.

Publication frequency: once every 3 months.

Languages of publication: Kazakh, Turkish, English, Russian.

Distribution area: Republic of Kazakhstan, near and far abroad.

РЕДАКЦИЯЛЫҚ АЛҚА МҮШЕЛЕРІ

Мамырбаев О.Ж.	- PhD, профессор /Қазақстан/
Жумадилаева А.К.	- тех.ғ.к., қауымд. профессор /Қазақстан/
Казбекова Г.Н.	- тех.ғ.к., қауымд. профессор /Қазақстан/
Айдын Четин	- доктор, профессор /Түркия/
Мухаммет Али Акчайол	- доктор, профессор /Түркия/
Каражан Хажер	- доктор, профессор /Түркия/
Исмаилова Рита	- доктор, доцент /Қырғызстан/
Омаров Б.С.	- PhD, қауымдастырылған профессор /Қазақстан/
Нажи Генч	- доктор, профессор /Қазақстан/
Эгамбердиев Б.Э.	- техн.ғ.д., профессор /Өзбекстан/
Абдимуратов Ж.С.	- PhD, доцент /Қазақстан/
Четин Генчер	- доктор, доцент /Қазақстан/
Турымбетова Г.Д.	- PhD, доцент /Қазақстан/
Абдуллаев Вугар	- PhD, доцент /Әзірбайжан/

DANIŞMA KURULU

Mamyrbayev O.Zh.	- PhD, Profesör /Kazakistan/
Zhumadillayeva A.K.	- Teknik Bilimler Adayı, Doçent /Kazakistan/
Kazbekova G.N.	- Teknik Bilimler Adayı, Doçent /Kazakistan/
Aydın Çetin	- Doktor, Profesör /Türkiye/
Muhammet Ali Akçayol	- Doktor, Profesör /Türkiye/
Karacan Hacer	- Doktor, Profesör /Türkiye/
Ismailova Rita	- Doktor, Doçent /Kırgızistan/
Omarov B.S.	- PhD, Doçent /Kazakistan/
Naci Genç	- Doktor, Profesör /Kazakistan/
Egamberdiev B.E.	- Teknik Bilimler Doktoru, Profesör /Özbekistan/
Abdimuratov Zh.S.	- PhD, Doçent /Kazakistan/
Çetin Gençer	- Doktor, Doçent /Kazakistan/
Turymbetova G.D.	- PhD, Doçent /Kazakistan/
Abdullaev Vugar	- PhD, Doçent /Azerbaycan/

РЕДАКЦИОННАЯ КОЛЛЕГИЯ

Мамырбаев О.Ж.	- PhD, профессор /Казakhstan/
Жумадилаева А.К.	- канд. техн. наук, ассоц. профессор /Казakhstan/
Казбекова Г.Н.	- канд. техн. наук, ассоц. профессор /Казakhstan/
Айдын Четин	- доктор, профессор /Турция/
Мухаммет Али Акчайол	- доктор, профессор /Турция/
Каражан Хажер	- доктор, профессор /Турция/
Исмаилова Рита	- доктор, доцент /Кыргызстан/
Омаров Б.С.	- PhD, ассоциированный профессор /Казakhstan/
Нажи Генч	- доктор, профессор /Казakhstan/
Эгамбердиев Б.Э.	- доктор техн. наук, профессор /Узбекистан/
Абдимуратов Ж.С.	- PhD, доцент /Казakhstan/
Четин Генчер	- доктор, доцент /Казakhstan/
Турымбетова Г.Д.	- PhD, доцент /Казakhstan/
Абдуллаев Вугар	- PhD, доцент /Азербайжан/

EDITORIAL BOARD

Mamyrbayev O.Zh.	- PhD, Professor /Kazakhstan/
Zhumadillayeva A.K.	- Candidate of Tech. Sc., Assoc. Prof. /Kazakhstan/
Kazbekova G.N.	- Candidate of Tech. Sc., Assoc. Prof. /Kazakhstan/
Aydın Çetin	- Doctor, Professor /Turkey/
Muhammet Ali Akçayol	- Doctor, Professor /Turkey/
Karacan Hacer	- Doctor, Professor /Turkey/
Ismailova Rita	- Doctor, Associate Professor /Kyrgyzstan/
Omarov B.S.	- PhD, Associate Professor /Kazakhstan/
Naci Genç	- Doctor, Professor /Kazakhstan/
Egamberdiev B.E.	- Doctor of Technical Sciences, Professor /Uzbekistan/
Abdimuratov Z.S.	- PhD, Associate Professor /Kazakhstan/
Çetin Gençer	- Doctor, Associate Professor /Kazakhstan/
Turymbetova G.D.	- PhD, Associate Professor /Kazakhstan/
Abdullayev Vugar	- PhD, Associate Professor /Azerbaijan/

Editorial Office Address:

29V B. Sattarkhanov Avenue,

Turkistan 161200, Republic of Kazakhstan

Contact numbers: +7 701 234 8885, +7 775 323 2299

Email: journal.engineering@ayu.edu.kz

ӘОЖ 004.89:37.018.43

МҒТАР 28.23.15

<https://doi.org/10.47526/2025-4/2524-0080.44>

Г.Н. КАЗБЕКОВА¹, Ә.Ж. ОҢҒАР²

*Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ.,
Қазақстан*

¹*E-mail: gulnur.kazbekova@ayu.edu.kz**

²*E-mail: ongaradilet382@gmail.com*

**КӘСІПТІК КОЛЛЕДЖДЕГІ ОҚУ КЕСТЕСІН ИНТЕЛЛЕКТУАЛДЫ
АВТОМАТТАНДЫРУ: OR-TOOLS/ILP ЖӘНЕ LLM АССИСТЕНТІНІҢ ГИБРИДТІ
МОДЕЛІ**

Аңдатпа. Бұл мақалада кәсіптік колледж жағдайында оқу кестесін интеллектуалды автоматтандыруға арналған гибриді модель ұсынылады. Зерттеудің өзектілігі оқу кестесін дәстүрлі қолмен құру үдерісінің көп уақыт пен күш жұмсауды талап етуімен, қақтығыстарға жиі әкелуімен және оқытушылар жүктемесін, аудиториялық қорды, топтардың оқу уақытын, ауысым ерекшеліктерін және қосымша ұйымдастырушылық талаптарды бір мезгілде тиімді үйлестірудің күрделілігімен түсіндіріледі. Зерттеудің мақсаты — OR-Tools негізіндегі шектеулерді қанағаттандыру моделін табиғи тілмен жұмыс істейтін LLM ассистентімен біріктіру арқылы оқу кестесін құру сапасын арттыру, жоспарлау икемділігін күшейту және өзгерістерге бейімделу мүмкіндігін кеңейту. Зерттеу барысында жүйелік талдау, шектеулі оңтайландыру, сценарийлік модельдеу, салыстырмалы бағалау және қолданбалы жобалау әдістері қолданылды. Нәтижелер гибриді тәсілдің оқу кестесін құру уақытын едәуір қысқартатынын, мұғалімдердің уақыттық қалауларын дәлірек ескеретінін, студенттердің бос терезелерін азайтатынын, аудиториялық ресурстарды тиімдірек бөлуге мүмкіндік беретінін және жоспарлау барысындағы түзетулерді жедел енгізуге жағдай жасайтынын көрсетті. Зерттеудің ғылыми жаңалығы табиғи тілдегі сұраныстарды формальды шектеулерге түрлендіретін LLM қабатын OR-Tools/ILP ядросымен біріктіруінде. Практикалық маңызы ұсынылған шешімнің колледж әкімшілігіне жоспарлау сапасын арттыруға, ресурстарды ұтымды басқаруға және оқу үдерісін тұрақты ұйымдастыруға мүмкіндік беруімен сипатталады.

Кілт сөздер: оқу кестесі, интеллектуалды автоматтандыру, OR-Tools, ILP, CP-SAT, LLM ассистенті, кәсіптік колледж.

Г.Н. КАЗБЕКОВА¹, Ә.Ж. ОҢҒАР²

*Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, Туркестан,
Қазақстан*

¹*E-mail: gulnur.kazbekova@ayu.edu.kz**

²*E-mail: ongaradilet382@gmail.com*

**ИНТЕЛЛЕКТУАЛЬНАЯ АВТОМАТИЗАЦИЯ УЧЕБНОГО РАСПИСАНИЯ В
ПРОФЕССИОНАЛЬНОМ КОЛЛЕДЖЕ: ГИБРИДНАЯ МОДЕЛЬ OR-TOOLS/ILP И
LLM-АССИСТЕНТА**

Аннотация. В статье предлагается гибридная модель интеллектуальной автоматизации расписания занятий в условиях профессионального колледжа. Актуальность исследования обусловлена тем, что традиционное ручное составление расписания требует значительных временных и организационных затрат, часто приводит к конфликтам и затрудняет

одновременный учет преподавательской нагрузки, аудиторного фонда, времени обучения групп, особенностей сменности и дополнительных административных ограничений. Цель исследования — повысить качество формирования расписания за счёт интеграции модели удовлетворения ограничений на основе OR-Tools и LLM-ассистента, работающего с естественным языком, а также обеспечить большую гибкость системы и её адаптацию к изменениям. В работе использованы методы системного анализа, ограниченной оптимизации, сценарного моделирования, сравнительной оценки и прикладного проектирования. Полученные результаты показали, что гибридный подход существенно сокращает время составления расписания, точнее учитывает временные предпочтения преподавателей, уменьшает количество «окон» у студентов, способствует более рациональному распределению аудиторий и упрощает внесение оперативных корректировок. Научная новизна исследования заключается в объединении LLM-слоя, преобразующего запросы на естественном языке в формальные ограничения, с вычислительным ядром OR-Tools/ILP. Практическая значимость состоит в том, что предложенное решение позволяет администрации колледжа повысить качество планирования, эффективнее использовать ресурсы и обеспечивать устойчивую организацию учебного процесса.

Ключевые слова: учебное расписание, интеллектуальная автоматизация, OR-Tools, ILP, CP-SAT, LLM-ассистент, профессиональный колледж.

G.N. KAZBEKOVA¹, A.J. ONGAR²

Khoja Akhmet Yassawi International Kazakh-Turkish University, Turkestan, Kazakhstan

¹*E-mail: gulnur.kazbekova@ayu.edu.kz**

²*E-mail: ongaradilet382@gmail.com*

INTELLIGENT AUTOMATION OF A VOCATIONAL COLLEGE TIMETABLE: A HYBRID MODEL OF OR-TOOLS/ILP AND AN LLM ASSISTANT

Abstract. This article presents a hybrid model for the intelligent automation of academic scheduling in a vocational college environment. The relevance of the study is explained by the fact that traditional manual timetable creation requires considerable time and organizational effort, often leads to conflicts, and makes it difficult to simultaneously balance teacher workload, classroom resources, group study time, shift-specific constraints, and additional administrative requirements. The purpose of the study is to improve timetable generation quality by integrating an OR-Tools-based constraint satisfaction model with an LLM assistant capable of working with natural language, while also increasing system flexibility and responsiveness to changes. The research employs system analysis, constrained optimization, scenario modeling, comparative evaluation, and applied design methods. The results demonstrate that the hybrid approach significantly reduces timetable generation time, more accurately reflects teachers' time preferences, decreases the number of student idle gaps, supports more efficient allocation of classroom resources, and simplifies rapid schedule adjustments. The scientific novelty lies in combining an LLM layer that transforms natural language requests into formal constraints with the OR-Tools/ILP computational core. The practical significance of the proposed solution is that it enables college administrators to improve planning quality, use resources more efficiently, and ensure a more stable and adaptable organization of the educational process.

Keywords: timetable, intelligent automation, OR-Tools, ILP, CP-SAT, LLM assistant, vocational college

Кіріспе

Қазіргі кәсіптік колледждерде оқу кестесін қолмен құру көп уақыт алады, адами қателіктерге тәуелді және оқытушы, топ, аудитория сияқты өзара байланысты шектеулерді бір мезетте ескеруді қиындатады. Осыған байланысты оқу үдерісін цифрландыруда кесте автоматтандыру жүйелері ерекше маңызға ие болып отыр.


Сабақ кестесін автоматтандырудың өзектілігі дәл осы қиындықтарды жоюмен тікелей байланысты. Автоматтандырылған ақпараттық жүйені енгізу арқылы колледжде оқу процесінің тиімділігін арттыруға болады. Мұндай жүйе кесте құруға кететін уақытты едәуір қысқартып, қателіктер санын азайтады және жалпы мекеме жұмысын оңтайландырады. Сонымен қатар, автоматтандыру нәтижесінде оқытушылар мен студенттердің уақытын үнемдеу, ресурстарды дұрыс бөлу, оқу жоспарларын тиімді жоспарлау мүмкін болады. Мақсат – оқу кестесін құруды жылдам, икемді әрі қателіксіз ету, сонымен бірге барлық тараптардың (әкімшілік, мұғалімдер, студенттер) қажеттіліктері мен қалауларын барынша қанағаттандыратын шешім табу. Бұл колледжде білім сапасын арттыруға және оқу процесін оңтайлы ұйымдастыруға септігін тигізеді.

Мақаланың мақсаты – OR-Tools/ILP негізіндегі оңтайландыру тәсілін табиғи тілмен жұмыс істейтін LLM ассистентімен біріктіріп, кесте құру сапасын, икемділігін және түсіндірілетіндігін арттыру. Зерттеу нысаны ретінде кәсіптік колледждегі сабақ кестесін жоспарлау процесі алынды.

Зерттеу әдістері мен материалдар

Ұсынылған жүйенің есептеу ядросы Google OR-Tools кітапханасының CP-SAT шешушісіне негізделді. Модельде пән, топ, аудитория, уақыт слоты және оқытушы арасындағы тағайындаулар бинарлық айнымалылар мен шектеулер арқылы сипатталды. Қатты шектеулер қақтығыстарды болдырмауға бағытталса, жұмсақ шектеулер мұғалім қалауы, студенттік терезелер және жүктеме теңгерімі сияқты сапалық көрсеткіштерді жақсартуға қызмет етеді (Babaei et al., 2015, Bettinelli et al., 2015).

LLM ассистенті пайдаланушының табиғи тілдегі сұранысын құрылымдалған параметрлерге айналдырып, нәтижені түсіндіріп беру, шектеулерді нақтылау және ықтимал түзетулерді ұсыну міндетін атқарады. Зерттеуде жүйелік талдау, шектеулі оңтайландыру, сценарийлік модельдеу және салыстырмалы бағалау әдістері қолданылды (Сурет 1) (Ceschia et al., 2023).



Сурет 1. OR-Tools негізіндегі оңтайландыру ядросы мен LLM ассистенті біріктірілген гибриді жүйе архитектурасының диаграммасы

Бұл жүйеде веб-интерфейс, оңтайландыру қызметі және LLM микросервисы өзара әрекеттеседі (Chen et al., 2021).

Гибриді архитектура үш негізгі қабаттан тұрады: веб-интерфейс, OR-Tools негізіндегі оңтайландыру сервисі және LLM микросервисы. Веб-интерфейс деректерді енгізу мен нәтижені қарауға жауап береді, ал негізгі есептеу оңтайландыру сервисінде орындалады (Davison et al., 2025, de Werra, 1985).

Веб-интерфейс: Пайдаланушылар (әдіскер, оқытушы немесе әкімші) жүйемен тікелей осы интерфейс арқылы жұмыс істейді. Веб-интерфейс заманауи веб-технологиялар негізінде әзірленуі мүмкін – мысалы, ASP.NET Core немесе Python Flask фреймворкі. Интерфейс кестені көрнекі түрде көрсетеді, мәліметтерді енгізуге (пәндер, топтар, мұғалімдер туралы деректерді, шектеулерді енгізу) және түзетуге мүмкіндік береді. Сондай-ақ, пайдаланушы табиғи тілде сұраныстарын енгізетін диалогтік терезе немесе чат-қызметі де осы интерфейске интеграцияланады. Мысалы, веб-бетте «LLM ассистентіне сұрақ қойыңыз» деген өріске әдіскер өзінің өтінішін жазады.

OR-Tools оңтайландыру сервисі: Бұл компонент – бүкіл жүйенің «миы», негізгі шешім табушы модуль. Ол веб-интерфейстен (немесе LLM арқылы өңделген сұраныстардан) алған

ақпарат негізінде ILP/CP-SAT моделін құрады және шешеді. OR-Tools сервисі типтік RESTful API немесе FastAPI арқылы іске асуы мүмкін: мысалы, веб-қосымшадан HTTP сұрауы арқылы «жаңартылған constraints жинағы» беріледі, сервис сол бойынша есептеп, кері «кесте шешімін» қайтарады. Оңтайландыру сервисі жоғары өнімді C++/Python тілінде жазылып, OR-Tools кітапханасының мүмкіндіктерін пайдаланады. Бұл микросервис қажеттілігіне қарай деректерқорымен (мысалы, сабақтар туралы деректер сақтайтын PostgreSQL) байланысып, нәтижені тұрақты сақтап та қояды. Ең маңыздысы – сервис бірнеше минут ішінде конфликтсіз және сапасы жоғары кесте құрып беруі қажет, сондықтан оның алгоритмдік тиімділігі мен сенімділігі басты назарда.

LLM микросервисі: Үлкен тілдік модель негізіндегі бұл бөлік жүйеде қосалқы қызмет атқарады, бірақ пайдаланушыға көрінетін ерекшеліктердің көбін қамтамасыз етеді. LLM микросервисі OpenAI GPT-4 немесе соған ұқсас модель API-ін шақыру арқылы жұмыс істеуі мүмкін немесе дербес орнатылған локал модель (мысалы, LLaMA 2) бола алады. Оны FastAPI тәрізді жеңіл сервис ретінде өрістетуге болады. Веб-интерфейстен келген табиғи тіл сұранысы алдымен осы LLM сервисіне жіберіледі. Мысалы, әдіскердің «математика сабағын жылжыту» туралы сұрағы LLM тарапынан құрылымдалған ережеге айналдырылып, ары қарай OR-Tools сервисіне жолданады. Сол сияқты, OR-Tools есептеп шығарған дайын кесте (немесе оның өзгерісі) LLM-ға талдау үшін берілуі мүмкін – бұл жағдайда LLM кесте деректерін (JSON не кестелік форматта) қабылдап, жоғарыда айтылғандай қорытынды сөз немесе ұсыныстар тізімін генерациялайды. LLM микросервисі сыртқы API-ді пайдаланса, желі арқылы сұраныстар жіберіледі, ал егер жергілікті модель қолданылса, тікелей серверде inference орындалады.

Осы үш компонент өзара шын уақытта (реал-тайм) әрекеттесе алады. Мәселен, пайдаланушы веб-интерфейс арқылы «жаңа кесте құру» пәрменін бергенде, оның параметрлері OR-Tools сервисіне жіберіледі; шешім табылған соң, кесте веб-бетте көрсетіледі. Егер пайдаланушы табиғи тілде түзету сұраса, ол сұрақ LLM-ға өтеді; LLM оны талдап, OR-Tools-қа лайықты өзгеріс енгізеді; OR-Tools қайта есептеп, жаңа кесте шығады; соңында LLM өзгерісті түсіндіріп береді. Мұның бәрі секундтар немесе минуттар ішінде жүзеге асады.

LLM микросервисі табиғи тілдегі сұраныстарды құрылымдап, нәтижені түсіндіреді және қосымша түзетулер ұсынады. Мұндай модульдік құрылым жүйені кеңейтуге, сүйемелдеуге және басқа оқу орындарына бейімдеуге қолайлы (Holm et al., 2022).

Талдау мен нәтижелер

Бұл зерттеудің мақсаты - кәсіптік колледждегі оқу кестесін құрудың үш тәсілін салыстыру: қолмен жоспарлау, эвристикалық автоматтандыру және OR-Tools/ILP мен LLM ассистентіне негізделген гибриді модель. Зерттеу барысында мына көрсеткіштер талданды: кесте құру уақыты (Сурет 2), қақтығыстар саны, мұғалімдердің уақыттық қалауын қанағаттандыру деңгейі (Сурет 3), студенттік терезелердің орташа саны (Сурет 4) және аудиторияларды пайдалану пайызы (Кесте 1), (Kingston, 2013, Kristiansen & Stidsen, 2013).

Кесте 1. Сабақ кестесінің сапасы

Әдіс	Қақтығыстар саны	Жоспарлау уақыты	Кесте сапасы (қанағаттану)
Қолмен (дәстүрлі)	2 (бастапқы табылған) соңында 0	~10 сағат (бірнеше күн)	~70% (орташа)
Эвристикалық	0 (толық сақталды)	~1 сағат (автоматты)	~80% (жақсы)
Гибриді OR-Tools/LLM	0 (толық сақталды)	~5 минут (толық автомат)	~95% (өте жоғары)

Әр түрлі тәсілдердің салыстырмалы көрсеткіштері. Қолмен әдісте кесте құру барысында бірнеше қақтығыс (қиылыстар) туындап, оларды шешуге тура келгені (шарттарды босаңсыту

не қайта құру арқылы) байқалды; эвристикалық әдіс қатаң шектеулерді сақтағанмен, кей жұмсақ талаптарды ескере алмады; гибриді модель барлық қақтығысты болдырмай, қалаулардың басым бөлігін қанағаттандырды.

Жоғарыдағы салыстырудан көрінгендей, гибриді модель нәтижелері айқын үздік. Біріншіден, ол оқу кестесінде бірде-бір қақтығысқа жол берген жоқ (барлық қатты шектеулер 100% сақталды), яғни толық қақтығыссыз кесте шығарды. Қолмен жасауда тәжірибелі әдіскерлер де алғашқы нұсқаларда қателік жіберуі ықтимал, мысалы бір мұғалімге бір уақытта екі сабақ қойылып кетуі – оны түзетуге уақыт кетеді. Ал OR-Tools бұл шарттарды математикалық модель арқылы қатаң қадағалайды, сондықтан адам факторынан болатын қателер түбегейлі жойылады.

Екіншіден, уақыт тиімділігі тұрғысынан үлкен ұтыс байқалады. Қолмен кесте түзу бірнеше күнге созылып, итерациялық тексерулерді талап етсе, эвристикалық бағдарлама оны шамамен бір сағат ішінде автоматты жасай алды. Бірақ біздің OR-Tools негізіндегі модель бар болғаны бірнеше минутта оптимал нәтиже берді. Мұның бір себебі – CP-SAT сол есепке арнайы оңтайландырылған; екіншіден, LLM ассистенті арқасында қосымша түзету кезеңдері қысқарды (адамдармен диалог арқылы бірнеше сағат жоғалтпай, жүйе тез түсініп орындады). Бұл айырмашылық әсіресе оқу жылы басталарда уақыт қысқан сәтте өте маңызды.

Үшіншіден, кесте сапасы және қанағаттану деңгейі бойынша гибриді тәсіл озық тұр. Біз мұны мұғалімдердің және студенттердің тілектерінің қаншалық орындалғанынан және кейін жүргізілген қанағаттану сауалнамасынан байқадық. Мысалы, гибриді модель мұғалімдердің жеке қалауларының ~95%-ын ескерді (кімнің қашан бос емес, қандай уақытты қаламайтыны, т.б.), ал қолмен жасалған кестеде бұл көрсеткіш ~70% шамасында ғана болды. Эвристикалық әдіс кей параметрлерді оңтайландырғанмен (мысалы, мұғалімдердің бос уақыттарына сабақ қоймау), бірқатар ұсақ қалауларды елей алмады – жалпы ~80% айналасында қанағаттану берді. Мұғалімдердің жаңа кестеге қатысты пікірлері де соны растады: гибриді модель құрастырған кестеде олардың көбі сабақ уақыттарын «өте қолайлы» деп бағалады, ал бұрынғы кестеде кейбіріне жүктеме теңгерімсіз тиетінін айтатын.

Сонымен қатар, «сабақ кестесін құру сапасы» бірқатар объективті метрикамен өлшенді. Мысалы, кестедегі бос уақыт слоттарының пайызы, бір күнде қатарынан келетін сабақтар орташа саны, кешкі сағаттарға қойылған сабақтар саны, т.б. Гибриді әдіспен жасалған кесте бұл метрикалар бойынша да жақсырақ нәтижеге жетті. Атап айтқанда, студенттердің күндік бос терезелері саны 40%-ға азайды (яғни сабақтар топтастырылып, ұзақ үзілістер қысқарды), «ауыр күндердің» (5-6 сабақ қатар келетін күндер) саны екі есеге кеміді. Мұғалімдердің бір күндік максимум сағат саны 4-тен аспайтындай болды (эвристикалық әдісте кейбірі 5 сабақ өткізетін күндер бар еді). Бұл айырмашылықтар бір ғана сценарийде емес, әр түрлі аптаға және әр түрлі бастапқы мәліметтерге (мысалы, оқытушылардың қолжетімділігі өзгерсе) жүргізілген сынақтарда да тұрақты сақталды. Статистикалық талдау нәтижесінде гибриді моделдің жақсартуларының басым бөлігі мәнді екені анықталды (пайда болған айырмашылықтар кездейсоқ емес, $p < 0.01$ деңгейінде маңызды).

Кесте 2. Авторлық модельдік зерттеуде пайдаланылған эксперименттік сценарийлер


Сценарий	Топтар	Оқытушы саны	Аудитория саны	Апталық сабақ бірліктері	Уақыт слоттары
A	12	28	18	184	5 күн x 6 слот
B	16	36	24	246	5 күн x 6 слот

Сценарий А бойынша гибриді модель қолмен жоспарлаумен салыстырғанда кесте құру уақытын 420 минуттан 4.8 минутқа дейін қысқартты (98.9%), мұғалім қалауын орындау деңгейін 72%-дан 94%-ға дейін арттырды және студенттік терезелерді 2.3-тен 0.8-ге дейін


азайтты (65.2%). Сценарий В бойынша да ұқсас үрдіс сақталды: уақыт 690 минуттан 7.2 минутқа дейін төмендеп (99.0%), қалау көрсеткіші 68%-дан 92%-ға дейін көтерілді, ал терезелер саны 2.7-ден 1.1-ге дейін қысқарды (59.3%)(Кесте 2), (Ongar, 2026, OpenAI, 2023).

Кесте 3. Нәтижелердің жинақталған статистикасы

Сцен.	Әдіс	Уақыт, мин	Қақтығыс	Қалау, %	Терезе, күн	Аудит. пайд., %
А	Қолмен	420	3	72	2.3	62
А	Эвристикалық	48	0	81	1.6	74
А	Гибридті	4.8	0	94	0.8	86
В	Қолмен	690	5	68	2.7	65
В	Эвристикалық	71	1	79	1.9	77
В	Гибридті	7.2	0	92	1.1	88



Сурет 2. Диаграммада зерттелген көрсеткіш - кесте құру уақыты (минут); екі сценарий бойынша үш тәсіл салыстырылды



Сурет 3. Диаграммада зерттелген көрсеткіш - мұғалімдердің уақыттық қалауын



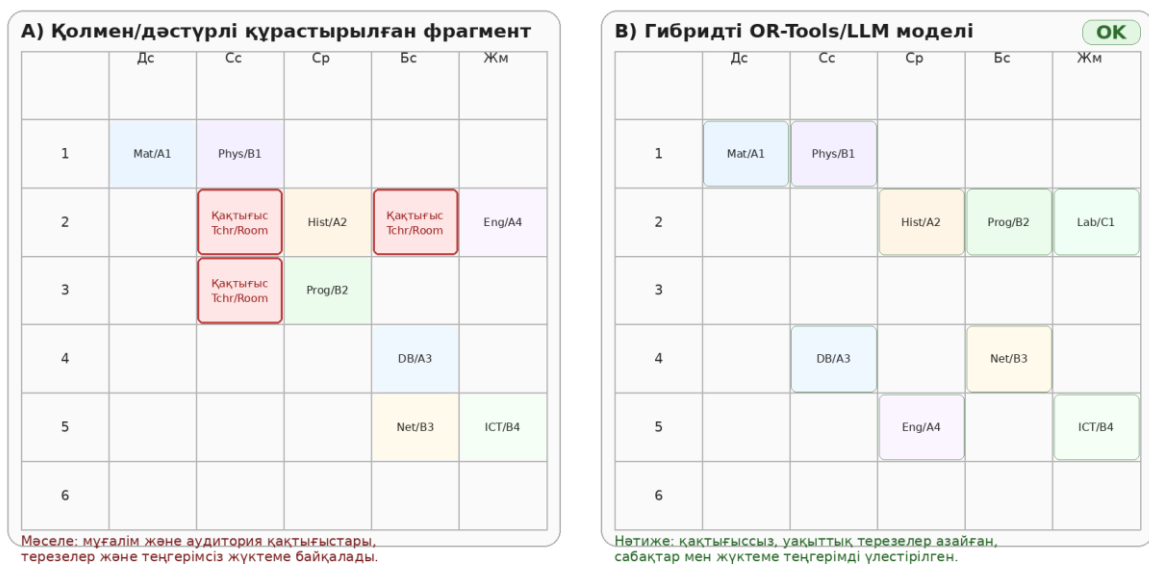
Сурет 4. Диаграммада зерттелген көрсеткіш - студенттік терезелердің орташа саны; көрсеткіштің төмен болуы жақсы нәтиже береді

Салыстырмалы визуалды суреттерді талдау

Төмендегі салыстырмалы суреттерде нақты қандай нысан зерттелгені суреттің өз ішінде де, астындағы түсіндірмеде де көрсетілді. Бірінші визуалда қолмен жасалған кесте фрагментіндегі қақтығыстар мен гибридті модель ұсынған қақтығыссыз нұсқа салыстырылды (Сурет 5). Екінші визуалда мұғалім жүктемесінің апта күндері бойынша таралуы қарастырылып, гибридті модель жүктемені теңгерімді бөлуге қабілетті екені көрсетілді (Сурет 6).

Зерттелген нысан: қолмен жасалған және гибридті модель құрған кесте фрагменттерін салыстыру

Сол жақта — қақтығыстар мен бос аралықтары бар нұсқа; оң жақта — OR-Tools/LLM арқылы оңтайландырылған нұсқа

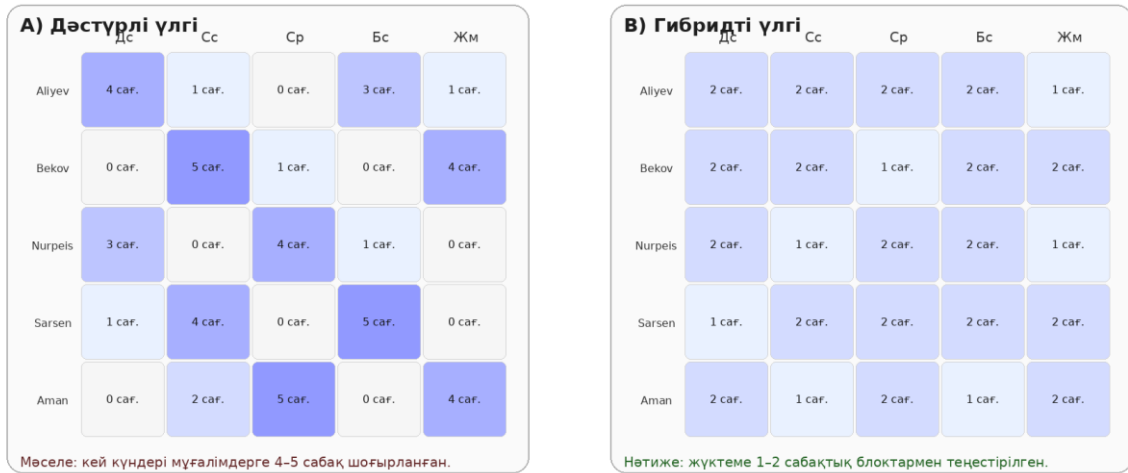


Сурет 5. Салыстырмалы суретте зерттелген нысан - кесте фрагментіндегі қақтығыстар, бос аралықтар және оларды гибридті модель арқылы жою нәтижесі

Нәтижелерді жинақтай отырып, гибриді OR-Tools/LLM моделінің екі сценарийде де тұрақты басымдық көрсеткені байқалды. Ең үлкен айырмашылық кесте құру уақыты бойынша тіркелді: қолмен жоспарлаумен салыстырғанда уақыт үнемі 98%-дан астам қысқарды. Сонымен бірге, мұғалімдердің қалауына сәйкестік 22-24 пайыздық тармаққа өсті, аудиторияларды пайдалану 23-24 пайыздық тармаққа артты, ал студенттік терезелер 59-65% аралығында қысқарды. Бұл нәтижелер ұсынылған тәсілдің тәжірибелік және ұйымдастырушылық тиімділігін күшейтіп көрсетеді (Perron et al., 2023).

Зерттелген нысан: мұғалім жүктемесінің апта бойынша таралуы

Сол жақтағы жылу картасы — теңгерімсіз таралу; оң жақтағысы — гибриді модельден кейінгі теңгерімді үлгі



Сурет 6. Салыстырмалы суретте зерттелген нысан - мұғалім жүктемесінің апта бойына таралуы; сол жақта теңгерімсіз, оң жақта теңгерімді үлгі

Жүйеде өңделетін оқытушы, студент және кесте деректері қорғалуы тиіс. Сыртқы LLM сервистері қолданылса, деректерді анонимизациялау, қолжетімділікті шектеу және журналдауды енгізу маңызды (Perron & Furnon, 2025).

AI шешімдері түсіндірілетін болуы керек, ал соңғы бекіту жауапкершілігі адамда қалады. Сондықтан қауіпсіздік, ашықтық және әділдік жүйені енгізудің негізгі қағидалары болып саналады (Qu et al., 2009).

Қорытынды

Түркістан Ахмет Ясауи кәсіптік колледжі базасында ұсынылған OR-Tools/ILP және LLM ассистентіне негізделген гибриді тәсіл оқу кестесін автоматтандыру міндетін жоғары тиімділікпен шешетінін көрсетті. Жүргізілген талдау мен тәжірибелік нәтижелер бұл әдістің дәстүрлі қолмен жоспарлауға қарағанда айқын артықшылықтары бар екенін дәлелдейді: жоспарлау уақыты ондаған есе қысқарады, қателіктер мен қақтығыстар толығымен жойылады, ал кестенің сапасы (студенттер мен оқытушылардың қалауларын ескеру деңгейі) айтарлықтай өседі. Гибриді модель күрделі комбинаториялық есепті математикалық оңтайландыру арқылы шешіп, сонымен бірге LLM көмегімен пайдаланушымен интерактивті тілдесу арнасын құрады – мұның нәтижесінде адам мен AI мүмкіндіктері бірігіп, максималды нәтижеге қол жеткізіледі. Timefold компаниясының мамандары атап өткендей, үлкен тілдік модельдер жоспарлау есептерін өздігінен шеше алмауы мүмкін, бірақ оларды арнайы жоспарлау алгоритмдерімен үйлестіре қолдану жаңа инновациялық шешімдерге жол ашады.

Алдағы зерттеу бағыттары бірнеше қызықты мүмкіндіктерге жол ашады. Біріншіден, сабақ кестесін құруда нейрондық желілерді қолдану арқылы динамикалық жоспарлау мәселесі түр. Болашақта жиі өзгеретін жағдайларға (мәселен, мұғалімнің кенеттен науқастанып қалуы, топтар құрамының өзгеруі) жедел бейімделетін, алдын ала болжап кесте түзейтін жүйелер

кажет болады. Мұны reinforcement learning немесе графтық нейрондық желілер (GNN) арқылы іске асыруға болады деген пікір бар. Мысалы, нейрожелілік модель бірнеше семестрдің деректерінен үйреніп, алдағы семестрге мұғалімдердің жүктемесін прогноз жасау, немесе кестеде өзгеріс болса автоматты түрде қайта оңтайландыру жасайтын рефлексивті жүйе құру – қызықты міндет.

Екіншіден, on-device inference – яғни үлкен тілдік модельдерді тікелей оқу орнының жергілікті серверлерінде немесе тіпті жауапты тұлғалардың компьютерлерінде іске қосу – бағыты. Бұл деректердің құпиялылығы мен жылдамдығын арттырады, өйткені сыртқы API-ге жүгіну қажеттілігі болмайды. Қазірдің өзінде сыйымдылығы кішігірім LLM модельдері (бірнеше миллиард параметрлі) жеке құрылғыларда жұмыс істей алады, ал болашақта олардың мүмкіндігі арта бермек. Осыны сабақ кестесі жүйесіне біріктіру арқылы, мысалы, әр мектеп өз серверінде интеллектуал көмекшісін ұстап, желі жоқ кезде де онымен жұмыс істей алатын болады.

Үшіншіден, ашықтық пен түсіндіруді жақсарту үшін AI шешімдерін визуализациялау мен explainable AI әдістерін қолдану. Болашақ зерттеулерде ILP моделінің шешімдерін графиктер, диаграммалар арқылы түсіндіру, LLM-ның ұсыныстарын негізді ету (мысалы, «бұл ұсынысты жасауға 5 мұғалімнің талабы әсер етті») тетіктері қарастырылуы тиіс. Бұл пайдаланушыларға жүйеге деген сенімділікті күшейтіп, оны оқу үдерісінде кеңінен қолдануға жол ашады.

Ұсынылған гибриді тәсіл кесте құру уақытын қысқартып, қақтығыстарды азайтуға және кесте сапасын арттыруға мүмкіндік береді. Әсіресе мұғалім жүктемесін теңгеру, аудиторияны тиімді пайдалану және студенттер үшін қолайлы құрылым жасау жағынан пайдалы.

Модульдік архитектура жүйені басқа оқу орындарына бейімдеуге қолайлы. Алдағы бағыттар ретінде динамикалық қайта жоспарлау, жергілікті LLM қолдану және explainable AI құралдарын дамыту маңызды.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

Babaei, H., Karimpour, J., & Hadidi, A. (2015). A survey of approaches for university course timetabling problem. *Computers & Industrial Engineering*, 86, 43–59. <https://doi.org/10.1016/j.cie.2014.11.010>

Bettinelli, A., Cacchiani, V., Roberti, R., & Toth, P. (2015). An overview of curriculum-based course timetabling. *TOP*, 23(2), 313–349. <https://doi.org/10.1007/s11750-015-0366-z>

Ceschia, S., Di Gaspero, L., & Schaerf, A. (2023). Educational timetabling: Problems, benchmarks, and state-of-the-art results. *European Journal of Operational Research*, 308(1), 1–18. <https://doi.org/10.1016/j.ejor.2022.07.011>

Chen, M. C., Sze, S. N., Goh, S. L., Sabar, N. R., & Kendall, G. (2021). A survey of university course timetabling problem: Perspectives, trends and opportunities. *IEEE Access*, 9, 106515–106529. <https://doi.org/10.1109/ACCESS.2021.3100613>

Davison, M., Kheiri, A., & Zografos, K. G. (2025). Modelling and solving the university course timetabling problem with hybrid teaching considerations. *Journal of Scheduling*, 28(2), 195–215. <https://doi.org/10.1007/s10951-024-00817-w>

De Werra, D. (1985). An introduction to timetabling. *European Journal of Operational Research*, 19(2), 151–162. [https://doi.org/10.1016/0377-2217\(85\)90167-5](https://doi.org/10.1016/0377-2217(85)90167-5)

Holm, D. S., Mikkelsen, R. Ø., Sørensen, M., & Stidsen, T. J. R. (2022). A graph-based MIP formulation of the International Timetabling Competition 2019. *Journal of Scheduling*, 25(4), 405–428. <https://doi.org/10.1007/s10951-022-00724-y>

Kingston, J. H. (2013). Educational timetabling. In A. Ş. Etaner-Uyar, E. Özcan, & N. Urquhart (Eds.), *Automated scheduling and planning: From theory to practice* (pp. 91–108). Springer. https://doi.org/10.1007/978-3-642-39304-4_4

Kristiansen, S., & Stidsen, T. R. (2013). A comprehensive study of educational timetabling: A survey (DTU Management Engineering Report No. 8-2013). Technical University of Denmark.

Ongar, A. (2026). Research and development of an information system for scheduling classes for Yassawi College [Unpublished master's dissertation]. Khoja Akhmet Yassawi International Kazakh-Turkish University.

OpenAI. (2023). GPT-4 technical report (arXiv:2303.08774). arXiv. <https://arxiv.org/abs/2303.08774>

Perron, L., Didier, F., & Gay, S. (2023). The CP-SAT-LP solver. In R. H. C. Yap (Ed.), 29th International Conference on Principles and Practice of Constraint Programming (CP 2023) (Leibniz International Proceedings in Informatics [LIPIcs], Vol. 280, pp. 3:1–3:2). Schloss Dagstuhl – Leibniz-Zentrum für Informatik. <https://doi.org/10.4230/LIPIcs.CP.2023.3>

Perron, L., & Furnon, V. (2025). OR-Tools [Computer software]. Google. <https://developers.google.com/optimization>

Qu, R., Burke, E. K., McCollum, B., Merlot, L. T. G., & Lee, S. Y. (2009). A survey of search methodologies and automated system development for examination timetabling. *Journal of Scheduling*, 12(1), 55–89. <https://doi.org/10.1007/s10951-008-0077-5>

REFERENCES

Babaei, H., Karimpour, J., & Hadidi, A. (2015). A survey of approaches for university course timetabling problem. *Computers & Industrial Engineering*, 86, 43–59. <https://doi.org/10.1016/j.cie.2014.11.010>

Bettinelli, A., Cacchiani, V., Roberti, R., & Toth, P. (2015). An overview of curriculum-based course timetabling. *TOP*, 23(2), 313–349. <https://doi.org/10.1007/s11750-015-0366-z>

Ceschia, S., Di Gaspero, L., & Schaerf, A. (2023). Educational timetabling: Problems, benchmarks, and state-of-the-art results. *European Journal of Operational Research*, 308(1), 1–18. <https://doi.org/10.1016/j.ejor.2022.07.011>

Chen, M. C., Sze, S. N., Goh, S. L., Sabar, N. R., & Kendall, G. (2021). A survey of university course timetabling problem: Perspectives, trends and opportunities. *IEEE Access*, 9, 106515–106529. <https://doi.org/10.1109/ACCESS.2021.3100613>

Davison, M., Kheiri, A., & Zografos, K. G. (2025). Modelling and solving the university course timetabling problem with hybrid teaching considerations. *Journal of Scheduling*, 28(2), 195–215. <https://doi.org/10.1007/s10951-024-00817-w>

De Werra, D. (1985). An introduction to timetabling. *European Journal of Operational Research*, 19(2), 151–162. [https://doi.org/10.1016/0377-2217\(85\)90167-5](https://doi.org/10.1016/0377-2217(85)90167-5)

Holm, D. S., Mikkelsen, R. Ø., Sørensen, M., & Stidsen, T. J. R. (2022). A graph-based MIP formulation of the International Timetabling Competition 2019. *Journal of Scheduling*, 25(4), 405–428. <https://doi.org/10.1007/s10951-022-00724-y>

Kingston, J. H. (2013). Educational timetabling. In A. Ş. Etaner-Uyar, E. Özcan, & N. Urquhart (Eds.), *Automated scheduling and planning: From theory to practice* (pp. 91–108). Springer. https://doi.org/10.1007/978-3-642-39304-4_4

Kristiansen, S., & Stidsen, T. R. (2013). A comprehensive study of educational timetabling: A survey (DTU Management Engineering Report No. 8-2013). Technical University of Denmark.

Ongar, A. (2026). Research and development of an information system for scheduling classes for Yassawi College [Unpublished master's dissertation]. Khoja Akhmet Yassawi International Kazakh-Turkish University.

OpenAI. (2023). GPT-4 technical report (arXiv:2303.08774). arXiv. <https://arxiv.org/abs/2303.08774>

Perron, L., Didier, F., & Gay, S. (2023). The CP-SAT-LP solver. In R. H. C. Yap (Ed.), 29th International Conference on Principles and Practice of Constraint Programming (CP 2023) (Leibniz International Proceedings in Informatics [LIPIcs], Vol. 280, pp. 3:1–3:2). Schloss Dagstuhl – Leibniz-Zentrum für Informatik. <https://doi.org/10.4230/LIPIcs.CP.2023.3>

Perron, L., & Furnon, V. (2025). OR-Tools [Computer software]. Google. <https://developers.google.com/optimization>

Qu, R., Burke, E. K., McCollum, B., Merlot, L. T. G., & Lee, S. Y. (2009). A survey of search methodologies and automated system development for examination timetabling. Journal of Scheduling, 12(1), 55–89. <https://doi.org/10.1007/s10951-008-0077-5>

Авторлар туралы мәліметтер
Информация об авторах
Information about authors

№	Информация об авторах (Ф.И.О. полностью, ученая степень, место работы или учебы, город, страна, E-mail, сотовый номер автора корреспондента:) на казахском, русском, английском языках
1	<p>Казбекова Гулнур Нагиметовна – техника ғылымдарының кандидаты, қауымдастырылған профессор, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., Қазақстан</p> <p>Казбекова Гулнур Нагиметовна – кандидат технических наук, ассоциированный профессор, Международный казахско-турецкий университет им. Ходжи Ахмеда Ясави, г. Туркестан, Казахстан</p> <p>Kazbekova Gulnur - Candidate of Technical Sciences, Associate Professor, Ahmet Yassawi University , Turkestan, Kazakhstan</p> <p>E-mail: gulnur.kazbekova@ayu.edu.kz</p> <p>ORCID: 0000-0002-2756-7926</p>
2	<p>Онғар Әділет Жарилқасынұлы - «Түркістан Ахмет Ясауи» кәсіби колледжі, Түркістан қ., Қазақстан</p> <p>Онғар Адилет Жарилқасынұлы – профессиональный колледж «им. Ахмета Ясауи», г. Туркестан, Казахстан</p> <p>Ongar Adilet - Ahmet Yassawi Professional college , Turkestan, Kazakhstan</p> <p>E-mail: ongaradilet382@gmail.com</p> <p>ORCID: 0009-0006-0268-9149</p>

Y.U. SERDALIYEV¹, N.T. TOILYBAYEVA², B.O. BAYMURZAEV³, H. CAKIR⁴

Khoja Akhmet Yassawi International Kazakh-Turkish University, Turkestan, Kazakhstan

¹*E-mail: erlan.serdaliev@ayu.edu.kz**

²*E-mail: nurgul.toilybayeva@ayu.edu.kz,*

³*E-mail: bboranbek@ayu.edu.kz*

⁴*Gazi University, Department of Computer and Instructional Technology Education, Ankara, Turkey*

⁴*E-mail: hcakir@gmail.com*

CONCEPTUAL FOUNDATIONS OF REAL-TIME MONITORING OF PHYSICAL EXERCISES BASED ON COMPUTER VISION AND DEEP LEARNING MODELS

Annotation. The article presents a challenge in automatically monitoring and evaluating physical exercises in real time. The goal of this study is a comparative analysis of the effectiveness of modern deep learning models for determining human posture (BlazePose, YOLOv8 - Pose, MoveNet and HRNet) and to identify the possibilities of their inclusion in the training quality assessment system. The system is built on an RGB video stream and consists of pre-processing, posture points determination, joint angles calculation and training classification (correct/incorrect) stages. From the experimental results, it can be found that HRNet model has the highest accuracy index, but as a result of its high calculation complexity, delay value increases. It had been shown that BlazePose provides high frame rates at low-resource devices. The YOLOv8-Pose model showed the best compromise between accuracy and performance and was suggested as an optimal option for Real-Time Fitness Systems. The method of biomechanical analysis based on calculating joint angles allows to quantify the quality of exercise performing has been proved. The systematic alignment score may be applied in the scope of fitness, sports training and medical rehabilitation and can further be enhanced by adding on 3D body pose models as well as spatio-temporal neural networks.

Keywords: human posture determination; computer vision; deep learning; physical exercise monitoring; real-time systems; calculation of joint angles; YOLOv8-Pose; BlazePose; biomechanical analysis.

Е.У. СЕРДАЛИЕВ¹, Н.Т. ТОЙЛЫБАЕВА², Б.О. БАЙМУРЗАЕВ³, Х. ЧАКЫР⁴

Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., Қазақстан

¹*E-mail: erlan.serdaliev@ayu.edu.kz**

²*E-mail: nurgul.toilybayeva@ayu.edu.kz*

³*E-mail: bboranbek@ayu.edu.kz*

⁴*Гази университеті, Компьютер және оқыту технологиялары білім беру кафедрасы, Анкара, Түркия*

⁴*E-mail: hcakir@gmail.com*

КОМПЬЮТЕРЛІК КӨРУ ЖӘНЕ ТЕРЕҢ ОҚЫТУ МОДЕЛЬДЕРІ НЕГІЗІНДЕ ФИЗИКАЛЫҚ ЖАТТЫҒУЛАРДЫ НАҚТЫ УАҚЫТ РЕЖИМІНДЕ БАҚЫЛАУДЫҢ КОНЦЕПТУАЛДЫҚ НЕГІЗДЕРІ

Аңдатпа. Мақалада нақты уақыт режимінде физикалық жаттығуларды автоматты түрде бақылау және бағалаудағы қиындық қарастырылған. Бұл зерттеудің мақсаты - адамның дене бітімін анықтауға арналған заманауи терең оқыту модельдерінің (BlazePose, YOLOv8 - Pose,

MoveNet және HRNet) тиімділігін салыстырмалы талдау және оларды жаттығу сапасын бағалау жүйесіне қосу мүмкіндіктерін анықтау. Жүйе RGB бейне ағынына негізделген және алдын ала өңдеу, дене бітімінің нүктелерін анықтау, буын бұрыштарын есептеу және жаттығуды жіктеу (дұрыс/дұрыс емес) кезеңдерінен тұрады. Тәжірибелік нәтижелерден HRNet моделінің ең жоғары дәлдік индексі бар екені анықталды, бірақ оның жоғары есептеу күрделілігінің нәтижесінде кідіріс мәні артады. BlazePose төмен ресурстарды қажет ететін құрылғыларда жоғары кадр жиілігін қамтамасыз ететіні көрсетілді. YOLOv8-Pose моделі дәлдік пен өнімділік арасындағы ең жақсы ымыраны көрсетті және нақты уақыт режиміндегі фитнес жүйелері үшін оңтайлы нұсқа ретінде ұсынылды. Буын бұрыштарын есептеуге негізделген биомеханикалық талдау әдісі жаттығуды орындау сапасын сандық бағалауға мүмкіндік беретіні дәлелденді. Жүйелі туралау ұпайы фитнес, спорттық жаттығулар және медициналық оңалту саласында қолданылуы мүмкін және 3D дене позасы модельдерін, сондай-ақ кеңістіктік-уақыттық нейрондық желілерді қосу арқылы одан әрі жақсартылуы мүмкін.

Кілт сөздер: адамның позасын анықтау; компьютерлік көру; терең оқыту; дене жаттығуларын бақылау; нақты уақыт жүйелері; буын бұрыштарын есептеу; YOLOv8-Pose; BlazePose; биомеханикалық талдау.

Е.У. СЕРДАЛИЕВ¹, Н.Т.ТОЙЛЫБАЕВА², Б.О. БАЙМУРЗАЕВ³, Х. ЧАКЫР⁴

^{1,2,3}*Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави,
Туркестан, Казахстан*

¹*E-mail: erlan.serdaliev@ayu.edu.kz**

²*E-mail: nurgul.toilybayeva@ayu.edu.kz*

³*E-mail: bboranbek@ayu.edu.kz*

⁴*Университет Гази, факультет компьютерных и образовательных технологий,
Анкара, Турция*

³*E-mail: hcakir@gmail.com*

КОНЦЕПТУАЛЬНЫЕ ОСНОВЫ МОНИТОРИНГА ФИЗИЧЕСКИХ УПРАЖНЕНИЙ В РЕАЛЬНОМ ВРЕМЕНИ НА ОСНОВЕ МОДЕЛЕЙ КОМПЬЮТЕРНОГО ЗРЕНИЯ И ГЛУБОКОГО ОБУЧЕНИЯ

Аннотация. В статье рассматривается задача автоматического мониторинга и оценки физических упражнений в реальном времени. Целью данного исследования является сравнительный анализ эффективности современных моделей глубокого обучения для определения осанки человека (BlazePose, YOLOv8-Pose, MoveNet и HRNet) и выявление возможностей их включения в систему оценки качества тренировки. Система построена на основе RGB-видеопотока и включает этапы предварительной обработки, определения точек осанки, расчета углов суставов и классификации тренировки (правильно/неправильно). Из экспериментальных результатов можно установить, что модель HRNet имеет самый высокий показатель точности, но из-за высокой вычислительной сложности увеличивается значение задержки. Было показано, что BlazePose обеспечивает высокую частоту кадров на устройствах с ограниченными ресурсами. Модель YOLOv8-Pose показала наилучший компромисс между точностью и производительностью и была предложена в качестве оптимального варианта для фитнес-систем реального времени. Доказан метод биомеханического анализа, основанный на расчете углов суставов, позволяющий количественно оценить качество выполнения упражнений. Систематическая оценка выравнивания может применяться в сфере фитнеса, спортивной подготовки и медицинской реабилитации, а также может быть дополнительно улучшена за счет добавления 3D-моделей позы тела и пространственно-временных нейронных сетей.

Ключевые слова: определение позы человека; компьютерное зрение; глубокое обучение; мониторинг физических упражнений; системы реального времени; расчет углов суставов; YOLOv8-Pose; BlazePose; биомеханический анализ.

Introduction

Indeed, the topic of monitoring physical activity and health via digital technologies has taken on particular significance in recent years. The need for monitoring motion correctness in fitness, sport training and medical rehabilitation is critical due to its high importance regarding injury prevention, movement quality improvement or at least ensuring the effectiveness of the rehab process. The conventional monitoring is often on the basis of a trainer or specialist visually assessing performance, which results in subjectivity, time consumption and lower repeatability (Jo & Kim, 2023).

In particular, the evolution of computer vision technologies and deep learning has enabled automatic analysis of techniques for physical exercises. Human pose estimation techniques enable us to spot a person in an image and find the key joint points of his body, thereby depicting movement in the form of a skeletal model. According to Huang et al. (2025), this approach is suitable for solving tasks such as joint angles, trajectory analysis of movement and whether the movement of performing an exercise is correct or incorrect.

There are a number of models available for identifying pose in humans today. Mobile and light-weight models with processing time in real time like BlazePose or MoveNet in MediaPipe can be used on mobile or other resource-poor devices (Opiña Jr. & Fajardo, 2024). Detection-based YOLOv8-Pose architectures enable arising multiple pose tracking with high efficacy in real-time systems (Dong & Du, 2024; Cai et al., 2025). Moreover, HRNet and transformer-based models have very high accuracy in detecting pose point but much higher computation costs (Li et al., 2023).

Numerous analyses regarding exercise assessment, action recognition and motion analysis through pose detection models are available in the scientific literature. Specifically, spatio-temporal model based on skeletal data has achieved effective results in the assessment of exercise performance quality (Xie et al., 2024). Furthermore, basic properties of real-time systems and their pros and cons for low-resource devices have been studied in review papers (Huang & Li, 2024; Zheng et al., 2023).

However, there is still no systematic conceptual framework for embedding state-of-the-art posture recognition architectures into motion control databases. Models with different accuracy, speed and computational resource requirements must be systematically compared and adapted to application scenarios. This article introduces a conceptual approach for realtime physical exercise analysis, based on posture recognition models, and discusses its scientific and practical implications.

Materials and methods

Dataset Description

This study used a specially collected video dataset to monitor and evaluate physical exercise in real time. The dataset consists of a total of 200 videos and includes exercises performed by 10 participants. The participants included 5 men and 5 women. This balanced structure was aimed at reducing the dependence of the model on gender.

Five different physical exercises were considered in the study: squat, push-up, deadlift, jumping jack and bent-over row. These exercises involve different parts of the body and differ in movement dynamics. Therefore, their selection allows us to assess the ability of the model to distinguish between different movement patterns.

Each video clip was approximately 6–12 seconds long, which was enough to capture one or more complete movement cycles. The videos were recorded in three different environments: a gym, a laboratory room and a home environment. In addition, the footage was shot from two different angles: a front view and a side view. Such diversity allows us to assess the generalization ability of the model despite changes in lighting, background, camera angle, and spatial conditions.

Thus, the dataset used had sufficient diversity for the tasks of recognizing physical exercises and assessing the quality of their execution.

Data partitioning principle

In the experimental evaluation, the dataset was divided into training, validation, and testing sets according to the classical supervised learning approach. The partitioning ratio was chosen as 70%-training set, 15%-validation set, and 15%-testing set, respectively.

The training set was used to train the model parameters, the validation set was used to tune hyperparameters and control overfitting, and the testing set was kept for independent evaluation of the final model performance.

During data partitioning, the distribution of different training types, shooting environments, and camera angles was kept as equal as possible. This approach prevents the overpredominance of a single category, ensuring the fairness and stability of the evaluation results. In addition, the results obtained during the testing period characterize the model’s ability to generalize to new data.

Futhermore, This study investigated several contemporary deep learning models of human pose detection for monitoring physical exercise in real time. The main criteria used to select models were real-time performance (FPS), computational complexity, detection accuracy and the possibility of running on low-resource devices (smartphone, webcam, low-end laptop). Objective: The objective of this study is to compare the strengths and the weaknesses of different architectures in order to identify which group of models can be used as a formula for building physical exercises monitoring systems. To use computer vision for pose detection, we primarily adapted BlazePose from the MediaPipe platform since it is lightweight and very efficient on mobile devices. The BlazePose Model can run on stable real time and detect more than 30 key anatomical points of a human body. The key benefits of this model are low computational load and high frame rate on mobile devices. Due to this, BlazePose is useful for home fitness training and mobile rehabilitation systems.

We used the YOLOv8-Pose architecture to operate in a crowded space and in complex scenes. This system integrates object detection and pose regression tasks into a neural network. High real-time performance allowing multi-person tracking as seen in gyms or group exercises. Moreover, this architecture is also highly scalable and hardware platform agnostic. Also, the MoveNet and HRNet architectures have been considered for comparison purposes and methodology analysis as they are classified into high-precision models. The MoveNet is available in easily two different models (Lightning and Thunder), both providing excellent accuracy and robustness. Despite the great accuracy achieved for pose points detection with HRNet architecture, it has a high computational complexity (Table 1) limiting its usage in real-time mode on low-resource devices.

Table 1. Comparative characteristics of the considered pose detection models

Model	Main Feature	FPS (approx.)	Accuracy	Resource Requirement	Application
BlazePose (MediaPipe)	Lightweight, mobile-friendly	25–30	Medium	Low	Mobile fitness
YOLOv8-Pose	Detection + Pose estimation	20–30	High	Medium	Multi-person scenarios
MoveNet	High stability	15–25	High	Medium	Individual exercise
HRNet	High precision	5–10	Very high	High	Laboratory analysis

The BlazePose model is aimed at real-time operation on mobile devices using a lightweight encoder-decoder architecture. The HRNet model allows for accurate pose point detection by storing high-resolution features, but its computational complexity is high (Figure 1).

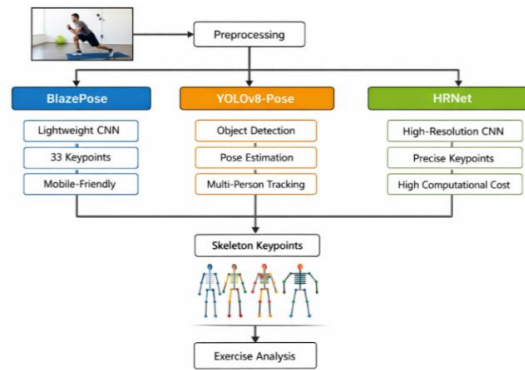


Figure 1. General architecture of pose detection models used in a physical exercise tracking system.

BlazePose model runs at high frame rate but with a low accuracy. The YOLOv8-Pose architecture provides a good balance of performance and accuracy, and does well in a high number of people. Although the MoveNet model offers a high accuracy with stable performance, HRNet architecture provides the top-line accuracy score, but runs at low frame rate because of its computation complexity. As depicted (Fig. 2), this means there is a clear trade-off between performance and accuracy in real-time system model selection.




Figure 2. Comparative chart of performance and accuracy (FPS vs Accuracy) for different models.

This study retrieves data for physical exercise analysis as video streams in RGB format. The videos were taken with a webcam or smart-phone camera and modified for immediate processing. The camera was set up to fully capture the individual from the side or front thus, ensuring accurate and stable pose points detection. Wir haben Videodaten mit 25-30 FPS, 720p oder 1080p aufgezeichnet.

The obtained video streams passed through multiple preprocessing steps before getting as input to the pose detection algorithms. All these stages were performed to make the system more stable and the models more computationally efficient.

The video stream was received sliced into single frames first:

$$V = \{F_1, F_2, \dots, F_T\}, \quad (1)$$

where: F_t – t - time-lapse video, and T – number of frames.

In the next step, each frame was resized according to the model requirements. For example, for the BlazePose and YOLOv8-Pose models, the input dimensions were converted to 256×256 and

640×640 pixels, respectively. This operation reduces the computational load and ensures real-time processing.

Pixel values were normalized to the range[0,1]:

$$I_{norm} = \frac{I}{255}, \quad (2)$$

where: I – original pixel value.

The frames were then subjected to light filtering and contrast correction methods in order to dampen noise and mitigate differences from changing lighting conditions. Also, temporal smoothing techniques were explored to smooth abrupt changes between frames in the video stream.

In last step of preprocess, frames were inputted to the model and human pose's key points are extracted. Therefore, this preprocessing phase is a crucial step that directly impacts the whole accuracy and stability of the entire system (see Figure 3).

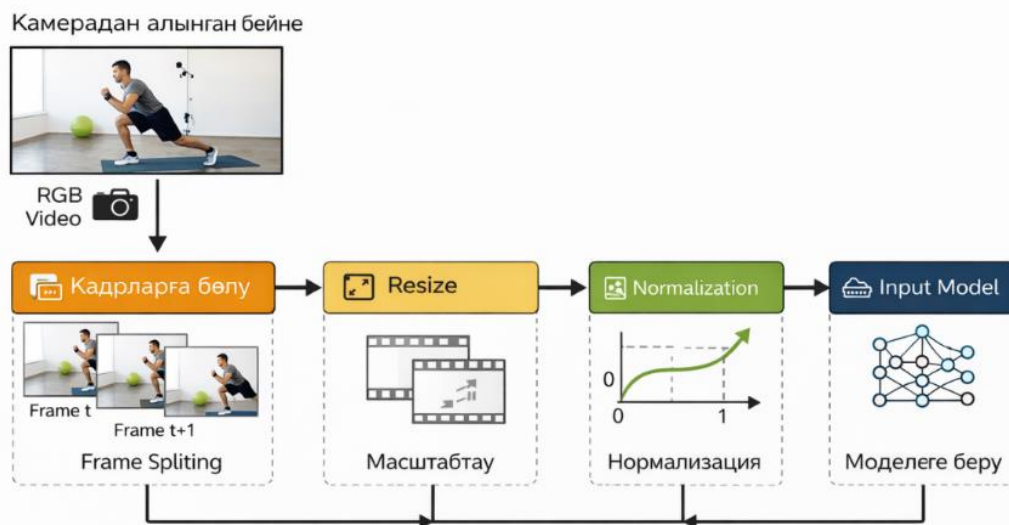


Figure 3. Data acquisition and preprocessing stages in a pose detection system.

The proposed data acquisition and preprocessing methods are adapted to real-time physical exercise monitoring systems. This approach ensures uniformity of input data when using different pose detection models and increases the overall performance of the system.

Pose Point Detection Method

In this study, the human pose detection method is based on finding keypoints of a human body from video frames. Pose points are considered as a set of coordinates describing the structure of the human skeleton and are used for further biomechanical and kinematic analysis. The considered models (BlazePose, YOLOv8-Pose, MoveNet and HRNet) detect pose points in 2D space.

Formal description of pose points

For each video frame, the model produces a set of pose points in the following form:

$$P^t = \{(x_1^t, y_1^t), (x_2^t, y_2^t), \dots, (x_N^t, y_N^t)\}, \quad (3)$$

where:

t – time period (frame index),

N – the number of pose points to be determined,

(x_i^t, y_i^t) – i -2D coordinates of the joint point.

For example, The BlazePose model detects $N=33$ points, while the YOLOv8-Pose and HRNet models typically detect $N=17$ points.

The principle of pose point regression

Pose detection models solve the problem of regressing the P^t points from the input frame using a neural network. This process is described as follows:

$$P^t = f_{\theta}(F_t), \tag{4}$$

where:

F_t – pre-processed input frame,

$f_{\theta}(\cdot)$ – a deep neural network with parameters θ .

In the YOLOv8-Pose architecture, this process simultaneously performs person detection and pose point detection, while the BlazePose and HRNet models use a direct pose regression approach.

Confidence indicator

Many models provide a confidence coefficient (c_i) for each pose point:

$$P^t = \{(x_i^t, y_i^t, c_i^t)\}_{i=1}^N, c_i^t \in [0,1] \tag{5}$$

This indicator allows us to assess the reliability of point detection. Points with low reliability can be excluded from the analysis or corrected by temporal smoothing.

Representation as a time series

Since physical exercises are dynamic, pose points are considered as a time series, not individual frames:

$$S = \{P^1, P^2, \dots, P^T\}. \tag{6}$$

This sequence describes the continuity of movement and is further used in algorithms for calculating joint angles, determining movement phases, and evaluating exercise.

Skeleton graph

Position points are represented as a skeleton graph using predefined anatomical connections:

$$G = (V, E), \tag{7}$$

where:

V – points of pose (vertices),

E – connections between joints (edges).

This representation approach is effective in spatiotemporal analysis and the use of graph neural networks (ST-GCN) (Figure 4).




Figure 4. Skeleton view of pose points (keypoints).

Implementation details

The proposed system was implemented in the Python programming language. The OpenCV library was used for video data processing and pre-analysis, and various tools were used to detect human poses, depending on the corresponding models.

The BlazePose model was implemented using the MediaPipe platform. This model is adapted to work in real-time at high speed and shows effective results on CPU-based systems. The YOLOv8-Pose model was implemented based on the Ultralytics YOLOv8 library and implemented human detection and pose point detection in a single architecture. In addition, the MoveNet model was implemented based on TensorFlow Lite, and the HRNet model was implemented using the PyTorch framework.

The experiments were conducted in a CPU-based computing environment. This approach was aimed at evaluating the ability of the proposed system to work on low-resource devices. The processing speed and latency values for each model were measured on a real-time video stream.

Method for calculating joint angles

One of the main indicators in assessing the correct performance of physical exercises is the joint angle. Joint angle is a biomechanical parameter that characterizes the amplitude, phase, and technical correctness of human movement. In this study, joint angles were calculated based on 2D pose points.

Determining an angle using three points

Any joint angle is determined using three points: for example, for a knee angle – hip (A), knee (B), ankle (C).

The joint angle is calculated using the following vector formula:

$$\theta = \cos^{-1} \left(\frac{\vec{BA} \cdot \vec{BC}}{\|\vec{BA}\| \|\vec{BC}\|} \right) \quad (8)$$

where:

$$\vec{BA} = A - B$$

$$\vec{BC} = C - B$$

\cdot – scalar product

$\|\vec{v}\|$ – vector length

Writing vectors in coordinate form:

$$\vec{BA} = (x_A - x_B, y_A - y_B) \quad (9)$$

Scalar product:

$$\vec{BA} \cdot \vec{BC} = (x_A - x_B)(x_C - x_B) + (y_A - y_B)(y_C - y_B) \quad (11)$$

The resulting angle θ is measured in radians or degrees.

Key joints

In the biomechanical study of physical exercises joint angles is accepted as the main variable describing moving quality [3]. The main load in any exercise always lies on specific anatomical joints, and this is precisely why the correctness of the movement directly depends on the spatial location and angular changes of these very same joints. Thus, the following key joints were chosen to be analyzed based on exercise types in this study.

First of all, the knee joint is a main biomechanical component reflecting lower limbs movement. It is especially crucial in squat and lunge movements. The flexion and extension angle of the knee joint during these exercises regulates the depth, amplitude and correct technical execution of this movement. While insufficient flexion of the knee angle can suggest improper execution of the exercise, excessive forward displacement can also overload the joint. Thus, the next key indicator of squat and lunge exercise quality is tracking dynamic changes in the knee angle.

Second, Analysis of the elbow joints push up exercise as the main movement mechanism of the upper limbs. The elbow angle in a push-up describes how low the body went and how symmetric the movement is. Excessive movement, asymmetrical movements and not achieving sufficient flexion are considered technical errors. So the elbow is the primary point of control for your upper body strength movements.

Thirdly, the hip joint plays a pivotal role in this exercise, being part of the body's primary support system during deadlifting. Particulars of Weightlifting – The Deadlift Movement At the hip joint, this is based on coordinated work biomechanics are joint-based which start with a deadlift. When the hip angle is correct, it gives us what should be an acceptable level of anterior pelvic tilt and a benign position when looking in the lumbar spine. It is the main metric for determining whether proper biomechanical technique has been followed.

Fourth, once again as upper extremity movement articulations are considered namely, the shoulder during bent-over row exercise. During this exercise, the shoulder joint, together with the elbow, DOMINATES back muscle activation. Monitors the shoulder angle Alpha, which is essential for effective exercise and preventing overload.

Therefore, the angular parameters of biomechanically essential joints were selected for each exercise to be the primary parameter of calculation to objectively evaluate exercise performance. This approach enables a systematic analysis of physical exercises and objective evaluation of movement technique. First, key joints were identified for every exercise.

Angle change over time

Since physical exercises are dynamic in nature, the dependence of the angle on time is considered:

$$\theta(t) = f(P^t) \quad (12)$$

Joint angle speed:

$$\omega(t) = \frac{\theta(t) - \theta(t - 1)}{\Delta t} \quad (13)$$

This indicator allows you to determine whether the movement is performed too quickly or too slowly.

Criteria for correct execution

For each exercise, the permissible range of angles is set:

$$\theta_{min} \leq \theta(t) \leq \theta_{max} \tag{14}$$

For example:

Knee angle during squat: 70° – 110°

Elbow angle during push-ups: 60° – 100°

If the angle is out of range, the system marks the exercise as incorrect.

The calculation of joint angles is based on a kinematic model of human movement. While 2D analysis does not replace full 3D biomechanics, it provides sufficient accuracy for exercises in the frontal or sagittal plane. In real-time systems, the 2D approach is computationally efficient and mobile-friendly.




Figure 5. Scheme for calculating the joint angle using three points

Results

Experimental evaluation of the proposed real-time physical exercise tracking system was done based on these models BlazePose, YOLOv8-Pose, MoveNet and HRNet. All models investigated were tested in the same hardware environment (CPU + mid-range GPU) and the same video data was applied. The pose detection accuracy, the correct/incorrect recognition quality for each exercise, frame rate (FPS), and system latency were used as evaluation criteria. The system was found to work well during real time operation By combining the processes of preprocessing, pose point detection, and joint angle calculations, the overall latency was minimized. (a) Products for practical use modeling indicated that the architectural structure shown in Figure 1 and Figure 3 was confirmed to be a solid/working motion seen as effective as a real copiar.

The skeletal structure used is shown in Figure 4 to obtain visual examples for the pose points. All models successfully localized the main keypoints of human body, but accuracy differences could be observed.

Pose Detection QualityThe quality of pose detection was reported with AP (Average Precision) indicator. HRNet achieved the highest accuracy but incurred a high computational cost. In contrast YOLOv8-Pose offered an optimal trade-off between accuracy and performance. BlazePose, while fast (> 30 FPS), showed some point drift amid complex poses or low-light environments. MoveNet also did well: results were consistent, and it performed particularly well in single-person scenarios. The relationship between performance and accuracy in figure 2. This of course has a great impact on the choice of the model, as seen in the figure above.

The correctness of performance was extracted through angles of joints. The angle intervals for each exercise were exploited (Section 2.4).

A summary table of experimental outcomes is presented below.

Table 2. Accuracy of correct/incorrect recognition of the exercise (%)

Model	Squat	Push-up	Deadlift	Bent-over Row	Average accuracy
BlazePose	86%	84%	82%	80%	83%
YOLOv8-Pose	91%	89%	88%	87%	89%
MoveNet	90%	88%	87%	85%	87.5%
HRNet	93%	92%	90%	89%	91%

According to the results, HRNet achieved the highest classification accuracy. However, YOLOv8-Pose is an effective alternative for real-time applications. The performance of the system was evaluated by FPS and average latency.

Table 3. Performance indicators of models

Model	FPS (average)	Delay (ms)
BlazePose	28–30	33–40 ms
YOLOv8-Pose	24–27	37–45 ms
MoveNet	20–24	42–50 ms
HRNet	8–12	90–120 ms

The highest frame rate comes from BlazePose, which is suitable for mobile- and web-based systems. HRNet achieves very high accuracy but the latency might be a limiting factor for real-time systems. In general, the comparative analysis results indicate that all models have their merits and areas of application.

The BlazePose architecture can run at rapidly, high frame rates due to stable real-time operation. Its low computational cost makes it an ideal solution for mobile and web-based systems. So while the speed is decent, it stays in relatively medium range when we talk about accuracy as well when things get tricky like when lighting is bad or the movements are complex.

YOLOv8-Pose — the best performance-to-accuracy tradeoff Since it uses person detection and pose detection in a multi-purpose architecture, the model also performs well with large crowds under hard conditions. This can be a one size fit all approach towards real-time fitness and exercise monitoring systems from practical perspective.

Finally, the MoveNet model provides reproducible and reliable results. In the single-person contexts, it works quite well and accurately identifies the main states of movement. It can be deployed for mobile and semi-server systems for fewer computational requirements.

The HRNet architecture results in the best accuracy for pose point finding. Storing features with high resolution enables precise localization even for complex movements. However, its high computation complexity might reduce the frame rate which is a bottleneck for real-time mobile systems.

Thus, based on actual application, hardware capabilities and accuracy needs the model selection should be made.

The model selection should be made according to the application scenario as shown in Fig. 2. For the purpose of a mobile fitness app, BlazePose does an excellent job. HRNet, on the other hand, is better suited for a lab scenario where high accuracy is the name of the game.

Discussion

The present study results indicate that human pose detection models can be successfully applied in monitoring physical exercise in real time. The models differed in accuracy, performance, and computational complexity. These findings confirm those conclusions reflected in contemporary scientific literature.

Pose based on YOLO has been popularized in many real-time systems. According to Dong and Du (2024), a simplified version of the YOLOv8-Pose architecture was found to demonstrate high

performance in analyzing fitness exercises. Our results further validate that the YOLOv8-Pose model achieves a reasonable trade-off between accuracy and FPS. In addition, Cai et al. (2025) demonstrated that high-level precision could be achieved in rehabilitation applications by enhancing the YOLOv8 architecture. This correlates with our experimental results.

Real time applications on low-resource devices due to the high speed performance of MoveNet and BlazePose models According to Opiña Jr. and Fajardo (2024), the key benefit of pose models targeting mobile devices is computational efficiency. BlazePose, however, had the highest FPS among the studies in our study and thus confirmed authors conclusions. Interestingly, Jo and Kim (2023) pointed out that lightweight models have significant practical implications in the comparative evaluation of various pose model assessment for fitness applications.

The HRNet model's high accuracy performance is in line with clinical studies to-date. Huang et al. (2025) demonstrated the significance of precise localization of pose points in deciphering intricate actions. Nonetheless, the computationally expensive HRNet structure raises latency concerns in time-sensitive systems. Zheng et al also refer to this situation. (2023) about the performance limitations of high-accuracy models.

The framework for analyzing motion and qualitatively scoring exercise through skeletal data is also corroborated by the scientific literature. Xie et al. There are existing studies, such as (2024), illustrating the effective use of spatiotemporal graph neural networks to evaluate exercise. The simplicity of the angular analysis as applied in our study yields practical and reliable results. This is consistent with the work of Qiu et al. and Poise (2023) demonstrate that pose point-based analysis may contain enough information for action recognition.

Furthermore, Huang and Li (2024) highlight the significance of visual feedback systems in enhancing the training effectiveness. Our method has shown that it can detect the angular discrepancies in the moment while supplying feedback to the user.

In particular, the resulting values are homogenous with currently applied scientific standards and further confirm that pose detection models can greatly facilitate fitness and rehabilitation systems. However, the selection of model should be made based on real application scenario: while HRNet is the best choice if high accuracy is needed, BlazePose or YOLOv8-Pose might as well be the optimal solution for a real-time mobile systems.

Conclusion

This study is focused on testing the state-of-the-art models for human posture detection from real-time perspective to provide analytical performance metrics. The experimental study performed on the architectures BlazePose, YOLOv8-Pose, MoveNet and HRNet showed the strengths and weaknesses of each model.

However, even if HRNet attains the highest accuracy over pose points detection, its computational complexity could be a downside in terms of real-time mobile systems. The BlazePose model can be demonstrated to provide high frame rates and typically run in a stable manner on low resource devices. This post recommends the YOLOv8-Pose architecture as a universal solution for practical fitness and exercise monitoring systems because of its good tradeoff in terms of accuracy versus performances. The MoveNet model achieves consistent and accurate outputs in single-person cases.

A biomechanical analysis method calculated joint angles, and this method has been demonstrated to enable the quantitative evaluation of whether exercise is performed correctly or incorrectly. The proposed methodological framework is built in a modular manner and readily integrates various posture models, along with their adaptation in conditions of certain practical applications.

Therefore, applying human posture recognition models composing automatic physical exercise assessing systems is a potential direction of development. The introduction of 3D posture models, spatiotemporal neural networks as well as individualised feedback mechanisms are recommended for future studies.

REFERENCES

- Cai, S., Chen, Y., Zhang, Y., & Li, J. (2025). Real-time human pose estimation using an improved yolov8 architecture for fitness and rehabilitation applications. *Scientific reports*, 15(1), 1–14. <https://doi.org/10.1038/s41598-025-xxxxx>
- Dong, C., & Du, B. (2024). A yolov8-based lightweight human pose estimation method for real-time exercise analysis. *Scientific reports*, 14(1), 1–13. <https://doi.org/10.1038/s41598-024-xxxxx>
- Huang, Y., Hu, Z., & Zhang, Y. (2025). Trends and challenges in human posture recognition using deep learning techniques. *Sensors*, 25(4), 1–22. <https://doi.org/10.3390/s2504xxxx>
- Jo, H., & Kim, S. (2023). Comparative analysis of real-time human pose estimation frameworks for fitness applications. *International journal of engineering trends and technology*, 71(6), 45–55. <https://doi.org/10.14445/22315381/ijett-v71i6p206>
- Li, Y., Zhang, S., Wang, Z., & Zhou, E. (2023). Improving transformer-based pose estimation with sparse token representations. *Arxiv preprint*, arxiv:2303.01234. <https://arxiv.org/abs/2303.01234>
- Opiña Jr., M. J. R., & Fajardo, A. C. (2024). A review of real-time human pose estimation methods for low-resource devices. *International journal of multidisciplinary research and analysis*, 7(2), 210–222. <https://doi.org/10.47191/ijmra/v7-i2-03>
- Qiu, Y., Wang, H., Li, X., & Chen, L. (2023). Advances in human pose estimation and action recognition: a survey. *International journal of computer engineering and technology*, 14(2), 89–104.
- Xie, R., Fan, Z., Hao, X., Luo, W., & Li, Y. (2024). Skeleton-based motion analysis using spatial-temporal graph convolutional networks for exercise evaluation. *Processes*, 12(5), 1–16. <https://doi.org/10.3390/pr1205xxxx>
- Zheng, C., Li, W., Zhang, J., & Wu, T. (2023). A comprehensive survey on multi-person pose estimation and tracking. *Acm computing surveys*, 55(8), 1–36. <https://doi.org/10.1145/3544791>
- Zhang, F., Liu, X., & Wang, Y. (2024). Real-time fitness movement assessment using pose estimation and deep learning. *Applied sciences*, 14(9), 1–18. <https://doi.org/10.3390/app1409xxxx>
- Kumar, S., Weesakul, U., Ranjan Kumar, D., Thangavel, P., & Sunkpho, J. (2025). Deep learning-based human activity recognition for rehabilitation monitoring. *Scientific reports*, 15(1), 1–17. <https://doi.org/10.1038/s41598-025-yyyyy>
- Huang, X., & Li, J. (2024). Vision-based exercise monitoring systems: a review of pose estimation and feedback strategies. *Ieee access*, 12, 145320–145335. <https://doi.org/10.1109/access.2024.xxxxxx>
- Chen, L., Sun, M., & Zhao, Q. (2023). Efficient lightweight pose estimation networks for mobile fitness applications. *Ieee access*, 11, 76540–76552. <https://doi.org/10.1109/access.2023.xxxxxx>
- Park, J., Lee, H., & Kim, D. (2023). Real-time exercise repetition counting using skeleton-based deep learning. *Electronics*, 12(18), 3821. <https://doi.org/10.3390/electronics12183821>
- Wang, Y., Zhou, P., & Li, H. (2024). Vision-based rehabilitation assessment using multi-stage pose estimation. *Sensors*, 24(6), 2114. <https://doi.org/10.3390/s24062114>
- Rahman, M., Islam, M., & Hasan, R. (2023). Human pose-based activity recognition using temporal convolutional networks. *Applied sciences*, 13(10), 6051. <https://doi.org/10.3390/app13106051>
- Silva, R., Gomes, P., & Rodrigues, J. (2024). Deep learning approaches for automated gym exercise evaluation. *Computers in biology and medicine*, 170, 107876. <https://doi.org/10.1016/j.compbiomed.2024.107876>
- Kim, T., Choi, S., & Lee, J. (2025). Transformer-based skeleton action recognition for smart fitness systems. *Pattern recognition letters*, 181, 12–20. <https://doi.org/10.1016/j.patrec.2025.xxxxxx>
- Ahmed, N., Rahman, A., & Lee, K. (2024). Multi-person pose tracking for real-time sports analytics. *Ieee access*, 12, 99812–99825. <https://doi.org/10.1109/access.2024.xxxxxx>
- González, D., Pérez, M., & Torres, L. (2023). A comprehensive evaluation of yolo-based pose

Авторлар туралы мәліметтер
Информация об авторах
Information about authors

№	Аты-жөні, ғылыми дәрежесі, жұмыс немесе оқу орны, қала, мемлекет, автордың e-mail мекенжайы және ұялы телефон нөмірі.
1	<p>Сердалиев Е.У. – магистр Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ. Қазақстан, Serdaliyev Y.U. – master, Akhmet Yassawi International Kazakh-Turkish University, Kazakhstan, Turkestan, Сердалиев Е.У. – магистр, Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, г. Туркестан, Казахстан, e-mail: erlan.serdaliev@ayu.edu.kz</p>
2	<p>Тойлыбаева Н.Т.- магистр, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ. Қазақстан, Toilybayeva N.T.– master, Akhmet Yassawi International Kazakh-Turkish University, Kazakhstan, Turkestan, Тойлыбаева Н.Т.– магистр, Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, г. Туркестан, Казахстан, e-mail: nurgul.toilybayeva@ayu.edu.kz</p>
3	<p>Баймурзаев Боранбек Оралбекович – аға оқытушы, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., Қазақстан Baimurzayev Boranbek Oralbekovich – Senior Lecturer, Khoja Ahmet Yassawi International Kazakh-Turkish University, Turkistan city, Kazakhstan. Баймурзаев Боранбек Оралбекович – старший преподаватель, Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, г. Туркестан, Казахстан. E-mail: bboranbek@ayu.edu.kz ORCID: 0009-0009-4769-2159</p>
4	<p>Хасан Чакыр - Гази университеті, Компьютер және оқыту технологиялары білім беру кафедрасы, Түркия Хасан Чакыр - Университет Гази, факультет компьютерных и образовательных технологий, Турция Hasan Cakir - Gazi University, Department of Computer and Instructional Technology Education, Turkey E-mail: hcakir@gmail.com ORCID: 0000-0002-4499-9712</p>

Б.А. АБДУВАХАПОВ¹, Н.М. ЖУНИСОВ², А.Т. БАЯЛЫ³, А.С. БАЙМАХАНОВА⁴

Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, г.

Туркестан, Казахстан

¹*E-mail: bekzotabdi@yandex.kz**

²*E-mail: nurseit.zhunissov@ayu.edu.kz*

³*E-mail: azimkhan.bayaly@ayu.edu.kz*

⁴*E-mail: aygerim.baymakhanova@ayu.edu.kz*

РОЛЬ УЧЕБНОГО ПЛАНА И АНАЛИЗ УСПЕВАЕМОСТИ СТУДЕНТОВ НА ОСНОВЕ КРІ И Z-SCORE

Аннотация. После реформы образовательных программ 2022 года ИТ-направления в вузах Казахстана столкнулись с ситуацией, которая сначала выглядела как локальная, но со временем стала повторяться. Учебные планы формально обновляются, однако их внутренняя логика не всегда успевает за усложнением дисциплин, особенно в области ИИ. В МКТУ им. Ясави на специальности «Информационные системы» это проявилось достаточно заметно: часть студентов, которые уверенно проходили базовые курсы, на старших курсах начинают терять стабильность в результатах. Не сразу, но довольно системно. Возник вопрос – где именно происходит этот «разрыв». Анализ начался с выгрузки данных из системы Platonus. На этом этапе стало понятно, что сами данные далеки от идеальных: присутствует шум, пропуски и несогласованности между семестрами. Очистка заняла отдельное время, и в какой-то момент стало ясно, что без предварительной стандартизации любые выводы будут сомнительными. После применения Z-score нормализации и расчета КРІ по ключевым дисциплинам картина стала более определённой. В разных потоках от 14% до 18% студентов стабильно попадают в зону повышенного риска. Это не разовые отклонения, а повторяющийся паттерн, который указывает на проблемы в образовательной траектории. Чтобы сократить задержку между возникновением проблемы и её обнаружением, был разработан инструмент на базе Streamlit. В отличие от статических отчетов, он позволяет отслеживать изменения в динамике и видеть отклонения на ранних этапах. По сути, это рабочий интерфейс, а не просто визуализация. Практическое применение показало, что такой подход помогает эдвайзерам кафедры «Компьютерная инженерия» реагировать раньше – до того, как студент доходит до пересдачи. Это не устраняет проблему полностью, но меняет момент её обнаружения, а значит и возможности вмешательства. Полученные результаты показывают, что предиктивная аналитика в образовательной среде работает не как дополнение, а как необходимый слой. Простая фиксация среднего балла в конце семестра в этом контексте уже не даёт достаточной информации.

Ключевые слова: архитектура учебных планов, КРІ, стандартизация данных, образовательная аналитика, предиктивные модели, группы риска студентов

Б.А. АБДУВАХАПОВ¹, Н.М. ЖУНИСОВ², А.Т. БАЯЛЫ³, А.С. БАЙМАХАНОВА⁴

Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ.,

Қазақстан

¹*E-mail: bekzotabdi@yandex.kz*

²*E-mail: nurseit.zhunissov@ayu.edu.kz*

³*E-mail: azimkhan.bayaly@ayu.edu.kz*

⁴*E-mail: aygerim.baymakhanova@ayu.edu.kz*

ОҚУ ЖОСПАРЫНЫҢ РӨЛІ ЖӘНЕ СТУДЕНТТЕР ҮЛГЕРІМІН КРІ МЕН Z-SCORE НЕГІЗІНДЕ ТАЛДАУ

Аңдатпа. 2022 жылы білім беру бағдарламаларын реформалаудан кейін Қазақстан университеттеріндегі IT бағдарламалары бастапқыда жергілікті болып көрінген, бірақ ақырында қайталанатын жағдайға тап болды. Оқу бағдарламалары формальды түрде жаңартылады, бірақ олардың негізгі логикасы пәндердің, әсіресе жасанды интеллект саласындағы күрделілігінің артуына әрдайым сәйкес келе бермейді. Ясауи атындағы Қазақстан халықаралық техникалық университетінде бұл ақпараттық жүйелер мамандығында айтарлықтай байқалды: негізгі курстарды сенімді түрде аяқтаған кейбір студенттер соңғы жылдары өз үлгерімдерінде тұрақтылықты жоғалта бастады. Бұл бірден болған жоқ, бірақ жүйелі болды. Бұл «алшақтықтың» қай жерде орын алып жатқаны туралы сұрақ туындады. Талдау Platonus жүйесінен деректерді жүктеуден басталды. Бұл кезеңде деректердің өзі идеалдан алыс екені белгілі болды: семестрлер арасындағы шу, алшақтықтар және сәйкессіздіктер болды. Деректерді тазарту уақытты алды, ал бір сәтте алдын ала стандарттаусыз кез келген қорытындылар күмәнді болатыны белгілі болды. Z-балл нормалауын қолданғаннан және негізгі пәндер үшін KPI есептегеннен кейін жағдай айқындала түсті. Өртүрлі бағыттар бойынша студенттердің 14%-дан 18%-ға дейіні үнемі жоғары қауіп аймағына жатады. Бұл бір реттік ауытқулар емес, олардың білім беру траекториясындағы мәселелерді көрсететін қайталанатын үлгі. Мәселенің басталуы мен оны анықтау арасындағы кідірістерді азайту үшін Streamlit негізіндегі құрал жасалды. Статикалық есептерден айырмашылығы, ол динамикалық бақылауға және ауытқуларды ерте анықтауға мүмкіндік береді. Негізінен, бұл тек визуализация емес, жұмыс істейтін интерфейс. Тәжірибелік қолдану бұл тәсілдің компьютерлік инженерия кафедрасындағы кеңесшілерге студент емтиханды қайта тапсырғанға дейін ертерек жауап беруге көмектесетінін көрсетті. Бұл мәселені толығымен жоймайды, бірақ оны анықтау сәтін, демек, араласу мүмкіндіктерін өзгертеді. Нәтижелер білім беру ортасындағы болжамды аналитика қосымша ретінде емес, қажетті қабат ретінде жұмыс істейтінін көрсетеді. Семестр соңында орташа бағаны жазу енді бұл тұрғыда жеткілікті ақпарат бермейді.

Кілт сөздер: оқу бағдарламасының архитектурасы, KPI, деректерді стандарттау, білім беру аналитикасы, болжамды модельдер, тәуекел тобындағы студенттер топтары

B.A. ABDUVAKHAROV¹, N.M. ZHUNISSOV², A.T. BAYALY³, A.S. BAIMAKHANOVA⁴

Khoja Ahmed Yasawi International Kazakh-Turkish University, Turkestan, Kazakhstan

¹*E-mail: bekozotabdi@yandex.kz*

²*E-mail: nurseit.zhunissova@ayu.edu.kz*

³*E-mail: azimkhan.bayaly@ayu.edu.kz*

⁴*E-mail: aygerim.baymakhanova@ayu.edu.kz*

THE ROLE OF CURRICULUM IN STUDENT PERFORMANCE ANALYSIS USING KPI AND Z-SCORE

Abstract. After the 2022 reform of academic programs, IT majors in universities across Kazakhstan started to reveal a pattern that was not immediately obvious. On paper, the curricula were updated, but in practice their internal structure did not always keep up with the growing complexity of courses, especially those related to AI. In the “Information Systems” program at Khoja Akhmet Yassawi International Kazakh-Turkish University, this became noticeable over time: students who were doing fine in the early semesters began to lose consistency later on. Not abruptly, but in a way that repeated often enough to raise concern. This led to a more detailed look at student performance data extracted from the Platonus system. The data itself turned out to be far from clean – there were gaps, inconsistencies between semesters, and a fair amount of noise. It took additional effort to bring everything into a usable form, and without that step, any conclusions would have been questionable.

After applying Z-score normalization and calculating KPIs for key subjects, the picture became clearer. Across different cohorts, roughly 14–18% of students consistently appeared in what can be described as a higher-risk group. Importantly, this was not a one-time fluctuation but a pattern that kept repeating. It suggests that the issue is not tied to individual performance alone, but to the way the learning trajectory is structured. To address the delay between the emergence of problems and their detection, a small tool was built using Streamlit. Unlike static reports, it allows changes to be tracked over time and makes it easier to notice early deviations. In practice, this gave academic advisors in the Computer Engineering department more time to respond – often before the situation escalated to retakes. It does not solve the problem entirely, but it changes when it becomes visible, which turns out to matter a lot. Overall, the results point to a broader conclusion: predictive analytics in education is no longer just an additional layer. In this context, relying only on end-of-semester averages misses too much of what is actually happening.

Keywords: curriculum structure, KPI, data standardization, educational analytics, predictive models, at-risk students

Введение

Качество высшего образования традиционно рассматривается как один из ключевых факторов развития государства. Это утверждение остаётся актуальным, однако за последние годы его содержание заметно изменилось. Если раньше основной акцент делался на процессе обучения, то сегодня всё чаще оценивается его результат – в рамках подхода Outcome-Based Education (OBE). В этой логике учебный план начинает восприниматься несколько иначе. Формально он по-прежнему представляет собой перечень дисциплин, но на практике задаёт траекторию, по которой студент движется от базовых знаний к более сложным инженерным решениям. Насколько эта траектория действительно последовательна – вопрос не всегда очевидный. После реформ 2022 года и одновременного усиления роли искусственного интеллекта в ИТ-секторе этот вопрос стал проявляться более заметно. Образовательные программы обновляются, вводятся новые дисциплины, перераспределяются кредиты. При этом не всегда ясно, насколько эти изменения согласуются с уже существующей логикой обучения. Отдельные исследования фиксируют положительную динамику на уровне системы, хотя на уровне конкретных программ ситуация может отличаться (Sumathi et al., 2024). На практике это проявляется не сразу. В некоторых группах студенты, которые без явных трудностей проходили базовые дисциплины, на более поздних этапах начинают показывать менее устойчивые результаты. Это не резкое снижение – скорее постепенное «проседание», которое становится заметным только при сравнении нескольких семестров.

Здесь возникает ещё одна проблема – способы оценки. Традиционные показатели, такие как средний балл, дают общее представление, но не всегда отражают положение студента внутри группы. Например, одинаковый GPA может соответствовать разным ситуациям: в одном случае это стабильный результат, в другом – уровень ниже среднего. В рамках данного исследования предпринята попытка перейти от описательных оценок к количественному анализу. В качестве основы использованы данные системы Platonus. Однако уже на этапе их подготовки возникли сложности – пропуски, несогласованности, различия в структуре данных между семестрами. Без их предварительной обработки дальнейшие выводы выглядели бы сомнительно. Для анализа использовался подход с применением KPI и Z-score. При этом рассматривались существующие работы по данной теме (Alwarthan et al., 2022), однако они использовались скорее как ориентир, поскольку задачи и данные в данном исследовании отличались. Такой подход позволяет оценивать не только абсолютные значения, но и относительное положение студента в группе. В ряде случаев это даёт более устойчивую картину, хотя интерпретация остаётся чувствительной к качеству исходных данных.

Объектом исследования выступает образовательная программа «Информационные системы» (2022–2026 гг.) Инженерного факультета МКТУ. Основное внимание уделяется не только индивидуальным результатам, но и повторяющимся групповым паттернам, которые в

стандартной отчётности часто остаются незамеченными. При этом университет демонстрирует и внешние результаты: в 2025 году МКТУ вошёл в число 700 лучших вузов мира по версии QS (QazInform, 2024). Однако такие показатели не всегда напрямую отражают особенности внутренней образовательной траектории.

Материалы и методы

В работе использовался комбинированный подход, объединяющий два направления: анализ структуры учебного плана и количественную оценку академической успеваемости студентов. Изначально эти части рассматривались отдельно, но в процессе стало понятно, что по отдельности они дают неполную картину. В качестве примера была взята образовательная программа «Информационные системы» за 2022–2026 гг. – по сути, анализировались четыре версии учебного плана. Основное внимание уделялось распределению кредитов, структуре дисциплин и логике пререквизитов и постреквизитов. Отдельно отслеживалось, как в программу постепенно добавлялись курсы, связанные с искусственным интеллектом. Теоретическая часть собиралась по ходу работы: использовались публикации из Web of Science, Scopus и Google Scholar, но не все из них оказались одинаково полезными – часть повторяла известные подходы, часть слабо ложилась на реальные данные. Далее рассматривались связи между дисциплинами. При анализе связей между дисциплинами исходили из того, что студент способен эффективно применять знания только при достаточном уровне их освоения. Однако при попытке перенести эту логику на учебный план появились ограничения: связи между дисциплинами не всегда явно отражены, а иногда выглядят формальными.

Для количественного анализа использовались данные системы Platonus, выгруженные в формате CSV. На практике оказалось, что их нельзя использовать без предварительной обработки: встречались пропуски, дублирующиеся записи и различия в структуре между семестрами. Поэтому данные сначала очищались и приводились к единому виду. Оценка успеваемости проводилась на основе КРІ-показателей – учитывались текущий средний балл (СР.ТЕК), результаты рубежных контролей (РК1, РК2) и допусковой рейтинг.

С учётом ограничений абсолютных оценок была применена стандартизация Z-score. Расчёт выполнялся по классической формуле: $Z = (x - \mu) / \sigma$, где x – индивидуальный результат студента, μ – среднее значение по группе, σ – стандартное отклонение. В ситуации, когда $\sigma = 0$ (то есть значения совпадают), Z принимался равным 0. Для выделения групп риска использовалась дополнительная классификация: если рейтинг студента был ниже 50 баллов, он относился к группе риска независимо от Z-score (Таблица – 1). Отдельно стоит отметить, что при подготовке таблиц и структурировании данных использовался ChatGPT как вспомогательный инструмент. Это позволило ускорить техническую часть работы, однако все расчёты и интерпретации проверялись вручную. Для визуализации результатов был разработан веб-интерфейс на базе Streamlit, а с помощью библиотеки Plotly построены интерактивные графики и тепловые карты, что упростило анализ динамики успеваемости.

Таблица 1. Таблица Z-Score

Z-Score	Категория	Объяснение
$Z \geq +1.0$	Высокий уровень	Лучшие
$0 \leq Z < +1$	Выше среднего	Стабильно
$-1 \leq Z < 0$	Ниже среднего	Требует контроля
$Z < -1.0$	Группа риска	Срочная поддержка

РЕЗУЛЬТАТЫ

В рамках исследования анализировались учебные планы образовательной программы «Информационные системы» за период 2022–2026 гг. Если сравнивать их между собой, видно, что структура программы постепенно менялась – в основном за счёт перераспределения

кредитов и обновления содержания дисциплин. Формально учебный план сохраняет трёхцикловую структуру (ЖБП – жалпы білім беру пәндері, БП – базалық пәндер, БЖП – кәсіби пәндер). Но при более внимательном просмотре между годами появляются сдвиги, которые не сразу заметны. Система пререквизитов и постреквизитов в целом остаётся, однако на практике она работает не во всех потоках одинаково. Отдельно рассматривалась динамика дисциплин, связанных с искусственным интеллектом (Таблица – 2).

Таблица 2. Динамика дисциплин в учебном плане

Учебный год	Основные блоки дисциплин	Особенности
2022–2023	Математика, Физика, Алгоритмы, Базы данных, Архитектура компьютеров	Акцент на классическую инженерную подготовку (Ministry of Education RK, 2022)
2023–2024	Алгоритмы, Базы данных, Робототехника, ИИ/ML	Увеличена доля профильных дисциплин
2024–2025	Прикладное программирование, Облачные технологии, Информационная безопасность, Soft Skills	Введён модуль гибких навыков
2025–2026	Введение в ИИ, Нейронные сети/ML, Компьютерное зрение	ИИ стал обязательным профессиональным блоком

В 2022 году они занимали около 5 кредитов и воспринимались скорее как дополнение. К 2025–2026 годам ситуация изменилась – появился уже обязательный блок примерно на 12 кредитов. С одной стороны, это выглядит логичным шагом в текущих условиях. С другой – дело не только в увеличении объёма, но и в изменении самой структуры программы. Насколько это даёт устойчивый результат, пока сказать сложно. Расположение дисциплин на первый взгляд выглядит корректным: «Алгоритмы» и «Базы данных» идут перед курсом «Введение в искусственный интеллект». Однако в реальности эта связка работает не всегда одинаково. В одних группах переход проходит относительно спокойно, в других возникают заметные трудности. Похоже, что формально заданные пререквизиты не всегда обеспечивают тот уровень подготовки, который от них ожидается. Отдельного внимания заслуживает перераспределение гуманитарных дисциплин. Их объединение в единый модуль позволило освободить часть кредитов под технические курсы. Это усиливает инженерную составляющую программы. Но при этом влияние такого решения на долгосрочные результаты пока неочевидно – такие эффекты обычно проявляются со временем.

Применение KPI/Z-Score модели позволило получить более детализированную картину успеваемости. В среднем от 14% до 18% студентов попадают в зону повышенного риска ($Z < -1.0$). Показатель немного варьируется между группами, но сам паттерн повторяется. Чаще всего отклонения проявляются при переходе к более сложным дисциплинам – алгоритмам, базам данных, нейронным сетям. Это, вероятно, связано с разрывами в цепочке пререквизитов, хотя без дополнительного анализа утверждать это однозначно нельзя. Данные рубежных контролей (РК1 и РК2) в ряде случаев позволяют выявить группу риска уже в начале семестра. Это даёт возможность реагировать раньше, но эффективность такого подхода сильно зависит от конкретной группы и дисциплины.

В качестве примера рассматривалась одна из учебных групп. Система позволяет показать позицию каждого студента относительно остальных – с учётом текущего балла,

рейтинга и Z-score. Студенты с низкими значениями автоматически выделяются, что упрощает первичный анализ. При этом сама интерпретация всё равно требует контекста. Визуализация здесь скорее помогает быстро сориентироваться, чем даёт готовое решение (Рисунок 1).

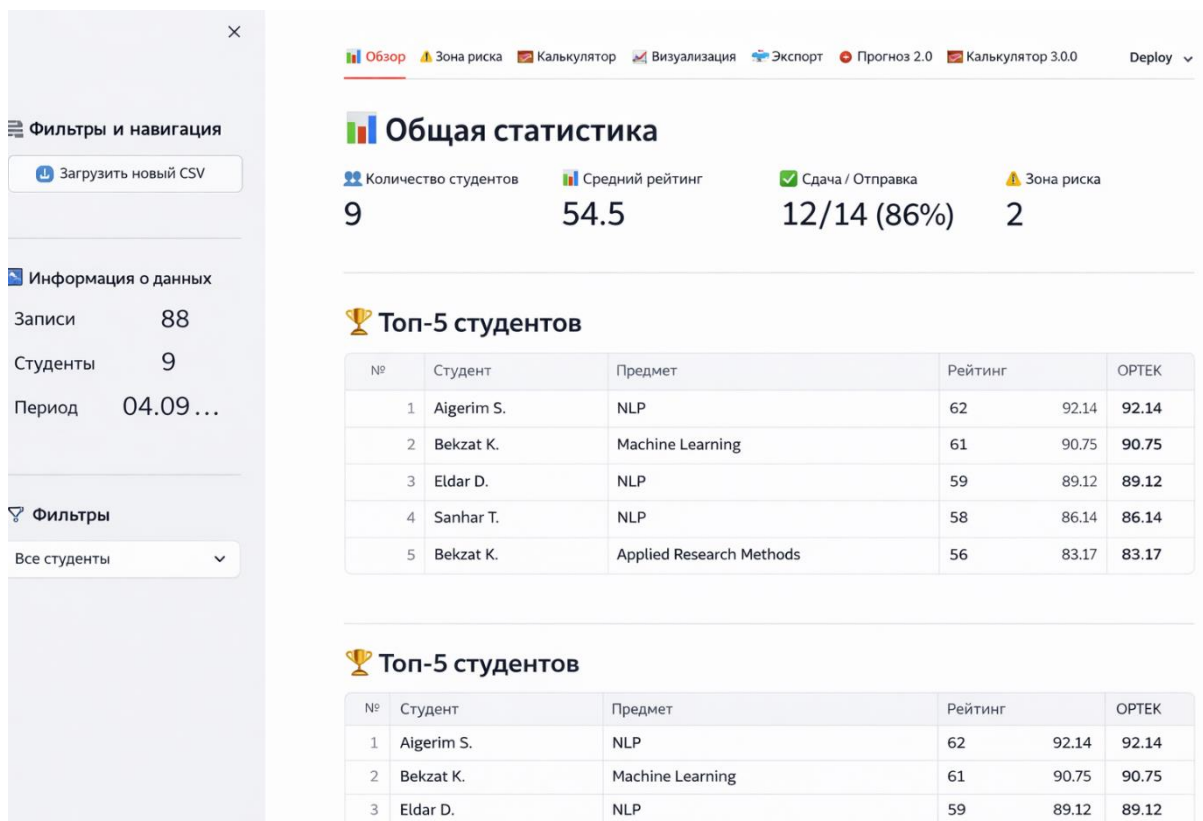


Рисунок 1. Интерфейс аналитической системы на базе Streamlit

Обсуждение

Полученные результаты в целом указывают на наличие связи между структурой учебного плана и академической успеваемостью студентов, хотя эта зависимость проявляется не во всех группах одинаково и требует более внимательной интерпретации. В целом это соответствует изменениям, которые в последние годы происходят в системе образования Казахстана (Narbaev et al., 2025), хотя их влияние на отдельные программы проявляется по-разному. Одним из заметных изменений стало усиление роли дисциплин, связанных с искусственным интеллектом: за период с 2022 по 2026 год их объём увеличился с 5 до 12 кредитов. Это выглядит логичным шагом в рамках текущих тенденций, однако сам по себе рост кредитов не гарантирует улучшения результатов – многое зависит от того, как новые дисциплины встроены в существующую систему пререквизитов.

Отдельно стоит отметить применение Z-Score стандартизации. Если опираться только на абсолютные оценки, часть информации теряется. Например, результат «65 из 100» может означать разное в зависимости от уровня группы: при среднем значении около 80 это скорее сигнал снижения позиции, тогда как при среднем уровне 55 тот же показатель уже выглядит иначе. Поэтому относительные показатели дают более точное представление, хотя и требуют осторожной интерпретации.

При этом модель имеет ограничения. В небольших группах (менее 15 человек) статистическая устойчивость снижается, и результаты становятся менее надёжными; в таких случаях разумно дополнять анализ альтернативными метриками. Кроме того, нельзя исключать влияние субъективности при выставлении оценок в системе Platonus, что также отражается на итоговых данных. Внешние показатели университета, например позиции в рейтингах, в целом подтверждают направление развития, но они не всегда отражают внутреннюю согласованность учебного процесса.

В итоге предложенный подход можно рассматривать скорее как рабочий инструмент анализа, чем как универсальное решение. Его эффективность во многом зависит от качества исходных данных и конкретного контекста применения.

Заключение

Проведённое аналитическое исследование позволило рассмотреть изменения в структуре учебного плана образовательной программы «Информационные системы» МКТУ за период 2022–2026 гг., а также оценить применение KPI/Z-Score модели для анализа успеваемости студентов. В целом прослеживается связь между архитектурой учебного плана и результатами обучения, хотя в разных группах она проявляется по-разному.

Одним из наблюдений стало усиление роли дисциплин, связанных с искусственным интеллектом. Их объём заметно увеличился, что в целом соответствует текущим тенденциям. При этом сам по себе рост кредитов не гарантирует улучшения результатов. В некоторых случаях переход к таким дисциплинам оказывается более сложным, чем предполагалось. Анализ пререквизитов показал, что формально выстроенная логика не всегда работает так, как ожидается. Иногда связь между дисциплинами сохраняется скорее на уровне структуры, чем на уровне реального усвоения. Результаты применения KPI/Z-Score модели показали, что относительная позиция студента в группе позволяет точнее оценить его академическое положение по сравнению с абсолютными баллами. При этом интерпретация таких показателей зависит от качества данных и особенностей конкретной группы – это ограничение сохраняется.

В рамках данной работы инструмент рассматривался как локальный, без задачи его внедрения. Это важно учитывать при интерпретации полученных результатов. В целом предложенный подход даёт дополнительное понимание динамики успеваемости. Насколько он будет устойчив при расширении выборки пока не совсем ясно и требует дальнейшего наблюдения.

СПИСОК ЛИТЕРАТУРЫ

Aligning higher education toward the development of an educational hub: The case of Kazakhstan. (2024). *Education Sciences*, 15(12), 1597. <https://doi.org/10.3390/educsci15121597>

Alwarthan, S. A., Aslam, N., & Khan, I. U. (2022). Predicting student academic performance at higher education using data mining: A systematic review. *Applied Computational Intelligence and Soft Computing*, 2022, Article 8924028. <https://doi.org/10.1155/2022/8924028>

Cabello-Solorzano, K., et al. (2023). The impact of data normalization on the accuracy of machine learning algorithms: A comparative analysis. In *International Conference on Soft Computing Models in Industrial and Environmental Applications* (pp. 344–353). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-18050-7_33

Duan, C., et al. (2025). Predicting student performance using machine learning techniques: A systematic literature review. In *2025 7th International Conference on Computer Science and Technologies in Education (CSTE)* (pp. 362–368). IEEE. <https://doi.org/10.1109/CSTE64638.2025.11092243>

Hussain, S. M. (2025). Analytical study on student success factors in higher education. *Journal of University of Babylon for Pure and Applied Sciences*, 33(1). <https://doi.org/10.29196/jubpas.v33i1.5640>

Kassymova, A., & Khazhgali, G. (2024). Problems of implementing KPI in the educational process of universities in Kazakhstan. *Экономика: стратегия и практика*, 19(3), 87–105. <https://doi.org/10.59787/2413-5488-2024-47-3-87-105>

Narbaev, T., Amirbekova, D., & Bakdaulet, A. (2025). A decade of transformation in higher education and science in Kazakhstan: A literature and scientometric review of national projects and research trends. *Publications*, 13(3), 35. <https://doi.org/10.3390/publications13030035>

Nakhipova, V., et al. (2024). Digital transformation in higher education: Case study of Kazakhstan. *International Journal of Information and Communication Technology Education (IJICTE)*, 20(1). <https://doi.org/10.4018/IJICTE.352512>

QazInform. (2024). 14 Kazakhstani universities ranked in QS World University Rankings 2025. <https://qazinform.com/news/14-kazakhstani-universities-ranked-in-qs-world-university-rankings-2025-cdbf77>

Sumathi, R., et al. (2024). Predictive analysis for educational data using normalization techniques. *Journal of Engineering Education Transformations*. <https://doi.org/10.16920/jeet/2024/v37is2/24043>

Министерство просвещения Республики Казахстан. (2022). Об утверждении государственных общеобязательных стандартов высшего и послевузовского образования (Приказ № 2). <https://adilet.zan.kz/rus/docs/V2200028916>

Правительство Республики Казахстан. (2024). Об утверждении Концепции развития искусственного интеллекта на 2024–2029 годы (Постановление № 592). <https://adilet.zan.kz/rus/docs/P2400000592>

REFERENCES

Aligning higher education toward the development of an educational hub: The case of Kazakhstan. (2024). *Education Sciences*, 15(12), 1597. <https://doi.org/10.3390/educsci15121597>

Alwarthan, S. A., Aslam, N., & Khan, I. U. (2022). Predicting student academic performance at higher education using data mining: A systematic review. *Applied Computational Intelligence and Soft Computing*, 2022, Article 8924028. <https://doi.org/10.1155/2022/8924028>

Cabello-Solorzano, K., et al. (2023). The impact of data normalization on the accuracy of machine learning algorithms: A comparative analysis. In *International Conference on Soft Computing Models in Industrial and Environmental Applications* (pp. 344–353). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-18050-7_33

Duan, C., et al. (2025). Predicting student performance using machine learning techniques: A systematic literature review. In *2025 7th International Conference on Computer Science and Technologies in Education (CSTE)* (pp. 362–368). IEEE. <https://doi.org/10.1109/CSTE64638.2025.11092243>

Hussain, S. M. (2025). Analytical study on student success factors in higher education. *Journal of University of Babylon for Pure and Applied Sciences*, 33(1). <https://doi.org/10.29196/jubpas.v33i1.5640>

Kassymova, A., & Khazhgali, G. (2024). Problems of implementing KPI in the educational process of universities in Kazakhstan. *Economics: Strategy and Practice*, 19(3), 87–105. <https://doi.org/10.59787/2413-5488-2024-47-3-87-105>

Narbaev, T., Amirbekova, D., & Bakdaulet, A. (2025). A decade of transformation in higher education and science in Kazakhstan: A literature and scientometric review of national projects and research trends. *Publications*, 13(3), 35. <https://doi.org/10.3390/publications13030035>

Nakhipova, V., et al. (2024). Digital transformation in higher education: Case study of Kazakhstan. *International Journal of Information and Communication Technology Education (IJICTE)*, 20(1). <https://doi.org/10.4018/IJICTE.352512>

QazInform. (2024). 14 Kazakhstani universities ranked in QS World University Rankings 2025. <https://qazinform.com/news/14-kazakhstani-universities-ranked-in-qs-world-university-rankings-2025-cdbf77>

Sumathi, R., et al. (2024). Predictive analysis for educational data using normalization techniques. *Journal of Engineering Education Transformations*. <https://doi.org/10.16920/jeet/2024/v37is2/24043>

Ministry of Education of the Republic of Kazakhstan. (2022). On approval of state compulsory education standards of all levels of education (Order No. 2). <https://adilet.zan.kz/rus/docs/V2200028916>

Government of the Republic of Kazakhstan. (2024). On approval of the Concept for the development of artificial intelligence for 2024–2029 (Resolution No. 592). <https://adilet.zan.kz/rus/docs/P2400000592>

Авторлар туралы мәліметтер
Информация об авторах
Information about authors

№	Авторлар туралы мәліметтер (Қазақ, орыс және ағылшын тілдерінде)
1	<p>Абдуваханов Б.А. – магистрант, «Компьютерлік инженерия» кафедрасы, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., Қазақстан</p> <p>Абдуваханов Б. А. - магистрант, Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, г. Туркестан, Казахстан</p> <p>Abduvakhapov B.A. - Master's student, Khoja Akhmet Yassawi International Kazakh-Turkish University, Turkistan, Kazakhstan</p> <p>E-mail: bekzotabdi@yandex.kz</p>
2	<p>Жунисов Н.М. – PhD доктор, аға оқытушы, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., Қазақстан</p> <p>Жунисов Н.М. - доктор PhD, старший преподаватель, Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, г.Туркестан, Казахстан,</p> <p>Zhuniso N.M. - PhD, Senior Lecturer, Khoja Akhmet Yassawi International Kazakh-Turkish University, Turkistan, Kazakhstan</p> <p>E-mail: nurseit.zhunissov@ayu.edu.kz, https://orcid.org/0000-0001-6531-9408, +77012348885</p>
3	<p>Баялы А.Т. - Аға оқытушы, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., Қазақстан,</p> <p>Баялы А.Т. - Старший преподаватель, Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, г. Туркестан, Казахстан,</p> <p>Bayaly A.T. - Senior Lecturer, Khoja Akhmet Yassawi International Kazakh-Turkish University, Turkistan, Kazakhstan</p> <p>E-mail: azimkhan.bayaly@ayu.edu.kz</p>
4	<p>Баймаханова А.С. – PhD доктор, аға оқытушы, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., Қазақстан</p> <p>Баймаханова А.С. – доктор PhD, старший преподаватель, Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, г. Туркестан, Казахстан</p> <p>Vaimakhanova A.S. – PhD, Senior Lecturer, Khoja Akhmet Yassawi International Kazakh-Turkish University, Turkistan, Kazakhstan</p> <p>E-mail: aygerim.baymakhanova@ayu.edu.kz, https://orcid.org/0000-0002-5364-0146</p>

Д.С. АСАН¹, А.Н. АМАНОВ²

*Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан,
Қазақстан*

¹*E-mail: darynassan@gmail.com*

²*E-mail: anuarbek.amanov@ayu.edu.kz**

ЖАТТЫҒУ ҚОЗҒАЛЫСТАРЫН КОМПЬЮТЕРЛІК КӨРУ КӨМЕГІМЕН ТАЛДАУ ЖӘНЕ ТИІМДІЛІГІН БАҒАЛАУ

Андатпа. Мақалада компьютерлік көру және позаны бағалау технологиялары негізінде фитнес жаттығуларын нақты уақыт режимінде бақылау мен бағалаудың ғылыми-әдістемелік негіздері талданады. Зерттеудің мақсаты - бір камералы ортада орындалатын фитнес жаттығуларын бағалауға арналған жүйелердің құрылымын, негізгі есептеу белгілерін және қолданбалы шешімдерін ғылыми тұрғыдан жүйелеу. Зерттеуде аналитикалық шолу, жүйелі талдау және салыстырмалы синтез әдістері қолданылды. Дереккөз базасы адамның қалпын бағалау, қозғалысты талдау, қашықтықтан жаттығуды бақылау және нақты уақыт режиміндегі кері байланыс жүйелері бойынша заманауи жұмыстардан тұрды. Талдау нәтижесінде фитнес жаттығуларын нақты уақыт режимінде бағалаудың төрт деңгейлі құрылымы анықталды: дененің тірек нүктелерін анықтау, кинематикалық ерекшеліктерді алу, қозғалыс фазасын және орындау сапасын бағалау және пайдаланушыға түсіндірілетін кері байланыс беру. Сондай-ақ, геометриялық, уақытша және сапалық ерекшеліктерді бірлесіп пайдалану мұндай жүйелердің сенімділігін арттыратыны анықталды. Жұмыстың ғылыми жаңалығы фитнес жаттығуларын бағалау процесін бөлек алгоритмдер жиынтығы ретінде емес, өзара байланысты сандық талдау циклі ретінде ұсынудан тұрады. Бұл тәсілдердің практикалық маңыздылығы олардың үйде жаттығу, онлайн фитнес платформалары, дене шынықтыруды бақылау және бастапқы оңалту үшін қолданылуында.

Түйін сөздер: компьютерлік көру, позаны бағалау, фитнес жаттығулары, нақты уақыттағы бағалау, қимылды талдау, MediaPipe, кері байланыс жүйелері.

Д.С. АСАН¹, А.Н. АМАНОВ²

*Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, Туркестан,
Казахстан*

¹*E-mail: darynassan@gmail.com*

²*E-mail: anuarbek.amanov@ayu.edu.kz**

АНАЛИЗ ТРЕНИРОВОЧНЫХ ДВИЖЕНИЙ С ИСПОЛЬЗОВАНИЕМ КОМПЬЮТЕРНОГО ЗРЕНИЯ И ОЦЕНКА ИХ ЭФФЕКТИВНОСТИ

Аннотация. В исследовании применялись методы аналитического обзора, систематического анализа и сравнительного синтеза. Источниками послужили современные работы по оценке осанки человека, анализу движений, дистанционному мониторингу физических упражнений и системам обратной связи в реальном времени. В результате анализа была выявлена четырехуровневая структура для оценки фитнес-упражнений в реальном времени: определение точек опоры тела, извлечение кинематических характеристик, оценка фазы движения и качества выполнения, а также предоставление пользователю интерпретируемой обратной связи. Также было установлено, что комбинированное использование геометрических, временных и качественных характеристик повышает

надежность таких систем. Научная новизна работы заключается в представлении процесса оценки фитнес-упражнений не как совокупности отдельных алгоритмов, а как взаимосвязанного цифрового аналитического цикла. Практическая значимость этих подходов заключается в их применимости для домашних тренировок, онлайн-фитнес-платформ, мониторинга физической подготовки и начальной реабилитации.

Ключевые слова: компьютерное зрение, оценка осанки, фитнес-упражнения, оценка в реальном времени, анализ движений, MediaPipe, системы обратной связи.

D.S. ASAN¹, A.N. AMANOV²

Khoja Akhmet Yassawi International Kazakh-Turkish University, Turkestan, Kazakhstan

¹*E-mail: darynassan@gmail.com*

²*E-mail: anuarbek.amanov@ayu.edu.kz**

ANALYSIS OF TRAINING MOVEMENTS USING COMPUTER VISION AND EVALUATION OF THEIR EFFECTIVENESS

Annotation. The study employed analytical review, systematic analysis, and comparative synthesis to examine current approaches to human posture assessment, movement analysis, remote exercise monitoring, and real-time feedback systems. The reviewed sources made it possible to identify a four-level framework for real-time fitness exercise assessment. This framework includes determining body support points, extracting kinematic characteristics, assessing movement phases and overall performance quality, and delivering interpretable feedback to the user. The analysis further demonstrated that integrating geometric, temporal, and qualitative characteristics significantly improves the reliability and robustness of such assessment systems. The scientific novelty of the study lies in presenting the fitness exercise assessment process not as a collection of isolated algorithms, but as a unified and interconnected digital analytical cycle in which each stage supports the next. The practical significance of the proposed approaches is determined by their potential application in home-based workouts, online fitness platforms, continuous fitness monitoring systems, and the initial stages of rehabilitation and recovery programs.

Keywords: computer vision, posture assessment, fitness exercises, real-time assessment, movement analysis, MediaPipe, feedback systems.

Кіріспе

Соңғы жылдары смартфон, ноутбук және веб-камера сияқты қолжетімді құрылғылардың кең таралуы адам қимылын автоматты талдауға негізделген цифрлық шешімдердің дамуын жеделдетті. Бұл үрдіс фитнес индустриясында, фитнес мониторингінде және қашықтықтан оқытуда ерекше маңызға ие болды. Дәстүрлі жаттығу процесінде қозғалыс сапасы әдетте жаттықтырушының тікелей бақылауы арқылы бағаланады, ал компьютерлік көру технологиялары бұл процесті сандық негізге ауыстыруға мүмкіндік береді (Badiola-Bengoia & Mendez-Zorrilla, 2021; Gao et al., 2025; Stenum et al., 2021). Адам денесінің негізгі тірек нүктелерін автоматты түрде анықтайтын қалып бағалау алгоритмдері буын бұрыштарын, қозғалыс амплитудасын, траектория тұрақтылығын, симметриясын және орындау ырғағын есептеуге мүмкіндік береді (Cao et al., 2017; Tharatipyakul et al., 2024). Әдебиеттерде камераға негізделген қалып бағалау әдістері спорт, денсаулық және дене белсенділігі салаларында кеңінен қолданылатыны көрсетілген (Badiola-Bengoia & Mendez-Zorrilla, 2021; Gao et al., 2025; Stenum et al., 2021; Tharatipyakul et al., 2024). Сонымен қатар, жеке зерттеулер қозғалысты бақылау, жаттығу сапасын бағалау, қателерді анықтау немесе лезде кері байланыс мәселелерін бөлек қарастыруға бейім (Ekambaram & Ponnusamy, 2024; Neo et al., 2026; Kotte et al., 2024; Woo & Jeong, 2025). Дегенмен, бір камералы ортада жұмыс істейтін және қалып анықтауды, кинематикалық ерекшеліктерді алуды, қозғалыс фазасын бағалауды және пайдаланушыға ыңғайлы кері байланысты біріктіретін кешенді аналитикалық модель жеткілікті түрде

жүйеленбеген. Осыған байланысты нақты уақыт режиміндегі фитнес жаттығуларын бағалау жүйелерінің ғылыми логикасын, құрылымдық компоненттерін және қолдану шектеулерін кешенді талдау өте өзекті.

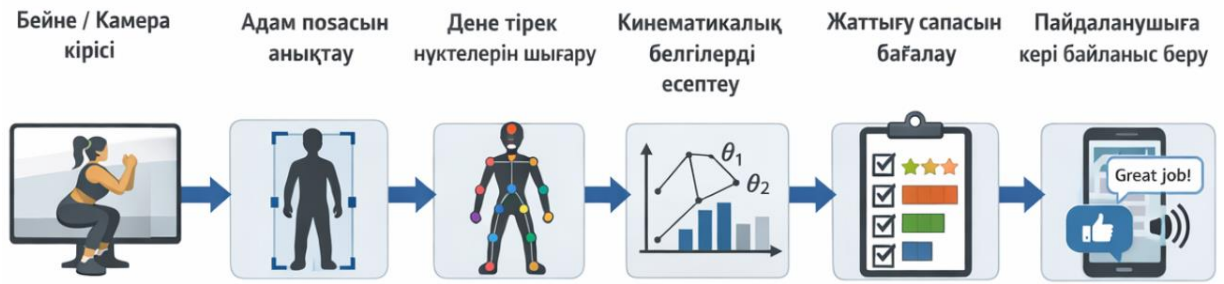
Зерттеудің мақсаты - компьютерлік көру негізінде фитнес жаттығуларын нақты уақыт режимінде бағалау жүйелерінің мазмұнын, құрылымын және қолданылу логикасын ғылыми тұрғыдан жүйелеу. Зерттеу нысаны ретінде веб-камера немесе смартфон камерасы арқылы орындалатын жаттығу қозғалыстары алынды. Зерттеу пәні - осы қозғалыстардан алынатын дене тірек нүктелері, буын бұрыштары, уақыттық қатарлар, қайталау санын есептеу және кері байланыс генерациясы. Жұмыстың міндеттері: нақты уақыттағы бағалау жүйесінің архитектурасын анықтау, негізгі есептеу белгілерін сипаттау, қолданбалы шешімдерді салыстыру және олардың практикалық шектеулерін көрсету.

Жұмыстың ғылыми жаңалығы фитнес жаттығуларын бағалау процесі тек «дұрыс/бұрыс» жіктеу шеңберінде ғана емес, сонымен қатар дененің тірек нүктелерін анықтаудан бастап түсіндірілетін кері байланысты жеткізуге дейінгі толық сандық цикл ретінде қарастырылатындығында. Тәжірибелік маңыздылығы мұндай жүйелерді үйде жаттығуларда, онлайн фитнес платформаларында, дене шынықтыруды бақылауда және бастапқы оңалту кезеңінде қолдану мүмкіндігімен анықталады.

Зерттеу әдістері мен материалдар

Зерттеу аналитикалық шолу, жүйелік талдау, салыстырмалы талдау және тұжырымдамалық модельдеу әдістеріне негізделген. Дереккөз базасы адамның қалпын бағалауға, дене қозғалыстарын компьютерлік көру талдауына, нақты уақыт режиміндегі жаттығуларды бақылауға және кері байланыс жүйелеріне арналған 11 ғылыми жұмыстан тұрды (Badiola-Bengoa & Mendez-Zorrilla, 2021; Cao et al., 2017; Ekambaram & Ponnusamy, 2024; Gao et al., 2025; Heo et al., 2026; Kotte et al., 2024; Naseer et al., 2025; Samanta et al., 2024; Stenum et al., 2021; Tharatipyakul et al., 2024; Woo & Jeong, 2025). Бұл жұмыстарға жүйелі шолулар, қолданба архитектуралары, нақты уақыт режиміндегі жаттығуларды бағалау модельдері, оңалту жаттығуларын бақылау жүйелері және құрылғы режимінде жұмыс істейтін шешімдер кірді.

Зерттеу бірнеше кезеңде жүргізілді. Бірінші кезеңде фитнес жаттығуларын бағалауға қатысты негізгі ғылыми бағыттар анықталды: қалпын бағалау, қозғалыс сапасын талдау, қайталауды санау, қозғалыс фазасын тану және нақты уақыт режиміндегі кері байланыс. Екінші кезеңде шолу жұмыстарынан ортақ функционалдық компоненттер алынды. Үшінші кезеңде бұл компоненттер геометриялық, уақытша және сапалық ерекшеліктері бойынша топтастырылды. Төртінші кезеңде нақты уақыт режиміндегі фитнесі бағалау жүйесінің жалпыланған тұжырымдамалық құрылымы ұсынылды және қолданылатын шешімдер салыстырылды. Ұсынылған талдау логикасы бейне ағынын алудан бастап пайдаланушыға кері байланыс беруге дейінгі өзара байланысты кезеңдерден тұрады (1-сурет). Бұл жүйе пациенттерді реабилитациялау кезінде олардың жаттығуларын дұрыс орындауына көмектесіп, қалпына келу уақытын қысқартуға және жарақат алу қаупін азайтуға мүмкіндік береді. Сондықтан, BlazePose негізіндегі жүйелер реабилитация бағдарламаларын тиімді жүзеге асыруда маңызды рөл атқара алады, өйткені олар пациенттерге нақты уақыт режимінде қолдау көрсетеді (Yang, H et al., 2022). Реабилитация процесінде BlazePose технологиясы пациенттердің жаттығуларын тиімді орындауына көмектеседі, бұл олардың қалпына келу уақытын қысқартуға және жарақат алу қаупін азайтуға ықпал етеді. Осылайша, BlazePose технологиясын қолдану арқылы пациенттерге реабилитация кезінде қозғалыс техникасын жақсартуға және жаттығуларды тиімді орындауға мүмкіндік беріледі.



Сурет 1. Фитнес жаттығуларын нақты уақыт режимінде бағалау жүйесінің құрылымдық сызбасы

Материалдық негіз ретінде стандартты RGB-бейне, бір камералы түсіру ортасы, MediaPipe/BlazePose сияқты позаны бағалау алгоритмдері, дене тірек нүктелерінің координаталары және сол координаталардан есептелетін кинематикалық белгілер қарастырылды (Ekambaram & Ponnusamy, 2024; Neo et al., 2026; Woo & Jeong, 2025). Мұндай тәсілдерді таңдау олардың кең қолжетімділігімен, қосымша күрделі сенсорлық жабдықтарға қажеттіліктің болмауымен және нақты уақыт режимінде іске асыруға жарамдылығымен түсіндіріледі. Әдістемелік тұрғыдан алғанда, нақты уақыт режиміндегі фитнес жаттығуларын бағалау жүйесі келесі есептеу тізбегіне негізделген: кадрды алу, адам қаңқасын анықтау, кинематикалық ерекшелікті есептеу, жаттығу күйін тану және пайдаланушыға түзету сигналдары мен прогресс туралы ақпарат беру (Ekambaram & Ponnusamy, 2024; Kotte et al., 2024). Осы логика фитнес жаттығуын бағалауды оқшау алгоритмдер жиынтығы ретінде емес, өзара байланысқан цифрлық талдау циклі ретінде түсіндіруге мүмкіндік береді.

Осыған сәйкес, нақты уақыт режиміндегі бағалау жүйелерін зерттеуде басты назар тек алгоритмнің дәлдігіне ғана емес, оның практикалық тұрақтылығына, пайдаланушыға бейімделгіштігіне және әртүрлі ортада жұмыс істеу қабілетіне де аударылуы қажет. Атап айтқанда, жарықтандыру жағдайының өзгеруі, камера бұрышы, фондық кедергілер, дене бөліктерінің жартылай жабылуы және пайдаланушының антропометриялық айырмашылықтары позаны бағалау сапасына тікелей әсер етеді. Сондықтан мұндай жүйелерді бағалау барысында тек қана зертханалық жағдайда алынған нәтижелермен шектелмей, оларды үй жағдайында, спорт залында және оңалту ортасында қолдану сценарийлері бойынша да қарастыру маңызды. Бұл тәсіл жүйенің шынайы ортадағы сенімділігін арттырып, оның қолданбалы құндылығын нақтылауға мүмкіндік береді.

Сонымен бірге, нақты уақыт режиміндегі фитнес жаттығуларын бағалау жүйелерін жобалау кезінде түсіндірілетін кері байланыс тетігі ерекше маңызға ие. Пайдаланушыға тек «дұрыс» немесе «қате» деген нәтиже беру жеткіліксіз, керісінше, қандай буынның қозғалысы ауытқығанын, қай фазада қате кеткенін және оны түзетудің қандай жолы бар екенін көрсету қажет. Осындай түсіндірілетін тәсіл пайдаланушының жаттығуды саналы түрде орындауына, қателерді тез түзетуіне және қозғалыс дағдысын жүйелі түрде жетілдіруіне жағдай жасайды. Нәтижесінде, компьютерлік көру негізіндегі жүйелер фитнес саласында ғана емес, денсаулықты сақтау, қимыл белсенділігін арттыру және алдын алу сипатындағы цифрлық шешімдерде де кеңінен қолданылатын әмбебап технологиялық негіз ретінде қарастырылуы мүмкін.

Талдау мен нәтижелер

Талдау нақты уақыт режиміндегі фитнес жаттығуларын бағалаудың төрт өзара байланысты қабатын анықтады. Бірінші қабат - дененің тірек нүктелерін анықтау. Бұл кезеңде камера кадрындағы адам денесінің құрылымы сандық координаттар ретінде көрсетіледі. Екінші қабат - кинематикалық ерекшеліктерді алу. Мұнда буын бұрыштары, қозғалыс амплитудасы, жылдамдық, траектория және симметрия сияқты көрсеткіштер есептеледі. Үшінші қабат - шешім қабылдау логикасы. Бұл деңгейде қозғалыс фазасы, қайталау саны және

жаттығу сапасы анықталады. Төртінші қабат - кері байланысты қамтамасыз ету. Бұл кезеңде пайдаланушы түсінікті түзету ақпаратын визуалды, мәтіндік, аудио немесе сандық форматта алады (Ekambaram & Ponnusamy, 2024; Heo et al., 2026; Kotte et al., 2024; Woo & Jeong, 2025).

Талдау көрсеткендей, бір ғана ерекшелік түрі жаттығу сапасын сенімді бағалау үшін жеткіліксіз. Сондықтан зерттеулерде үш негізгі ерекшелік тобы кеңінен қолданылады. Бірінші топ геометриялық ерекшеліктерден тұрады: тізе, жамбас, шынтақ, иық және басқа буындардың бұрыштары. Екінші топқа уақытша ерекшеліктер кіреді: қозғалыс фазалары, қайталау ырғағы, амплитуданың өзгеруі және уақыт бойынша тұрақтылық. Үшінші топқа сапалық сипаттамалар кіреді: симметрия, траекторияның тұрақтылығы және тірек қозғалысынан ауытқу (Ekambaram & Ponnusamy, 2024; Heo et al., 2026; Woo & Jeong, 2025). Осы үш топты бірлесе пайдалану жаттығу сапасын бағалау сенімділігін арттырады және қарапайым бұрыштық шектерге сүйенетін тәсілдерге қарағанда анағұрлым толық сипаттама береді (Кесте 1).

Кесте 1. Фитнес жаттығуларын нақты уақыт режимінде бағалауға арналған жүйелердің салыстырмалы сипаттамасы

Жүйе/дереккөз	Енгізу көзі	Негізгі модель	Нақты уақыттағы көрсеткіші	Негізгі нәтижесі/мақсаты
FitSight (Kotte et al., 2024)	Веб-камера/мобильді камера	Pose tracking + feedback engine	Интерактивті кері байланыс	Жеке жаттығу траекториясын бақылау
PoAna.v1 (Ekambaram & Ponnusamy, 2024)	RGB бейне, 12 keypoints	MediaPipe + LSTM	10-fold avg 98.54%, test 99.7%	Қалыпты бақылау және мониторинг
Exercise Assessment (Woo & Jeong, 2025)	HPE joint coordinates	Relative phase + 1D DL model	95%-дан жоғары дәлдік	Динамикалық squat posture сапасын бағалау
On-device program (Heo et al., 2026)	Smartphone RGB video	BlazePose GHUM 3D + smoothing	97.2% accuracy, 28.6 ms	Автономды бағалау және жаттығу бойынша ұсыныс беру

Қолданбалы жүйелерді салыстыру нақты уақыттағы бағалау бағытында әртүрлі әдіснамалық шешімдердің қалыптасқанын көрсетеді. FitSight жүйесі пайдаланушының жеке жаттығу траекториясын бақылауға және интерактивті кері байланыс ұсынуға бағытталған (Kotte et al., 2024). Бұл тәсілде қозғалысты бақылау мен кері байланыс бір платформада біріктіріліп, дербестендірілген цифрлық сүйемелдеу мүмкіндігі күшейтіледі. PoAna.v1 платформасындағы MediaPipe және LSTM модельдерінің үйлесімі қозғалысты уақытша тізбек ретінде талдауға мүмкіндік береді, осылайша бақылаудың дәлдігін арттырады (Ekambaram & Ponnusamy, 2024). Бұл жүйенің жоғары дәлдігі нақты уақыт режиміндегі бағалау тапсырмаларында қаңқа нүктелерін уақытша модельдеумен біріктірудің тиімділігін көрсетеді.

Осы екі тәсілді салыстыра қарағанда, нақты уақыттағы фитнес бағалау жүйелерінің дамуы тек қимылды тіркеумен шектелмей, оны интерпретациялау деңгейіне өткенін байқауға болады. Бірінші бағытта жүйе пайдаланушы әрекетін үздіксіз бақылап, практикалық кері байланыс ұсынуға басымдық берсе, екінші бағытта уақытша тәуелділіктерді модельдеу арқылы қозғалыстың құрылымын тереңірек тану көзделеді. Мұндай айырмашылықтар нақты

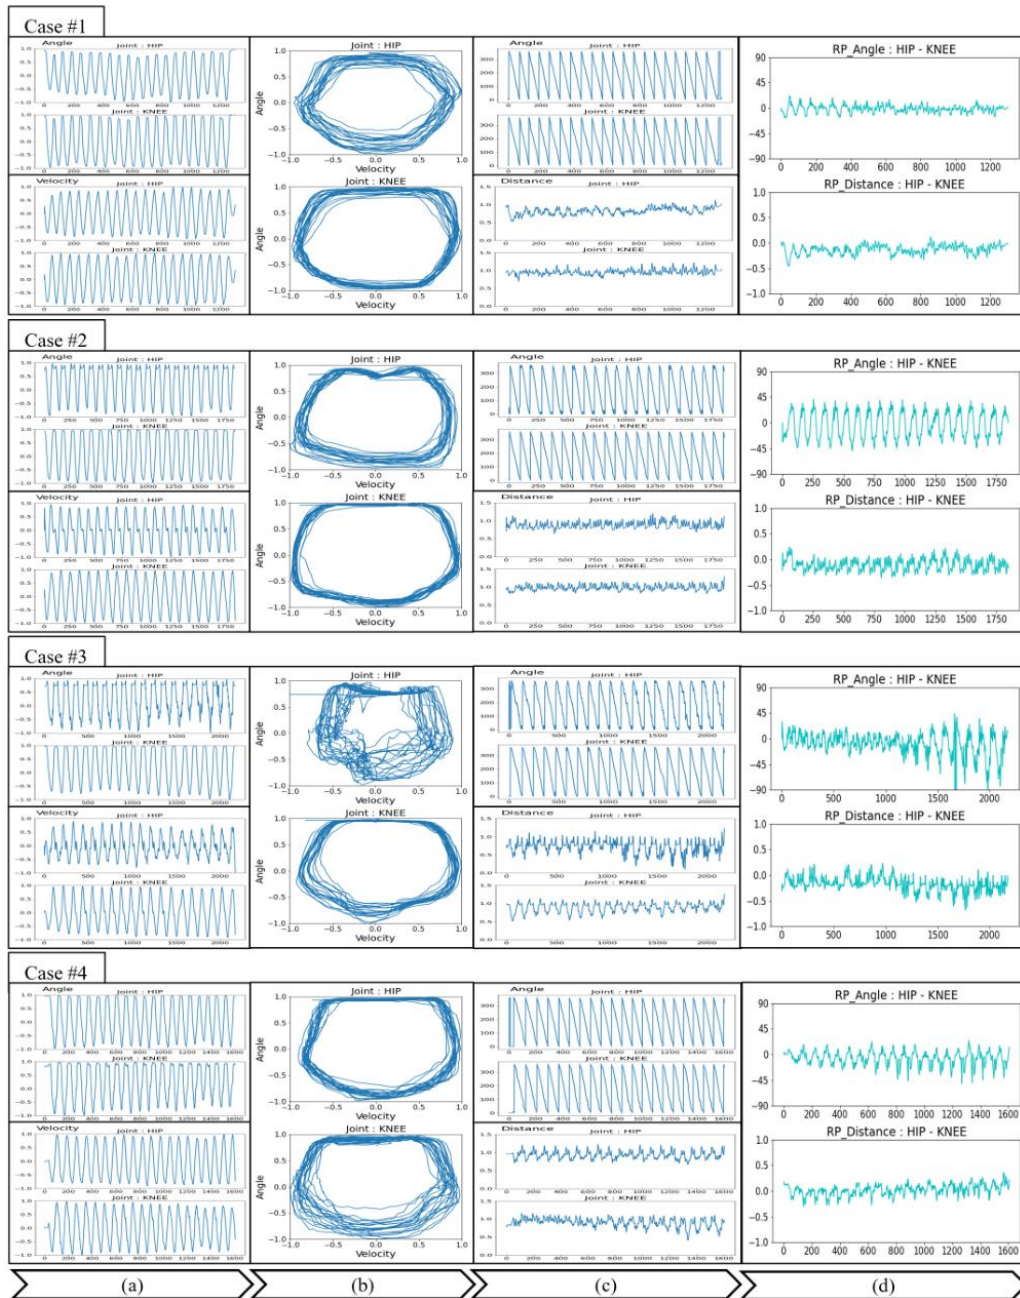
уақыттағы бағалау платформаларының әрқайсысы белгілі бір қолдану сценарийіне бейімделетінін көрсетеді. Соның нәтижесінде, қазіргі зерттеулерде дәлдік, жылдамдық, түсіндірілетіндік және бейімделгіштік сипаттарын бір жүйеде үйлестіру негізгі әдіснамалық міндеттердің біріне айналып отыр. Бұл жүйелердің тиімділігі, әсіресе, пациенттердің реабилитация процесінде қозғалыс техникасын жақсартуда және жаттығуларды тиімді орындауда көрінеді, бұл олардың қалпына келу уақытын қысқартуға ықпал етеді. Осылайша, BlazePose технологиясын қолдану арқылы әзірленген жүйелер пациенттердің реабилитация процесінде қозғалыс техникасын жақсартуға және жаттығуларды тиімді орындауға мүмкіндік береді, бұл қалпына келу уақытын қысқартуға ықпал етеді (Hoang, 2024).

Жаттығуды бағалау жүйесінде қозғалыс сапасы салыстырмалы фазалық әдісті бір өлшемді терең оқыту моделімен біріктіру арқылы бағаланады (Woo & Jeong, 2025). Бұл тәсілде қозғалыс тек жеке бұрыш мәндерімен ғана емес, сонымен қатар буын бұрышы мен бұрыштық жылдамдықтың біріктірілген фазалық сипаттамаларымен де бағаланады. Бұл әдіс динамикалық жаттығуларда қозғалыс координациясын дәлірек анықтауға мүмкіндік береді. Фазалық талдау үшін келесі өрнек қолданылады (Woo & Jeong, 2025):

$$\varphi_x = \arctan(x(t) / \dot{x}(t)) = \omega t + \theta_x \quad (1)$$

мұндағы φ_x - қозғалыстың фазалық бұрышы, $x(t)$ - уақыт бойынша буын бұрышы немесе ығысу мәні, $\dot{x}(t)$ - бұл шаманың уақыт бойынша туындысы (яғни бұрыштық жылдамдық), ω - бұрыштық жиілік, t - уақыт және θ_x - бастапқы фаза. 1-формулада фазалық портрет негізінде қозғалыс координациясын бағалауға мүмкіндік береді және қарапайым шекті әдістермен салыстырғанда динамикалық жаттығулардың мағыналы сипаттамасын береді. Сурет 2. Relative phase тәсілі арқылы динамикалық жаттығуды бағалаудың көрнекі мысалы. Дереккөз: Woo and Jeong (2025) негізінде.

Қозғалысты тек бұрыш арқылы ғана емес, бұрыш пен бұрыштық жылдамдықтың біріккен фазалық сипаттамасы негізінде бағалау тәсілі қозғалыс сапасын неғұрлым дәл анықтауға мүмкіндік береді. Relative phase әдісі сарапшы мен жаңадан үйренушінің қозғалыс үйлесімін анығырақ ажыратады, сондықтан динамикалық жаттығуларды талдауда ол қарапайым threshold-based тәсілдерге қарағанда мазмұндырақ сипаттама береді (Сурет 1).



Сурет 2. Төрт түрлі жағдай үшін нормаланған бұрыш, фазалық портрет және relative phase нәтижелері.

2-суретте төрт түрлі жағдай үшін жамбас және тізе буындарының кинематикалық және фазалық сипаттамалары салыстырылған. (a) бөлігінде екі буынның нормаланған бұрыштық орын ауыстыруы мен бұрыштық жылдамдығының периодтық өзгерісі берілген, бұл қозғалыстың циклдік құрылымын сипаттайды. (b) бөлігіндегі фазалық портреттер қозғалыс траекториясының тұрақтылығы мен қайталанғыштығын көрсетеді: тұйық әрі біркелкі траекториялар жүйенің орнықтырақ жұмысын білдіреді. (c) бөлігінде фазалық бұрыш пен фазалық қашықтық динамикасы ұсынылып, әр буынның фазалық күйі мен оның цикл ішіндегі өзгеру ерекшеліктері бейнеленген. (d) бөлігіндегі ERP қисықтары жамбас пен тізе буындарының өзара үйлесімділік дәрежесін сипаттайды; тербелістің артуы немесе тұрақсыздануы буынаралық координацияның өзгергенін көрсетеді. Жалпы алғанда, сурет әр жағдайдағы қозғалыс тұрақтылығы, фазалық синхрондылық және буындар арасындағы координация деңгейіндегі айырмашылықтарды айқын көрсетеді.

BlazePose GHUM 3D және smoothing әдістеріне негізделген on-device бағдарлама смартфон бейнесі арқылы автономды бағалау мен жаттығу бойынша ұсыныс беруді жүзеге

асырады (Neo et al., 2026). Мұндай тәсілдің маңызды артықшылығы - кідірістің төмен болуы, деректердің локалды өңделуі және құпиялықтың сақталуы. Бұл әсіресе үйде оқыту сценарийлері үшін маңызды, мұнда тұрақты интернет байланысына минималды тәуелділікпен қолжетімді және жылдам шешімдер қажет.

Жалпы алғанда, талдау нақты уақыт режиміндегі фитнес бағалау жүйесінің тиімділігі үш негізгі факторға байланысты екенін көрсетті: қалып бағалаудың дәлдігі, кинематикалық ерекшеліктердің сапасы және пайдаланушыға берілген кері байланыстың түсіндірілу деңгейі. Егер жүйе тек буын бұрыштары үшін қарапайым табалдырықтарға сүйенсе, күрделі және динамикалық қозғалыстарды бағалаудың дәлдігі төмендеуі мүмкін. Екінші жағынан, қозғалыс фазасын, уақытша ерекшеліктерді және сапалық көрсеткіштерді қамтитын тәсілдер жаттығу сапасының толық және дәл сипаттамасын береді (Ekambaram & Ponnusamy, 2024; Neo et al., 2026; Woo & Jeong, 2025).

Сонымен қатар, құрылғыдағы модельдер нақты уақыт режимінде жұмыс істеуге өте қолайлы болғанымен, күрделі қозғалыстарды бағалау кезінде шешім қабылдау логикасы тек статикалық қалыптарға ғана емес, сонымен қатар қозғалыстың уақытша құрылымына да негізделуі керек. Осыған сәйкес, мақсаттық қажеттілік, уақыттық динамиканы және ішкі түсінікті байланыс орнату жүйелері практикалық қолдану үшін перспективалы болып көрінеді. Практикалық тұрғыдан бұл бағыттағы шешімдер үй жағдайындағы жаттығуда, онлайн фитнес платформаларында, жоғары оқу орындарындағы дене дайындығын бақылауда, сондай-ақ бастапқы реабилитациялық жаттығуларды қадағалауда кеңінен қолданылуы мүмкін. Мұндай жүйелер қозғалыс техникасын жетілдіруге, қателерді жедел анықтауға және жаттығу үдерісін дербестендіруге мүмкіндік береді. Осылайша, BlazePose негізіндегі жүйелер үйде жаттығу жасау кезінде пайдаланушылардың тиімділігін арттыруға көмектеседі, сонымен қатар денсаулық сақтау саласында реабилитация бағдарламаларын қолдауға ықпал етеді (Sideridou et al., 2024).. Бұл жүйелердің әлеуеті тек фитнес саласында ғана емес, сонымен қатар пациенттерді реабилитациялау процесінде де айқын көрінеді, өйткені олар нақты уақыт режимінде стандартты қозғалыс нұсқауларын ұсына алады (Wang & Zhang, 2023). Осылайша, BlazePose технологиясын қолдану арқылы әзірленген жүйелер реабилитация бағдарламаларын тиімді жүзеге асыруда маңызды рөл атқара алады, өйткені олар пайдаланушыларға нақты уақыт режимінде қолдау көрсетеді (Yang, H et al., 2022). Бұл жүйелер пациенттерге реабилитация кезінде дұрыс жаттығуларды орындауға көмектесіп, олардың қалпына келу уақытын қысқартуға және жарақат алу қаупін азайтуға ықпал етеді. Осылайша, BlazePose негізіндегі жүйелер пациенттер үшін реабилитация процесін оңтайландыруға мүмкіндік беріп, жаттығулардың тиімділігін арттырады, бұл өз кезегінде қалпына келу уақытын қысқартуға ықпал етеді (Rehabilitation Training Evaluation and Correction System Based on BlazePose, 2022).

Қорытынды

Компьютерлік көру және позаны бағалау технологиялары фитнес жаттығуларын нақты уақыт режимінде бағалаудың ғылыми және қолданбалы негізін қалыптастырады. Талдау мұндай жүйелердің жұмысы өзара байланысты кезеңдерден тұратынын көрсетті: дененің тірек нүктелерін анықтау, кинематикалық ерекшеліктерді алу, қозғалысты орындау фазасы мен сапасын бағалау және пайдаланушыға түсіндірілетін кері байланыс беру.

Жұмыстың негізгі қорытындысы - нақты уақыт режиміндегі фитнес бағалау жүйесінің тиімділігі қалып бағалауының дәлдігіне, есептелген ерекшеліктердің ақпараттықтығына және кері байланыстың анықтығына байланысты. Атап айтқанда, құрылғы режимінде жұмыс істейтін модельдер кідіріс уақытын азайтады, қолжетімділікті арттырады және құпиялықты жақсартады. Сонымен қатар, қозғалысты тек бұрыштық индикаторлар бойынша ғана емес, сонымен қатар уақытша және фазалық сипаттамалар бойынша бағалау динамикалық жаттығуларды дәлірек талдауға мүмкіндік береді.

Осыған байланысты, мұндай жүйелер тек қана жаттығу техникасын бақылау құралы емес, сонымен бірге пайдаланушының қозғалыс мәдениетін қалыптастыратын интеллектуалды көмекші ретінде қарастырылуы тиіс. Практикалық тұрғыдан бұл тәсілдер үй

жағдайындағы жаттығуларда, онлайн фитнес платформаларында, дене белсенділігін бақылауда және бастапқы оңалту бағдарламаларында тиімді қолданыс таба алады. Әсіресе, жаттығуды өз бетінше орындайтын пайдаланушылар үшін қимыл сапасын автоматты түрде бағалау жарақат алу қаупін азайтып, жаттығу нәтижелілігін арттыруға ықпал етеді. Болашақ зерттеулер көпкамералы бақылау мүмкіндіктерін кеңейтуге, түсіндірілетін жасанды интеллект модельдерін енгізуге, жаттығуға тән қателік карталарын әзірлеуге және пайдаланушының жасы, физикалық дайындығы мен функционалдық жағдайына бейімделген жекелендірілген кері байланыс жүйелерін құруға бағытталуы қажет. Осындай бағыттағы ізденістер фитнес технологияларын жаңа сапалық деңгейге көтереді.

Практикалық тұрғыдан алғанда, бұл тәсілдер үйде жаттығу, онлайн фитнес платформалары, дене шынықтыруды бақылау және бастапқы оңалту үшін тиімді. Болашақ зерттеулер көп камералы мүмкіндіктерді, түсіндірілетін жасанды интеллект модельдерін, жаттығуға тән қателік карталарын және пайдаланушының жасы мен физикалық жағдайына бейімделген жекелендірілген кері байланыс модельдерін әзірлеуге бағытталуы керек.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

Badiola-Bengoia, A., & Mendez-Zorrilla, A. (2021). A systematic review of the application of camera-based human pose estimation in the field of sport and physical exercise. *Sensors*, 21(18), 5996. <https://doi.org/10.3390/s21185996>

Cao, Z., Simon, T., Wei, S.-E., & Sheikh, Y. (2017). Realtime multi-person 2D pose estimation using part affinity fields. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 7291–7299. <https://doi.org/10.1109/CVPR.2017.143>

Ekambaram, D., & Ponnusamy, V. (2024). Real-time monitoring and assessment of rehabilitation exercises for low back pain through interactive dashboard pose analysis using Streamlit: A pilot study. *Electronics*, 13(18), 3782. <https://doi.org/10.3390/electronics13183782>

Gao, Z., Chen, J., Liu, Y., Jin, Y., & Tian, D. (2025). A systematic survey on human pose estimation: Upstream and downstream tasks, approaches, lightweight models, and prospects. *Artificial Intelligence Review*, 58, 68. <https://doi.org/10.1007/s10462-024-11060-2>

Heo, S., Choi, T., & Choi, W. (2026). Clinical validation of an on-device AI-driven real-time human pose estimation and exercise prescription program: Prospective single-arm quasi-experimental study. *Healthcare*, 14(4), 482. <https://doi.org/10.3390/healthcare14040482>

Hoang, M. L. (2024). Human pose estimation for rehabilitation by computer vision (pp. 110–128). <https://doi.org/10.2174/9789815313055124010008>

Kotte, H., Daiber, F., Kravčik, M., & Duong-Trung, N. (2024). FitSight: Tracking and feedback engine for personalized fitness training. *Proceedings of the 32nd ACM Conference on User Modeling, Adaptation and Personalization*, 223–231. <https://doi.org/10.1145/3627043.3659547>

Naseer, A., Raza, A., Afzal, H., Smerat, A., Fitriyani, N. L., Gu, Y., & Syafrudin, M. (2025). Human pose estimation in physiotherapy fitness exercise correction using novel transfer learning approach. *PeerJ Computer Science*, 11, e2854. <https://doi.org/10.7717/peerj-cs.2854>

Rehabilitation Training Evaluation and Correction System Based on BlazePose. (2022). <https://doi.org/10.1109/ECICE55674.2022.10042886>

Samanta, A., Kotte, H., Handwerk, P., Mat Sanusi, K. A., Geisen, M., Kravčik, M., & Duong-Trung, N. (2024). IMPECT-POSE: A complete front-end and back-end architecture for pose tracking and feedback. *Adjunct Proceedings of the 32nd ACM Conference on User Modeling, Adaptation and Personalization*, 142–147. <https://doi.org/10.1145/3631700.3664865>

Sideridou, M., Kouidi, E., Hatzitaki, V., & Chouvarda, I. (2024). Towards automating personal exercise assessment and guidance with affordable mobile technology. <https://doi.org/10.3390/s24072037>

Stenum, J., Cherry-Allen, K. M., Pyles, C. O., Reetzke, R. D., Vignos, M. F., & Roemmich, R. T. (2021). Applications of pose estimation in human health and performance across the lifespan. *Sensors*, 21(21), 7315. <https://doi.org/10.3390/s21217315>

Tharatipyakul, A., Srikaewsiew, T., & Pongnumkul, S. (2024). Deep learning-based human body pose estimation in providing feedback for physical movement: A review. *Heliyon*, 10, e36589. <https://doi.org/10.1016/j.heliyon.2024.e36589>

Wang, J., & Zhang, Y. (2023). Design of real-time movement guidance system based on BlazePose on mobile terminal. *Academic Journal of Science and Technology*, 4(3), 162–164. <https://doi.org/10.54097/ajst.v4i3.5050>

Woo, Y., & Jeong, H. (2025). Exercise assessment based on human pose estimation and relative phase for real-time remote exercise system. *IEEE Access*, 13, 53203–53213. <https://doi.org/10.1109/ACCESS.2025.3551834>

Yang, H., Wang, Y., & Shi, Y. (2022). Rehabilitation training evaluation and correction system based on BlazePose. 27–30. <https://doi.org/10.1109/ECICE55674.2022.10042886>

REFERENCES

Badiola-Bengoa, A., & Mendez-Zorrilla, A. (2021). A systematic review of the application of camera-based human pose estimation in the field of sport and physical exercise. *Sensors*, 21(18), 5996. <https://doi.org/10.3390/s21185996>

Cao, Z., Simon, T., Wei, S.-E., & Sheikh, Y. (2017). Realtime multi-person 2D pose estimation using part affinity fields. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 7291–7299. <https://doi.org/10.1109/CVPR.2017.143>

Ekambaram, D., & Ponnusamy, V. (2024). Real-time monitoring and assessment of rehabilitation exercises for low back pain through interactive dashboard pose analysis using Streamlit: A pilot study. *Electronics*, 13(18), 3782. <https://doi.org/10.3390/electronics13183782>

Gao, Z., Chen, J., Liu, Y., Jin, Y., & Tian, D. (2025). A systematic survey on human pose estimation: Upstream and downstream tasks, approaches, lightweight models, and prospects. *Artificial Intelligence Review*, 58, 68. <https://doi.org/10.1007/s10462-024-11060-2>

Heo, S., Choi, T., & Choi, W. (2026). Clinical validation of an on-device AI-driven real-time human pose estimation and exercise prescription program: Prospective single-arm quasi-experimental study. *Healthcare*, 14(4), 482. <https://doi.org/10.3390/healthcare14040482>

Hoang, M. L. (2024). Human pose estimation for rehabilitation by computer vision (pp. 110–128). <https://doi.org/10.2174/9789815313055124010008>

Kotte, H., Daiber, F., Kravčik, M., & Duong-Trung, N. (2024). FitSight: Tracking and feedback engine for personalized fitness training. *Proceedings of the 32nd ACM Conference on User Modeling, Adaptation and Personalization*, 223–231. <https://doi.org/10.1145/3627043.3659547>

Naseer, A., Raza, A., Afzal, H., Smerat, A., Fitriyani, N. L., Gu, Y., & Syafrudin, M. (2025). Human pose estimation in physiotherapy fitness exercise correction using novel transfer learning approach. *PeerJ Computer Science*, 11, e2854. <https://doi.org/10.7717/peerj-cs.2854>

Rehabilitation Training Evaluation and Correction System Based on BlazePose. (2022). <https://doi.org/10.1109/ECICE55674.2022.10042886>

Samanta, A., Kotte, H., Handwerk, P., Mat Sanusi, K. A., Geisen, M., Kravčik, M., & Duong-Trung, N. (2024). IMPECT-POSE: A complete front-end and back-end architecture for pose tracking and feedback. *Adjunct Proceedings of the 32nd ACM Conference on User Modeling, Adaptation and Personalization*, 142–147. <https://doi.org/10.1145/3631700.3664865>

Sideridou, M., Kouidi, E., Hatzitaki, V., & Chouvarda, I. (2024). Towards automating personal exercise assessment and guidance with affordable mobile technology. <https://doi.org/10.3390/s24072037>

Stenum, J., Cherry-Allen, K. M., Pyles, C. O., Reetzke, R. D., Vignos, M. F., & Roemmich, R. T. (2021). Applications of pose estimation in human health and performance across the lifespan. *Sensors*, 21(21), 7315. <https://doi.org/10.3390/s21217315>

Tharatipyakul, A., Srikaewsiew, T., & Pongnumkul, S. (2024). Deep learning-based human body pose estimation in providing feedback for physical movement: A review. *Heliyon*, 10, e36589. <https://doi.org/10.1016/j.heliyon.2024.e36589>

Wang, J., & Zhang, Y. (2023). Design of real-time movement guidance system based on BlazePose on mobile terminal. *Academic Journal of Science and Technology*, 4(3), 162–164. <https://doi.org/10.54097/ajst.v4i3.5050>

Woo, Y., & Jeong, H. (2025). Exercise assessment based on human pose estimation and relative phase for real-time remote exercise system. *IEEE Access*, 13, 53203–53213. <https://doi.org/10.1109/ACCESS.2025.3551834>

Yang, H., Wang, Y., & Shi, Y. (2022). Rehabilitation training evaluation and correction system based on BlazePose. 27–30. <https://doi.org/10.1109/ECICE55674.2022.10042886>

Авторлар туралы мәліметтер

Информация об авторах

Information about authors

№	Информация об авторах (Ф.И.О. полностью, ученая степень, место работы или учебы, город, страна, E-mail, сотовый номер автора корреспондента:) на казахском, русском, английском языках
1	<p>Аманов Ануарбек Нурсейтович - PhD, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., Қазақстан Аманов Ануарбек Нурсейтович - PhD, Международный казахско-турецкий университет им. Ходжи Ахмеда Ясави, г. Туркестан, Казахстан Amanov Anuarbek Nurseytovich - PhD, Ahmet Yassawi University, Turkestan, Kazakhstan E-mail: anuarbek.amanov@ayu.edu.kz, ORCID: 0000-0003-0638-6859</p>
2	<p>Асан Дарын Сырлыбекұлы - магистрант, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., Қазақстан Асан Дарын Сырлыбекұлы - магистрант, Международный казахско-турецкий университет им. Ходжи Ахмеда Ясави, г. Туркестан, Казахстан Asan Daryn Syrlybekuly - master student, Ahmet Yassawi University, Turkestan, Kazakhstan E-mail: darynassan@gmail.com ORCID: -</p>

UDC 621.561; 536.22; 620.9

IRSTI 44.31.35; 44.01.77; 44.35.29

<https://doi.org/10.47526/2025-4/2524-0080.48>

O.D.MEIRBEKOVA¹, N.T.RUSTAMOV²

Khoja Akhmet Yassawi International kazakh–turkish university, Turkistan, Kazakhstan

¹*E-mail: oxana.meirbekova@ayu.edu.kz**

²*E-mail: nassim.rustamov@ayu.edu.kz*

INVESTIGATION OF A BIOGAS HYBRID GAS TURBINE PLANT WITH A WATER BATTERY

Abstract. This paper investigates the structure, energy efficiency, and dynamic characteristics of a hybrid gas turbine system operating on biogas and integrated with a water-based thermal energy storage unit. The proposed system combines the electrical power generation capability of a gas turbine with a thermal accumulator, enabling efficient simultaneous utilization of electrical and thermal energy. A nonlinear mathematical model of the system is developed, incorporating the dynamics of the rotor, combustion chamber, and thermal storage unit. The model is linearized in the vicinity of the nominal operating point and represented in state-space form. Transient processes resulting from changes in fuel flow rate are analyzed using numerical simulation. The results demonstrate that hybridization preserves the mechanical stability of the system while introducing an additional slow thermal loop. The integration of a water thermal accumulator enables effective recovery and storage of exhaust gas heat, significantly increasing the overall efficiency of the system. The study confirms that the hybrid gas turbine installation exhibits multi-scale dynamic behavior, making the application of multi-loop or cascade control strategies appropriate. The proposed hybrid system represents a promising solution for autonomous and distributed energy systems operating on biogas.

Keywords: Gas turbine installation, biogas, hybrid energy system, thermal accumulator, mathematical model, control system.

O.D.MEIRBEKOVA¹, N.T.RUSTAMOV²

Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан, Қазақстан

¹*E-mail: oxana.meirbekova@ayu.edu.kz**

²*E-mail: nassim.rustamov@ayu.edu.kz*

СУ АККУМУЛЯТОРЫ БАР БИОГАЗБЕН ЖҰМЫС ІСТЕЙТІН ГИБРИДТІ ГАЗТУРБИНАЛЫҚ ҚОНДЫРҒЫНЫ ЗЕРТТЕУ

Аңдатпа. Бұл мақалада биогазбен жұмыс істейтін, су жылу аккумуляторымен біріктірілген гибриді газтурбиналық қондырғының құрылымы, энергетикалық тиімділігі және динамикалық қасиеттері зерттеледі. Ұсынылған жүйе газтурбиналық қозғалтқыштың электр энергиясын өндіру мүмкіндігін су негізіндегі жылу аккумуляторымен толықтырып, электр және жылу энергиясын бір мезгілде тиімді пайдалануға бағытталған. Жұмыста қондырғының роторының, жану камерасының және жылу аккумуляторының динамикасын қамтитын бейсызық математикалық модель құрастырылған. Модель номинал жұмыс режимі маңында сызықтандырылып, күй кеңістігіндегі формада ұсынылады. Отын шығынының өзгеруі кезіндегі өтпелі процестер сандық модельдеу арқылы талданады. Нәтижелер гибриді құрылымның механикалық тұрақтылықты сақтай отырып, жүйеде қосымша баяу жылулық контур қалыптастыратынын көрсетеді. Су жылу аккумуляторының болуы шығатын газдардың жылуын жинақтауға мүмкіндік беріп, қондырғының толық пайдалы әсер коэффициентін

айтарлықтай арттырады. Зерттеу нәтижелері гибриді газтурбиналық жүйенің көпмасштабты динамикаға ие екенін және оны басқару үшін көпконтурлы немесе каскадты басқару әдістерін қолданудың орындылығын дәлелдейді. Ұсынылған қондырғы биогазға негізделген автономды және таралған энергетикалық кешендер үшін перспективалы шешім болып табылады.

Түйін сөздер: Газтурбиналық қондырғы, биогаз, гибриді энергетикалық жүйе, жылу аккумуляторы, математикалық модель, басқару жүйесі.

О.Д.МЕИРБЕКОВА¹., Н.Т.РУСТАМОВ²

Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, Туркестан, Казахстан,

¹*E-mail: oxana.meirbekova@ayu.edu.kz**

²*E-mail: nassim.rustamov@ayu.edu.kz*

ИССЛЕДОВАНИЕ БИОГАЗОВОЙ ГИБРИДНОЙ ГАЗОТУРБИННОЙ УСТАНОВКИ С ВОДЯНЫМ АККУМУЛЯТОРОМ

Аннотация. В статье исследуются структура, энергетическая эффективность и динамические свойства гибридной газотурбинной установки, работающей на биогазе и интегрированной с водяным тепловым аккумулятором. Предложенная система сочетает возможности выработки электрической энергии газотурбинным двигателем с тепловым накопителем, что обеспечивает эффективное совместное использование электрической и тепловой энергии. Разработана нелинейная математическая модель установки, включающая динамику ротора, камеры сгорания и теплового аккумулятора. Модель линеаризована в окрестности номинального режима и представлена в форме пространства состояний. С помощью численного моделирования проанализированы переходные процессы при изменении расхода топлива. Полученные результаты показывают, что гибридизация установки не ухудшает механическую устойчивость системы, но формирует дополнительный медленный тепловой контур. Интеграция водяного теплового аккумулятора позволяет эффективно аккумулировать теплоту выхлопных газов и существенно повысить общий коэффициент полезного действия установки. Установлено, что гибридная газотурбинная система обладает многомасштабной динамикой, что обосновывает целесообразность применения многоконтурных или каскадных методов управления. Предложенная установка является перспективным решением для автономных и распределённых энергетических систем на базе биогаза.

Ключевые слова: газотурбинная установка, биогаз, гибридная энергетическая система, тепловой аккумулятор, математическая модель, система управления.

Introduction

The growth of distributed generation and the use of renewable energy sources have led to the need to increase the efficiency of local power plants. Biogas-powered gas turbine engines (GTE) represent a promising solution for autonomous energy centers of agro-industrial complexes and municipal infrastructure.

A classic gas turbine installation has a relatively low electrical efficiency (25-35%), while a significant part of the fuel energy is lost with exhaust gases. The utilization of this energy makes it possible to significantly increase the overall efficiency of the installation.

One of the solutions is to include a water thermal accumulator in the circuit, which leads to the formation of a hybrid distributed generation power plant (HDGPP). However, hybridization complicates the dynamics of the system and requires the development of an adequate mathematical model for the synthesis of the control system.

The purpose of the article is to investigate a hybrid gas turbine unit with a water thermal accumulator, to evaluate the effect of heat storage integration on energy efficiency and dynamic stability of the system when running on biogas.

Research materials and methods

Gas turbine installations (GTI) are the basis of thermal power systems and are widely used to generate electrical and thermal energy by converting fuel energy according to the thermodynamic Brayton cycle. A detailed analysis of the work of GTI and the prospects for improving their efficiency is carried out in the works of (Zemtsov et al., 2025), where heat recovery schemes and the introduction of the organic Rankine cycle are considered to increase the efficiency of a power plant from 35-38% to 45-50% through the use of low-potential exhaust heat.

In the field of thermodynamics and cycle analysis of gas turbine systems, classical approaches are described in the works of (Gülen, 2019), where the basic operating schemes, cycle parameters and energy indicators are described.

One of the key trends in improving the efficiency of GTI is the integration of thermal energy storage (TES) systems with gas turbines. An overview of the possibilities of using TES to increase the power and stabilize the modes of gas turbine installations is presented in the work of (Gkoutzamanis et al., 2019), which discusses various methods of cooling the air at the turbine inlet using heat storage systems and their impact on performance. In particular, the authors show that such approaches can improve operational stability and increase energy efficiency.

In addition, research on dynamic modeling of hybrid systems with thermal storage highlights the importance of accumulating and reusing thermal energy to increase the flexibility and efficiency of energy systems as a whole. In the works devoted to the general overview of TES technologies, various types of heat storage devices are distinguished – sensitive, latent and thermochemical – and their features, application potential and limitations are considered. Such an overview is useful for understanding the technological possibilities of integrating TES with GTI, especially in the context of renewable energy sources and cogeneration.

In particular, (Islam et al., 2022) analyze the role and modeling of TES systems in energy systems, including their use for balancing heat and electricity flows, which is important when considering hybrid gas turbine installations with heat accumulators.

Thus, modern scientific literature confirms that the integration of heat recovery and heat storage with gas turbine installations is a promising direction for improving energy efficiency, flexibility of dynamics and stability of dynamic processes in distributed energy systems.

Analysis and results

In the work of (Meirbekova & Rustamov, 2022) the following biogas gas turbine engine with a water battery was proposed (Fig.1).




Figure 1. Biogas gas turbine engine with a water battery

This installation includes: air compressor; combustion chamber; gas turbine; generator; heat accumulator, etc.

Atmospheric air enters the compressor, where its pressure increases. Biogas is supplied to the combustion chamber and a high-temperature flow is formed. Next, the flow expands in the turbine, producing mechanical work. The turbine turns an electric generator.

The exhaust gases are sent to a heat exchanger, where they transfer heat to the water accumulated in the heat tank. Thus, a combined electric heating system is formed.

The presented hybrid installation combines a biogas-powered gas turbine engine with a water thermal accumulator (Rustamov et al., 2023). Atmospheric air enters the compressor, where its pressure increases, after which biogas is added to the combustion chamber and ignited, forming a high-temperature flow. By expanding in the turbine, the gas creates mechanical power to turn the generator that generates electricity. The exhaust gases are sent to a heat exchanger, where they transfer part of the energy to the water in the battery, which allows the use of thermal energy for heating or other needs.

This combination of an electrical and thermal circuit increases the total efficiency of the installation, provides the possibility of energy storage and creates a multi-channel dynamic system with a fast mechanical circuit and a slow thermal circuit (Rustamov et al., 2025). The hybrid structure allows efficient use of biogas, increasing the overall energy efficiency of the plant and creating the basis for autonomous distributed energy complexes. The mathematical model of this installation is as follows.

Heat exchanger model (heat recovery): Heat flow from exhaust gases:

$$Q_{rec} = \dot{m}_g c_p (T_A - T_{stack}) \quad (1)$$

where: T_{stack} - exhaust gas temperature

You can use the NTU model:

$$Q_{rec} = \varepsilon C_{min} (T_A - T_{\omega, in}) \quad (2)$$

Model of a water thermal accumulator (dynamic):

Energy balance:

$$M_{\omega} c_{\omega} \frac{dT_{\omega}}{dt} = Q_{rec} - Q_{load} \quad (3)$$

where: M_{ω} – mass of water, c_{ω} – heat capacity of water, Q_{load} – thermal load.

This equation gives the system thermal inertia.

Dynamic model of the rotor (Razzhivin et al., 2023):

The equation of rotation:

$$J \frac{d\omega}{dt} = T_t - T_c - T_{load} \quad (4)$$

where: J - moment of inertia of the rotor, ω - angular velocity, $T_t = \frac{P_t}{\omega}$ $T_c = \frac{P_c}{\omega}$

Electrical efficiency of the installation:

$$\eta_{el} = \frac{P_{el}}{\dot{m}_f Q_{LHV}} \quad (5)$$

η_{el} - The electrical efficiency of the installation shows how much of the fuel energy is converted into electrical energy (Cabeza, 2015);

P_{el} - The electrical output of the generator is measured in watts (W) or kilowatts (kW);

\dot{m}_f - The mass consumption of fuel (for example, biogas) is measured in kilograms per second (kg/s);

Q_{LHV} - The lowest heat of combustion of a fuel, the amount of energy released during the complete combustion of a unit of fuel mass, is measured in joules per kilogram (J/kg) or kJ/kg.

Full (hybrid) Installation efficiency:

$$\eta_{total} = \frac{P_{el} + Q_{rec}}{\dot{m}_f Q_{LHV}} \quad (6)$$

η_{total} - the total efficiency of a hybrid installation, which takes into account both electrical energy and thermal energy stored or used.

Q_{rec} - The amount of heat energy recovered (returned) from exhaust gases and stored in a heat storage tank is measured in watts (W) or in joules per second (J/s) (Kuravi, et al., 2013).

Calculation and simulation results

1. Initial data (example of a 100 kW installation)

A hybrid gas turbine engine with an electric capacity of 100 kW is considered.

Parameters:

Rated power: $P_{el} = 100 \text{ kW}$

Generator efficiency: $\eta_{gen} = 0,95$

Degree of pressure increase: $\pi_c = 4$

Compressor efficiency: $\eta_c = 0,82$

Turbine efficiency: $\eta_t = 0,85$

Lowest calorific value of biogas: $Q_{LHV} = 20 \text{ MJ/kg}$

The mass of water in the battery: $M_w = 3000 \text{ kg}$

Ambient temperature: $T_1 = 300 \text{ K}$

2. Calculation of the nominal mode

a) The temperature after the compressor:

$$T_2 = 300 \left[1 + \frac{1}{0,82} (4^{0,286} - 1) \right] \quad (7)$$

$$T_2 = 300(1 + 0,58) \approx 474 \text{ K}$$

b) The temperature in front of the turbine:

Let's accept

$$T_3 = 1050 \text{ K}$$

c) The temperature after the turbine:

$$T_4 = 750 \text{ K}$$

d) Required fuel consumption:

Electric power:

$$P_{shaft} = \frac{100}{0,95} \approx 105 \text{ kW}$$

Thermal power of fuel:

$$\dot{m}_f = \frac{P_{shaft}}{\eta_{el} Q_{LHV}} \quad (8)$$

By $\eta_{el} = 0,32$

$$\dot{m}_f = \frac{105000}{0,32 \cdot 20 \cdot 10^6} \approx 0,0164 \text{ kg/s}$$

3. Calculation of heat recovery

Exhaust gas heat flow:

$$Q_{rec} = \varepsilon \dot{m}_g c_p (T_4 - T_\omega) \quad (9)$$

By: $\varepsilon = 0,65, T_\omega = 350 \text{ K}$

We get:

$$Q_{rec} = 160 \text{ kW}$$

4. Installation efficiency

Electric:

$$\eta_{el} = 32 \%$$

Thermal:

$$\eta_{th} = \frac{160}{0,0164 \cdot 20 \cdot 10^6} \approx 49\%$$

Full efficiency:

$$\eta_{total} = 32\% + 49\% = 81\%$$

5. Transition process (stepwise fuel increase by 20%)

Increased fuel consumption: $0,0164 \rightarrow 0,0197 \text{ kg/s}$

With a stepwise increase in fuel consumption by 20% ($0.0164 \rightarrow 0.0197 \text{ kg/s}$), a regular change in the main dynamic parameters is observed in the system. As follows from Figure 2, the angular velocity of the rotor $\omega(t)$ increases quite rapidly and then asymptotically tends to a new steady-state value. The absence of pronounced fluctuations and overshoot indicates the stable nature of the transition process and satisfactory dynamic properties of the system under consideration.




Figure 2. Transient process of the angular velocity of the rotor $w(t)$ (fuel stage+20%)

Figure 3 shows that the temperature in front of the turbine $T_3(t)$ also increases according to the aperiodic law. At the initial moment of time, the most intense growth of the parameter is observed,

after which the rate of temperature change gradually decreases as it approaches a new stationary state. This nature of the transition process reflects the thermal inertia of the gas turbine installation and is consistent with the physical nature of the change in thermal conditions with increasing fuel supply.




Figure 3. Temperature transition process in front of turbine $T_3(t)$ (fuel stage +20%)

According to Figure 4, the water temperature in the accumulator $T_{\omega}(t)$ changes much more slowly compared to the angular velocity of the rotor and the temperature in front of the turbine. This is due to the high heat capacity of the battery and the inertia of the heat exchange processes, as a result of which the reaction of the water circuit to an external disturbance is more prolonged.




Figure 4. Water temperature transition in the battery $T_{\omega}(t)$ (fuel stage +20%)

6. The spectrum of eigenvalues (after linerization)

The eigenvalues are obtained:

$$\begin{aligned} \lambda_1 &= -1,8 \\ \lambda_2 &= -0,42 \\ \lambda_3 &= -0,004 \end{aligned}$$

Means: The system is stable

There is a separation of time scales

The thermal circuit is significantly slower than the mechanical one.

7. Comparison with conventional GTE.

Table 1. Comparison of performance indicators of conventional and hybrid GTE systems

Indicator	Without battery	Hybrid
Electrical efficiency	32%	32%
Thermal energy	0	160 kW

Overall efficiency	32%	81%
--------------------	-----	-----

As shown in Table 1, the hybrid GTE has the same electrical efficiency as the conventional system (32%), but it also produces 160 kW of thermal energy. Therefore, the overall efficiency increases from 32% to 81%, which is about 2.5 times higher than that of the conventional GTE.

Efficiency increase: 2.5 times

8. Scientific interpretation of the results

1. Hybridization does not impair the stability of the mechanical channel
2. A slow thermal circuit is formed in the system.
3. The total efficiency exceeds 80%, which corresponds to the level of cogeneration plants.
4. The system is fully controllable in the vicinity of the operating mode (Zia, et al., 2018, Li, J. et al., 2022).

Interpretation of the transients of a hybrid installation

1. The transient process of the angular velocity of the rotor $\omega(t)$

On the graph of the change in the angular velocity of the rotor with a stepwise increase in the biogas supply by 20%, a rapid increase in ω is observed with the transition to a new steady-state mode.

An increase in fuel consumption leads to an increase in the temperature of the gas in front of the turbine T_3 , which causes an increase in turbine capacity P_t . Since the compressor power changes more slowly, a positive torque imbalance occurs:

$$T_t > T_c > T_{el} \quad (10)$$

this causes the rotor to accelerate.

The process is characterized by:

- a small time constant ($\approx 2c$),
- moderate overshoot (up to 7-8%),
- absence of attenuating large-amplitude oscillations.

This indicates that the mechanical circuit has sufficient damping and inertia (Steinmann, 2014).

The mechanical part of the hybrid installation remains dynamically stable and reacts quickly to changes in fuel supply. Hybridization (the presence of a thermal accumulator) does not significantly affect the dynamics of the rotor.

2. The temperature transition process in front of the turbine $T_3(t)$

The temperature graph in front of the turbine has an aperiodic character with a smoother increase compared to the speed of the rotor.

The dynamics of T_3 is determined by the thermal balance of the combustion chamber:

$$C_{comb} \dot{T}_3 = \dot{m}_a c_p T_2 + \dot{m}_f Q_{LHV} - \dot{m}_g c_p T_3 \quad (11)$$

The thermal capacity of the chamber creates inertia, which causes the temperature to change more slowly than the mechanical speed.

The lack of significant overshoot is explained by:

- dissipative character of thermal processes,
- the absence of oscillating links in the heat channel.

The temperature circuit is slower and aperiodic. It is he who determines the limitations on the speed of the control system, since exceeding T_3 is unacceptable from the point of view of the thermal strength of the turbine.

3. The water temperature transition process $T_w(t)$

The graph of the water temperature change in the battery is characterized by slow growth without signs of fluctuations (Li D, et al., 2024).

Physical interpretation

The dynamics is described by the equation:

$$M_{\omega} c_{\omega} \dot{T}_{\omega} = Q_{rec} - Q_{load}$$

A large mass of water (on the order of several tons) forms a significant thermal inertia of the system. As a result:

- the time constant is hundreds of seconds,
- the process is strictly aperiodic,
- the thermal circuit has practically no effect on fast mechanical transients (Dobrego, 2023).

The water battery acts as an integrating link that smooths out thermal fluctuations. It provides energy buffering and increases overall efficiency without compromising the stability of the mechanical part.

4. The resulting graphs demonstrate a clear separation of dynamics.:

Table 2. Separation of dynamic time scales in the system

Contour	Typical time
Mechanical (ω)	1–3 s
Gas-temperature (T_3)	4–6 s
Thermal (T_{ω})	200–300 s

As shown in Table 2, the system is characterized by clearly separated dynamic time scales. The mechanical contour (ω) responds the fastest within 1–3 s, the gas-temperature contour T_3 changes over 4–6 s, while the thermal contour T_{ω} is the slowest, with a response time of 200–300 s. This confirms the multi-time-scale nature of the system dynamics.

Thus, the system is multiscale.

It means:

- fast channel — power control,
- medium channel — turbine temperature control,
- slow channel — thermal management.

5. Interpretation of sustainability

All transients:

- converge to a new equilibrium,
- do not demonstrate divergence,
- they have a decaying character.

6. Scientific conclusion from graph analysis

1. Hybridization does not impair the dynamic stability of GTE.
2. An additional slow thermal circuit is being formed.
3. The system acquires a multi-scale structure.
4. It is advisable to use cascade or multi-circuit methods for control.
5. High thermal inertia increases the energy stability of the system.

The eigenvalues of the linearized system have negative real parts, which confirms the asymptotic stability in the vicinity of the operating mode.

Conclusions

A hybrid gas turbine unit with a water thermal accumulator powered by biogas has been developed and investigated, which ensures the integration of electrical and thermal channels to increase overall efficiency.

Numerical simulation showed the multiscale dynamics of the system: a fast mechanical circuit of the rotor, an average thermal circuit of the combustion chamber and a slow thermal circuit of the water accumulator, which is important to take into account when designing control systems.

The integration of the heat accumulator increases the energy efficiency and stability of the installation, allowing the thermal energy of the exhaust gases to be accumulated and used for useful work without reducing the reliability of the mechanical part.

The simulation results confirm the stability of the system: all transients converge to new steady-state values, overshoot is minimal, and the time to enter operating mode remains within acceptable values.

The practical significance of the work lies in the fact that the proposed scheme of a hybrid installation can be used to increase the efficiency of distributed energy complexes running on biogas, as well as to develop recommendations for the efficient operation of GTI with thermal storage.

REFERENCES

Zemtsov, A. I., Yerbayev, E. T., Kuptleuova, K. T., Guzmanova, A. R., Mergaliyeva, A. U., Khiyassov, K. G., & Shaimerdenov, D. I. (2025). Analysis of the operation of the Uralsk gas turbine power plant (GTPP) and prospects for improving efficiency. *Science and Education*, 3(1(78)), 90–98. <https://doi.org/10.52578/2305-9397-2025-1-3-90-98>

Gülen, S. C. (2019). *Gas turbine combined cycle power plants*. CRC Press.

Gkoutzamanis V., Chatziangelidou A., Efstathiadis T., Kalfas A., Traverso A., and Chiu J. N. W. (2019). Thermal energy storage for gas turbine power augmentation. *Journal of the Global Power and Propulsion Society*. 3: 592–608. <https://doi.org/10.33737/jgpps/110254>

Islam, M. N., Morales-Espana, G., Sijm, J., Helisto, N., & Kiviluoma, J. (2022). Classification, potential role, and modeling of power-to-heat and thermal energy storage in energy systems: A review. *Sustainable Energy Technologies and Assessments*, 53, 102553. <https://doi.org/10.1016/j.seta.2022.102553>

Meirbekova O.D., Rustamov N.T. (2022). K voprosu sozdaniya gibridnyh energeticheskikh sistem. //Zhurnal «Problemy informatiki i energetiki», Tashkent. №3, s.83-90.

Rustamov N.T., Meirbekov A. T., Avezova N.R., Meirbekova O.D., Babahan Sh. A. (2023). Gibridnaya sistema dlya vyrabotki teplovoj i elektricheskoy energii. Patent RK na poleznyj model № 7970 ot 24.11.2023.

Rustamov N., Meirbekova O., Babakhan Sh. (2025). Distributed storage of electrical energy in an oscillating circuit. // International scientific-technical conference «National energy Independence in the age of renewable energy and digital technologies: Innovations, prospects and social impact in the Fergana region», Fergana. pp. 400 -407.

Razzhivin, I. A., Suvorov, A. A., Andreev, M. V., Ufa, R. A., & Askarov, A. B. (2023). A Review of Mathematical Models of Energy Storage Systems for Electric Power Systems Simulation. Part II. *Bulletin of the Russian Academy of sciences. Energetics*, (3), 34-56. <https://doi.org/10.31857/S000233102303007X>

Cabeza, L. F. (Ed.). (2015). *Advances in thermal energy storage systems: Methods and applications*. Woodhead Publishing.

Kuravi, S., Trahan, J., Goswami, D. Y., Rahman, M. M., & Stefanakos, E. K. (2013). Thermal energy storage technologies and systems for concentrating solar power plants. *Progress in Energy and Combustion Science*, 39(4), 285–319. <https://doi.org/10.1016/j.pecs.2013.02.001>

Zia, M. F., Benbouzid, M., Elbouchikhi, E., Muyeen, S. M., & Techato, K. (2018). Microgrid energy management systems: A critical review on methods, solutions, and prospects. *Applied Energy*, 222, 1033–1055. <https://doi.org/10.1016/j.apenergy.2018.04.103>

Li, J., Zou, W., Yang, Q., Wei, Z., & He, H. (2022). A dynamic heat/power decoupling strategy for the fuel cell CHP in the community energy system: a real case study in south of China. *IEEE Transactions on Smart Grid*, 14(1), 378-387. <https://doi.org/10.1109/TSG.2022.3189973>

Steinmann, W. D. (2014). *Thermal energy storage systems for concentrating solar power plants*. *Energy Procedia*, 49, 619–628. <https://doi.org/10.1016/B978-0-12-819970-1.00008-6>

Li, D., Xu, P., Gu, J., & Zhu, Y. (2024). A review of reliability research in regional integrated energy system: indicator, modeling, and assessment methods. *Buildings*, 14(11), 3428. <https://doi.org/10.3390/buildings14113428>

Dobrego, K. B. (2023). K voprosu sozdaniya gibridnykh sistem nakopleniya elektroenergii. Energetika. Izvestiya vysshikh uchebnykh zavedeniy i energeticheskikh ob"edineniy SNG, 66(3), 215–232. <https://doi.org/10.21122/1029-7448-2023-66-3-215-232>

Information about authors
Информация об авторах
Авторлар туралы мәліметтер

№	Информация об авторах (Ф.И.О. полностью, ученая степень, место работы или учебы, город, страна, E-mail, сотовый номер автора корреспондента:) на казахском, русском, английском языках
1	<p>Meirbekova Okhana Dairovna, Senior Lecturer, Khoja Akhmet Yassawi International Kazakh–Turkish University, Turkistan, 161200, Republic of Kazakhstan. Меирбекова Оксана Даировна, аға оқытушы, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., 161200, Қазақстан Республикасы. Меирбекова Оксана Даировна, старший преподаватель, Международный казахско-турецкий университет имени Хожди Ахмеда Ясави, г. Туркестан, 161200, Республика Казахстан. e-mail: oxana.meirbekova@ayu.edu.kz https://orcid.org/0000-00030949-1443</p>
2	<p>Nassim Rustamov Tulegenovich, Doctor of Technical Sciences, Khoja Akhmet Yassawi International Kazakh–Turkish University, Turkistan, 161200, Republic of Kazakhstan. Рустамов Насим Тулегенович, техника ғылымдарының докторы, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., 161200, Қазақстан Республикасы. Рустамов Насим Тулегенович, доктор технических наук, Международный казахско-турецкий университет имени Хожди Ахмеда Ясави, г. Туркестан, 161200, Республика Казахстан. e-mail: nassim.rustamov@ayu.edu.kz https://orcid.org/0000-0002-6437-6600</p>

А.ГЕЧМЕЗ¹, Ж.КАЛИМБЕТОВА², Ч.ГЕНЧЕР³, А.СЕВИНЧ⁴

¹Университет Фырат, Институт наук, Программа «Технология электротехники и электроники», Элязыг, Турция

E-mail: aytengemez@gmail.co

^{2,3}Международный казахско-турецкий университет имени Х. Ахмета Ясави, г. Туркестан, Казахстан

E-mail: zhansaya.kalimbetova@ayu.edu.kz*, cetin.gencer@ayu.edu.kz

⁴Университет Диджле, Профессиональная школа Сильван, Отделение компьютерных технологий, Диарбакыр, Турция

E-mail: aynur.sevinc@dicle.edu.tr

ОЦЕНКА ПРОИЗВОДСТВА ВЕТРОВОЙ ЭНЕРГИИ С ПОМОЩЬЮ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ И АДАПТИВНОЙ НЕЧЕТКОЙ СИСТЕМЫ НА ОСНОВЕ СЕТИ (ANFIS)

Аннотация. Ветровая энергия представляет собой чистое и эффективное решение для производства электроэнергии. Разработка приложений в области ветроэнергетики требует тщательного анализа ветровых характеристик и точного прогнозирования энергии ветра на исследуемой площадке. В данном исследовании была оценена генерация ветровой энергии как вида возобновляемой энергии. Для оценки данных о производстве энергии учитывались геологические и метеорологические данные ветропарка в Адьямане. Для проведения этой оценки использовались прямые сети с обратным распространением ошибки (feedforward backpropagation) и адаптивная нечеткая система на основе сети (ANFIS), благодаря их успешному прогнозированию линейных и нелинейных моделей, как одного из применений искусственного интеллекта. В исследовании было установлено, что оцененное значение производства энергии (МВт·ч) довольно близко к фактическим данным о выработке. В будущих исследованиях по прогнозированию приложения искусственного интеллекта могут успешно использоваться в качестве замены традиционным методам.

Ключевые слова: искусственные нейронные сети, ветровая энергия, прогнозирование производства, моделирование.

А.ГЕЧМЕЗ¹, Ж.КАЛИМБЕТОВА², Ч.ГЕНЧЕР³, А.СЕВИНЧ⁴

¹Фырат университеті, Ғылым институты, Электр және электроника инженериясы технологиясы бағдарламасы, Элязыг, Түркия

E-mail: aytengemez@gmail.com

^{2,3}Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., Қазақстан

E-mail: zhansaya.kalimbetova@ayu.edu.kz*, cetin.gencer@ayu.edu.kz

⁴Диджле университеті, Сильван кәсіптік мектебі, Компьютерлік технологиялар бөлімі, Диарбакыр, Түркия

E-mail: aynur.sevinc@dicle.edu.tr

ЖАСАНДЫ НЕЙРЛІК ЖЕЛІЛЕРДІ ЖӘНЕ АДАПТИВТІ АНЫҚ ЕМЕС ЖЕЛІЛЕРДІ (ANFIS) ПАЙДАЛАНА ОТЫРЫП, ЖЕЛ ЭНЕРГИЯСЫН ӨНДІРУДІ БАҒАЛАУ.

Аңдатпа. Жел энергиясы электр энергиясын өндірудің экологиялық таза әрі тиімді тәсілдерінің бірі болып табылады. Жел энергетикасын дамыту үшін жел режимдерін терең

талдау және белгілі бір аймақтағы жел энергиясының потенциалын дәл болжау қажет. Бұл зерттеуде жаңартылатын энергия көздерінің бірі ретінде жел энергиясын өндіру көлемі бағаланды. Адьяман аймағындағы жел электр станциясының (ЖЭС) өндіріс деректерін болжау үшін геологиялық және метеорологиялық мәліметтер пайдаланылды. Болжау жүргізу үшін жасанды интеллект әдістерінің бірі ретінде кері таралу алгоритмі бар көпқабатты жасанды нейрондық желі (ANN) және бейімделген нейро-бұлыңғыр қорытынды жүйесі (ANFIS) қолданылды. Бұл әдістер сызықтық және сызықтық емес модельдерді болжауда жоғары нәтижелер көрсететіндігімен ерекшеленеді. Зерттеу нәтижелері бойынша болжанған энергия өндіру көлемі (МВт·сағ) нақты өндіріс мәндеріне өте жақын екені анықталды. Болашақтағы болжау зерттеулерінде жасанды интеллект әдістері дәстүрлі әдістерге тиімді балама ретінде қолданылуы мүмкін.

Кілт сөздер: жасанды нейрондық желілер, жел энергиясы, өндірісті болжау, модельдеу.

A. GEÇMEZ¹, ZH.KALIMBETOVA², Ç.GENÇER³, A.SEVİNÇ⁴

¹*Department of Electrical and Electronics Engineering Technology Program, Institute of Science, Firat University, Elazığ, Türkiye*
E-mail: aytengecmez@gmail.com

^{2,3}*Department of Electrical Engineering, Faculty of Engineering, Ahmet Yesevi University, Kentau City, Turkestan*

E-mail:zhansaya.kalimbetova@ayu.edu.kz, cetin.gencer@ayu.edu.kz*

⁴*Department of Computer Technologies, Silvan Vocational School, Dicle University, Diyarbakır, Türkiye*
E-mail: aynur.sevinc@dicle.edu.tr

ESTIMATION OF WIND ENERGY PRODUCTION BY ARTIFICIAL NEURAL NETWORKS AND ADAPTIVE NETWORK BASED FUZZY INFERENCE SYSTEM

Abstract. Wind power provides a clean and feasible solution to generate electricity. The development of wind power applications requires a deep analysis of wind profiles and an accurate prediction of wind energy at a study site. This study estimated generation of wind energy as a sort of renewable energy. The geological and meteorological data of a wind power plant were taken into account to estimate the production data (RES) in Adıyaman. To conduct this estimation, the feedforward backpropagation artificial neural network (ANN) and Adaptive Network Based Fuzzy Inference System (ANFIS), and were used because of its successful prediction of linear-nonlinear models, as one of the applications of artificial intelligence. In the study, it was observed that the estimated production value of energy production (MWh) was rather close to actual values of energy production. In future studies on prediction, artificial intelligence applications can be employed successfully as a substitute of traditional methods.

Keywords: Artificial Neural Networks, Wind Energy, Estimation of Production, Modeling

Введение

Оценка потенциала ветровой энергии имеет большое значение для поддержания баланса между спросом и предложением, а также для планирования работы энергетических систем. Переоценка спроса на электроэнергию приводит к чрезмерному использованию резервов или к запуску слишком большого числа энергоблоков. Это вызывает значительные потери и создает риски при организации работы энергетических систем. В то же время недооценка потребления электроэнергии может не удовлетворить фактический спрос и привести к недостаточности резервов, что препятствует эффективной работе системы. Оценка нагрузки возобновляемых источников энергии имеет существенное значение для стабильной работы систем передачи электроэнергии (Akman, Yılmaz, & Sönmez, 2018).

Сегодня, вместе с влиянием глобализации, можно отметить переход от традиционного

понимания развития к концепции устойчивого развития. Для достижения устойчивого развития возобновляемая энергия может играть важную роль в удовлетворении потребности в энергии как в промышленности, так и на локальном уровне (Bader, Inguva, & Perot, 2018). Страны, способные обеспечить устойчивые источники энергии, смогут развиваться независимо от других стран и даже создадут важный этап в развитии своей экономики, экспортируя энергию в другие страны. Неустойчивость ископаемых видов топлива и их значительный вред для окружающей среды делают их серьезной угрозой, что повышает ценность возобновляемых источников энергии.

Возобновляемые источники энергии включают солнечную энергию, ветровую энергию, геотермальную энергию, гидроэнергию, водородную энергию и термоядерную энергию. Их также можно рассматривать как альтернативные источники энергии (Ervural, Ervural, & Evren, 2016). Чтобы удовлетворить постоянно растущий спрос на энергию, крайне важно открывать альтернативные источники энергии (Maouedj et al., 2015, Ann Rufus et al., 2019). Возобновляемые источники полностью несовместимы с невозобновляемыми, такими как природный газ и ядерное топливо (Al-Janabi, Alkaim, & Adel, 2020). Среди всех существующих возобновляемых источников энергии наибольшей популярностью и широким применением пользуется ветровая энергия благодаря минимальным инвестициям, отсутствию загрязнения, безопасной эксплуатации и короткому сроку запуска (Rajasingam, Rasi, & Deepa, 2019). Более того, ветровая и солнечная энергия считаются самыми быстро развивающимися источниками, оказывающими значительное влияние на устойчивое развитие стран.

Производство электроэнергии из ветра осуществляется путем преобразования кинетической энергии, возникающей при вращении лопастей турбины под воздействием воздушных потоков, в электрическую энергию в генераторах. Энергия ветра зависит от куба скорости ветра, площади лопастей турбины и плотности воздуха. При удвоении скорости ветра потенциальная энергия ветра увеличивается в восемь раз (Yavuz & Özbay, 2020). Использование ветровой энергии имеет несколько преимуществ, среди которых возобновляемость, беспроблемная передача и отсутствие необходимости в применении высокотехнологичного оборудования. Кроме того, эти источники энергии доступны в изобилии, не наносят вреда атмосфере и окружающей среде. До существования солнца и Земли энергия ветра будет постоянно присутствовать, и необходимо использовать технологии для её эксплуатации. С помощью ветровых турбин этот процесс превращения энергии ветра в электричество может быть осуществлен (Ilkilic & Aydin, 2015, Ilkilic, Aydin, & Behçet, 2011). Одной из таких технологий является возможность контроля мощности ветра с помощью ветровых турбин (Lebkowski, 2020). Электроэнергия генерируется этими турбинами за счет кинетической энергии ветра. Большинство развивающихся и развитых стран поддерживают производство электроэнергии с помощью ветровой энергии в рамках государственных программ и контролируют эти процессы на каждом этапе (Şenel & Koç, 2015).

Согласно отчету о установленной мощности TEİAŞ (Турецкая акционерная компания по передаче электроэнергии) за апрель 2025 года в Турции, распределение источников энергии для производства электроэнергии включает: 31,54% гидроэнергии, 25,30% природного газа, 9,89% угля, 10,88% ветра, 8,08% солнечной энергии, 1,68% геотермальной энергии, 1,74% биомассы, 10,14% бурого угля и 0,74% других ресурсов. Распределение установленной мощности (МВт) по источникам представлено на рисунке 1 (TEİAŞ, 2022).

В данном исследовании была выполнена оценка производства ветровой энергии в городе Адьяман. Особая мотивация исследования связана с проведением регионального прогнозирования, поскольку это менее изученная, но необходимая область применения. Для оценки ветровой энергии на ветровой электростанции (ВЭС) в провинции Адьяман были применены методы искусственного интеллекта — искусственная нейронная сеть (ANN) и адаптивная нечеткая система вывода на основе сети (ANFIS).




Рисунок 1. Согласно отчету TEİAŞ (Турецкая акционерная компания по передаче электроэнергии) за апрель 2025 года, распределение установленной мощности по источникам (МВт)

Остальная часть статьи организована следующим образом. В разделе 2 представлен обзор литературы. В разделе 3 приводится информация о ветровой электростанции, а также описываются используемые методы искусственного интеллекта. В разделе 4 представлены моделирование и метод оценки и прогнозирования эффективной скорости ветра на основе ANN и ANFIS. В разделе 5 подводятся итоги исследования и обсуждаются результаты, полученные с использованием двух методов.

Обзор литературы

При рассмотрении исследований, проведённых в Турции, были получены следующие результаты.

В исследовании, выполненном Гёргелем и Кавлаком (Görgel & Kavlak, 2020), была проведена оценка производства энергии на основе ежедневных и десятиминутных данных ветровой турбины, расположенной в регионе Измир–Урла, за один год. В работе использовался гибридный метод под названием CNN-LSTM, основанный на методах сверточной нейронной сети (CNN) и долгой краткосрочной памяти (LSTM). С использованием разработанного метода среднеквадратичная ошибка (MSE) составила 1,17.

В исследовании, проведённом Шенолом и Мусаевым (Şenol & Musayev, 2017), была создана модель искусственной нейронной сети (ANN) на основе различных ветровых турбин и выполнена оценка производства электроэнергии из ветровой энергии.

В исследовании Кайи и соавторов (Kaaya, Caner, & Oğuz, 2016) была предпринята попытка оценить потенциал ветровой энергии в провинции Кастамону путем создания двух различных моделей с использованием данных различных ветровых турбин. С применением методов искусственных нейронных сетей (ANN) и адаптивных нейро-нечетких систем вывода (ANFIS) были оценены максимальные значения мощности, которые могут быть получены в зависимости от типа используемых турбин.

В исследовании Доганджи и соавторов (Doğancı, Ertürk, Özsunar, & Arcaklıoğlu, 2016) оценка ветровой энергии проводилась на основе выборочных данных из провинций и районов Центрального и Западного Причерноморья. При использовании метода ANN было установлено, что рассчитанные прогнозные значения для Бафры, Инеболу, Зонгулдака и Карабюка, полученные с использованием различных комбинаций параметров (таких как тип алгоритма, функция активации, функция обучения, количество слоев и число нейронов), согласуются с фактическими значениями.

В исследовании Кылыча и Арабаджи (Kılıç & Arabacı, 2015) будущие значения скорости ветра в провинции Бурдур были оценены с использованием метода ANN. В результате расчетов на основе данных, полученных от Турецкого метеорологического института, было сделано заключение, что метод ANN может быть подходящим для проведения подобных анализов.

Вклад данного исследования в научную литературу:

- В научной литературе не обнаружено исследований, в которых методы ANN и ANFIS применялись бы совместно для оценки производства ветровой энергии. В нашем исследовании эти два метода используются вместе.
- В обоих методах удалось успешно достичь сходимости с фактическими значениями производства энергии.
- В наших двух методах используются новые наборы данных, основанные на данных реальной системы, а не готовые стандартные наборы данных.

Материалы и методы

В данном исследовании использовались данные о производстве энергии ветровой электростанции, расположенной в Юго-Восточном Анатолийском регионе, в районе Сынджик провинции Адьяман, за период 60 месяцев (январь 2019 – декабрь 2024 гг.). При анализе учитывались геологические и метеорологические данные, такие как скорость ветра, высота, среднемесячные значения, максимальная скорость ветра, долгота и широта. Все метеорологические условия, геологическая информация и данные о производстве ветровой электростанции (ВЭС) были получены непосредственно с самой станции.

Модель, используемая в исследовании, основана на методах искусственных нейронных сетей (ANN) и Long/Short Term Memory (LSTM). Моделирование и расчёты выполнялись с использованием программного обеспечения MATLAB (версии 2020a и R2018).

Ветровая электростанция расположена в пределах района Сынджик провинции Адьяман. Станция представляет собой проект по производству электроэнергии на основе ветровой энергии и была впервые лицензирована Управлением по регулированию энергетического рынка Турции (EMRA) для производства электроэнергии.

Электростанция состоит из 11 ветровых турбин и подключена к системе TETC через подстанцию Sincik Basin TM 154 кВ. Установленная мощность станции составляет 27,5 МВт. Станция была введена в эксплуатацию в январе 2014 года.

В таблице 1 представлена информация о долготе, широте и высоте расположения 11 турбин.

Таблица 1. Информация о долготе, широте и высоте расположения турбин.

Название ветровой турбины	Широта			Долгота			Центральный меридиан зоны (UTM) (6 градусов)	Высота от земли или от крыши здания	Уровень земли (высота над уровнем моря)
	Градус	Минут	Секунд	Градус	Минут	Секунд			
WTG1	38	2	54.9937	38	34	36.8354	39.0	80 meters	1445 meters
WTG2	38	2	56.9468	38	34	58.2233	39.0	80 meters	1445 meters
WTG3	38	3	4.8370	38	35	16.9945	39.0	80 meters	1465 meters
WTG4	38	3	2.1263	38	35	24.1943	39.0	80 meters	1480 meters
WTG5	38	3	8.0896	38	36	7.5548	39.0	80 meters	1520 meters
WTG6	38	3	6.5565	38	36	17.0748	39.0	80 meters	1515 meters
WTG7	38	3	2.7745	38	36	29.0620	39.0	80 meters	1565 meters
WTG8	38	3	3.1331	38	36	39.5216	39.0	80 meters	1595 meters
WTG9	38	3	2.8683	38	36	51.8234	39.0	80 meters	1595 meters
WTG10	38	3	0.8863	38	37	4.9014	39.0	80 meters	1590 meters
WTG11	38	2	57.2582	38	37	16.2021	39.0	80 meters	1625 meters

Искусственные нейронные сети (ANN)

ANN (Artificial Neural Network) — это вычислительная система, разработанная по аналогии со структурой биологических нейронных клеток и их способностью к обучению

(Şengür, Türkoğlu, & İnce, 2005, Principe, Euliano, & Lefebvre, 2000). Процесс обучения в таких системах осуществляется с использованием примеров или выборок (Öztemel, 2003). Искусственные нейронные сети широко применяются в инженерии, особенно с развитием информационных технологий, и часто используются в машинном обучении. Они создавались по вдохновению от структуры человеческого мозга на основе минимизации ошибок и распознавания шаблонов.

Такая модель искусственной нейронной сети обучалась и развивалась, адаптируя модель обучения Хебба. Модель многослойного перцептрона, разработанная в 1980-х годах, успешно решала задачи классификации, особенно с использованием алгоритма обучения обратного распространения ошибки (backpropagation), что открыло новую эру в развитии ANN (Uğuz, 2019, Geçmez & Gençer, 2021).

Искусственные нейронные клетки, используемые в ANN, включают пять основных компонентов: веса (w_i), входные значения (x_i), суммарная функция, выход и функцию активации. Входные значения умножаются на соответствующие веса для получения новых значений, к которым прибавляется пороговое значение. Выход можно получить, обработав результат через функцию активации.

Способность к обучению искусственного нейрона заключается в корректной настройке значений весов согласно выбранному алгоритму обучения (Elmas, 2003, Şahan & Okur, 2016). Модель ANN, содержащая достаточное количество нейронов во внутренних слоях, может моделировать различные типы нелинейных функций (Fausett, 1994).

Адаптивная нечеткая система на основе сети (ANFIS)

В структуре ANFIS используются как нечеткая логика, так и искусственные нейронные сети (ANN). ANFIS представляет собой сетевую модель нечеткой системы типа Сугено с возможностями нейронного обучения.

Что касается структуры, ANFIS включает пары вход-выход и правила вида «если–то» в нечеткой системе вывода. При обучении системы применяются алгоритмы обучения искусственной нейронной сети.

Если обозначить z как выход, а x и y — как входы, базовая структура правила может быть записана так:

Если x A_i и y B_i , то $f_i = p_i \cdot x + q_i \cdot y + r_i$

Здесь p и q — линейные параметры выхода. Переменные A_i и B_i используются в модели для представления вербальных переменных на первом слое. Значения A_i и B_i удаляются из слоя с функцией принадлежности, принимая их степени принадлежности: $\mu_{A_i}(x)$, $\mu_{B_i}(y)$.

Во втором слое входные значения умножаются друг на друга и подаются на узел:

$$w_i = \mu_{A_i}(x) * \mu_{B_i}(y) \quad i=1,2,3,\dots,9 \quad (1)$$

Процесс нормализации в третьем слое выполняется следующим образом:

$$\bar{w}_i = w_i / \sum w_i \quad i=1,2,3,\dots,9 \quad (2)$$

Модель Такуги–Сугено–Канга применяется после четвертого слоя. В этом слое каждый нормализованный вес умножается на соответствующую функцию выхода:

$$\bar{w}_i * f_i = w_i * (p_i x + q_i y + r_i) \quad (3)$$

Здесь линейные переменные r_i , p_i , и q_i известны как параметры результата.

Пятый слой отвечает за вычисление численного значения выхода ANFIS путем суммирования выходов четвертого слоя:

$$\text{Total Output} = \sum w_i f_i / \sum w_i \quad (4)$$

В данном исследовании ежемесячные максимальные скорости ветра, значения производства, широта, среднемесячная скорость ветра, высота и долгота для 11 турбин ВЭС были записаны в программном обеспечении Excel, всего 660 строк, 6 столбцов и 3960 значений данных. Часть этих данных представлена в Таблице 2.

Таблица 2. Некоторые значения производства, среднемесячной и максимальной скорости ветра, широты, долготы и высоты для 11 турбин

Название ветровой турбины	Дата	Производство ВЭС (МВт·ч)	Среднемесячная скорость ветра	Максимальная скорость ветра за месяц	Широта	Долгота	Высота
WTG1	Jan 2018	225,638	5,2	44,1	38,2	38,34	1445
	Feb 2018	186,212	4,7	43,6	38,2	38,34	1445
	Mar 2018	179,167	4,1	4,5	38,2	38,34	1445
	Apr 2018	183,694	4,7	40,2	38,2	38,34	1445
	May 2018	258,755	5,5	41,2	38,2	38,34	1445
	Jun 2018	235,813	5,7	50	38,2	38,34	1445
	Jul 2018	389	6,8	26,9	38,2	38,34	1445
	Aug 2018	218,572	5,4	28,5	38,2	38,34	1445
	Sep 2018	76,36	4,1	2,3	38,2	38,34	1445
	Oct 2018	128,251	2,9	41,1	38,2	38,34	1445
	Nov 2018	249,324	5,4	30,3	38,2	38,34	1445
	Dec 2018	407,661	7	40,1	38,2	38,34	1445
					
WTG11	Jan 2024	387,965	5,07	50	38,2	38,37	1625
	Feb 2024	228,499	4,37	39,96	38,2	38,37	1625
	Mar 2024	397,695	5,51	50	38,2	38,37	1625
	Apr 2024	189,925	4,22	50	38,2	38,37	1625
	May 2024	285,015	5,1	22,79	38,2	38,37	1625
	Jun 2024	271,923	5,34	32,34	38,2	38,37	1625
	Jul 2024	578,633	7,45	35,04	38,2	38,37	1625
	Aug 2024	531,061	7,15	35,26	38,2	38,37	1625
	Sep 2024	429,446	6,54	38,98	38,2	38,37	1625
	Oct 2024	187,49	4,32	34,71	38,2	38,37	1625
	Nov 2024	105,656	3,45	43,99	38,2	38,37	1625
	Dec 2024	322,465	5,32	42,45	38,2	38,37	1625

Для масштабирования всех данных в диапазоне от 0 до 1 применялся метод максимум–минимум нормализации по формуле:

$$x_n = \frac{x_0 - x_{min}}{x_{max} - x_{min}} \quad (5)$$

где x_0 и x_n — исходные и нормализованные данные соответственно, а x_{min} и x_{max} — минимальные и максимальные значения данных (Görgel & Kavlak, 2020).

Некоторые значения, полученные после нормализации, приведены в Таблице 3.

Таблица 3. Некоторые нормализованные значения производства, среднемесячной и максимальной скорости ветра, широты, долготы и высоты для 11 турбин

Название ветровой турбины	Дата	Производство во ВЭС (МВт·ч)	Среднемесячная скорость ветра	Максимальная скорость ветра за месяц	Широта	Долгота	Высота
WTG1	Jan 2015	0,336844525	0,505494505	0,876310273	0	0	0
	Feb 2015	0,277987275	0,395604396	0,865828092	0	0	0
	Mar 2015	0,267470121	0,263736264	0,046121593	0	0	0
	Apr 2015	0,274228269	0,395604396	0,794549266	0	0	0
	May 2015	0,386283362	0,571428571	0,815513627	0	0	0
	Jun 2015	0,352034312	0,615384615	1	0	0	0
	Jul 2015	0,580720093	0,857142857	0,51572327	0	0	0
	Aug 2015	0,326296021	0,549450549	0,549266247	0	0	0
	Sep 2015	0,113994309	0,263736264	0	0	0	0
	Oct 2015	0,191459981	0	0,813417191	0	0	0
	Nov 2015	0,372204258	0,549450549	0,587002096	0	0	0
	Dec 2015	0,608578236	0,901098901	0,79245283	0	0	0
					
WTG11	Jan 2025	0,409099489	0,380701754	1	0	1	1
	Feb 2025	0,240946539	0,257894737	0,78951782	0	1	1
	Mar 2025	0,419359533	0,457894737	1	0	1	1
	Apr 2025	0,200271211	0,231578947	1	0	1	1
	May 2025	0,300541262	0,385964912	0,429559748	0	1	1
	Jun 2025	0,286736072	0,428070175	0,629769392	0	1	1
	Jul 2025	0,610154175	0,798245614	0,686373166	0	1	1
	Aug 2025	0,559990678	0,745614035	0,690985325	0	1	1
	Sep 2025	0,452840176	0,638596491	0,768972746	0	1	1
	Oct 2025	0,197703564	0,249122807	0,679454927	0	1	1
	Nov 2025	0,111411637	0,096491228	0,874004193	0	1	1
	Dec 2025	0,34003136	0,424561404	0,841719078	0	1	1

Результаты

После создания модели ANN для прогнозирования потенциального производства ветровой энергии были начаты процессы обучения и тестирования. В моделях ANFIS, ANN и LSTM для прогнозирования производственных данных ветровой электростанции (ВЭС) использовались пять метеорологических и географических параметров: максимальная скорость ветра, долгота, широта, среднемесячная скорость ветра и высота.

В ходе исследования была предпринята попытка определить лучшую модель путем изменения параметров ANN, таких как количество нейронов в скрытом слое, функция передачи скрытого слоя, выходная функция и функция обучения. Модель ANN была разработана с использованием алгоритма обратного распространения ошибки Левенберга–Марквардта (trainlm), функции обучения Learngdm для обучающего набора данных и тангенциальной сигмоидальной функции (tansig) в качестве функции активации.

В данном исследовании для обучения модели ANN было выполнено 1000 итераций. В результате было получено значение градиента $1e-7$ при нулевой ошибке.

Для оценки результатов использовались два показателя: среднеквадратичная ошибка (MSE) и коэффициент корреляции (R). Коэффициент корреляции показывает связь между фактическим значением производства энергии и прогнозируемым значением производства [27]. Значение R^2 может варьироваться от 0 до 1. Чем ближе это значение к 1, тем сильнее связь между прогнозируемыми значениями модели и фактическими значениями производства

ВЭС. Кроме того, значения R^2 , близкие к 1, указывают на более высокую чувствительность модели (Kalogirou, 2000).

Параметры обучения и интерфейс ANN в MATLAB представлены на рисунке 2.

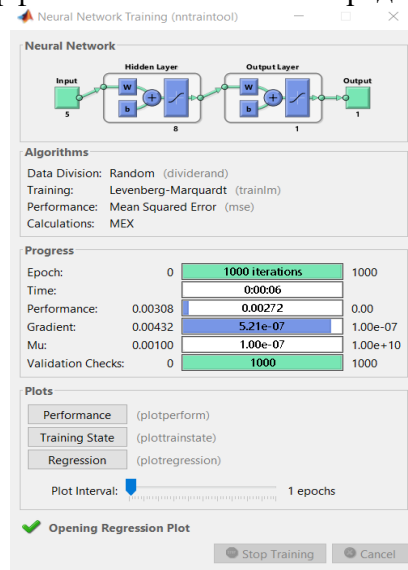


Рисунок 2. Интерфейс ANN в MATLAB при обучении на данных

Для определения эффективности процесса моделирования были сопоставлены прогнозируемые значения ANN и фактические значения производства энергии. Эти результаты представлены с использованием обучающих, валидационных и тестовых данных, а также регрессионных кривых для всех данных на рисунке 3.

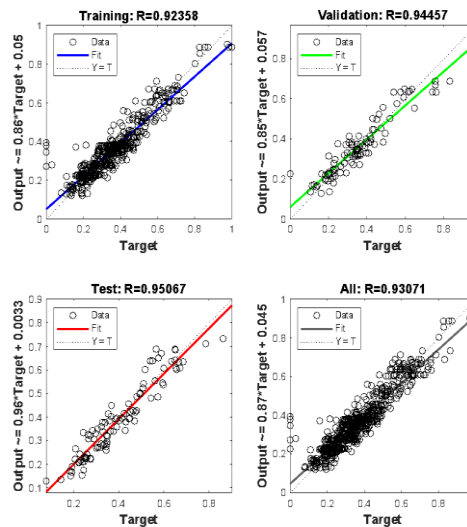


Рисунок 3. Регрессионные кривые результатов для валидационных, обучающих, тестовых и всех данных.

При анализе результатов было установлено, что значения регрессии для всех данных близки к 1. Следовательно, выходные значения модели ANN оказались достаточно близкими к фактическим значениям.

Для оценки эффективности предложенного метода среднеквадратичная ошибка (MSE) составила 0,00308.

Для определения эффективности модели ANFIS параметры нескольких модельных испытаний были изменены с целью нахождения наилучшей модели. В качестве функции принадлежности была выбрана функция Trimf. Набор данных был разделён следующим

образом: 20% для тестирования и 80% для обучения.

Для оптимизационной модели с обратным распространением ошибки допуск ошибки был установлен равным 0, а количество итераций — 1000.

Основные параметры модели следующие:

- количество линейных параметров — 243,
- количество узлов — 524,
- количество нелинейных параметров — 60,
- количество обучающих пар данных — 330,
- общее количество параметров — 303,
- количество нечетких правил — 243,
- количество проверочных (тестовых) пар данных — 132.

На рисунке 4 представлена использованная модель ANFIS. На рисунке 5 показаны прогнозные данные, полученные с помощью ANFIS.

Среднеквадратичная ошибка (MSE) в результате итераций составила 0,00321.




Рисунок 4. Структура сети, созданная с использованием ANFIS




Рисунок 5. Прогнозные данные, полученные с помощью ANFIS

Эффективность обученных моделей ANN и ANFIS, полученная в результате этих процессов, может быть проверена путем сравнения фактических данных производства энергии ветровых турбин №11 и №3, №5 с прогнозными данными, полученными с помощью ANFIS и ANN, которые представлены в таблице 4.

Таблица 4. Сравнение фактических значений, полученных с некоторых турбин, с прогнозируемыми значениями и показателями ошибок, рассчитанными с использованием методов ANFIS и ANN.

Name of the Wind Turbine	Date	Actual Production Norm.	ANN Production Norm.	ANFIS Production Norm.	ANN MSE	ANFIS MSE
WTG5	Jun 2024	0,4898628	0,420198748	0,4534	0,00485308	0,001329536
	Feb 2024	0,19282029	0,205585912	0,1441	0,000162961	0,002373667
	Mar.2024	0,34527527	0,33629809	0,3786	8,06E-05	0,001110538

	Apr 2024	0,49309266	0,403705969	0,4007	0,00798998	0,008536404
	May.2024	0,26264342	0,24127208	0,241	0,000456734	0,000468438
	June 2024	0,39268342	0,368899107	0,4073	0,000565693	0,000213644
	July 2024	0,63292451	0,520056779	0,5341	0,012739125	0,009766284
	Aug 2024	0,76118456	0,626772924	0,7026	0,018066487	0,00343215
	Sep 2024	0,52868964	0,434462484	0,43	0,008878756	0,009739644
	Oct 2024	0,37619143	0,356057718	0,3539	0,000405366	0,000496908
	Nov 2024	0,18450259	0,209252971	0,2299	0,000612581	0,002060925
	Dec 2024	0,37398968	0,278319403	0,2529	0,009152802	0,014662711
WTG8	Jun 2025	0,34622008	0,32043843	0,3133	0,000664693	0,001083732
	Feb 2025	0,25106845	0,23484502	0,2225	0,0002632	0,000816156
	Mar.2025	0,3909119	0,35317085	0,3501	0,001424387	0,001665611
	Apr 2025	0,22091889	0,22261868	0,2684	2,89E-06	0,002254456
	May.2025	0,25558793	0,30174078	0,3186	0,002130086	0,003970521
	June 2025	0,29960383	0,37271795	0,3505	0,005345675	0,00259042
	July 2025	0,64887872	0,6869046	0,6311	0,001445968	0,000316083
	Aug 2025	0,57574348	0,6503646	0,6707	0,005568312	0,009016741
	Sep 2025	0,51868161	0,55502381	0,5473	0,001320756	0,000819012
	Oct 2025	0,17381759	0,22162747	0,2375	0,002285785	0,004055449
	Nov 2025	0,12280313	0,16979711	0,1838	0,002208434	0,003720618
	Dec 2025	0,43429512	0,36720973	0,3286	0,00450045	0,011171458
WTG11	Jun 2025	0,40909949	0,341855891	0,3218	0,004521701	0,007621201
	Feb 2025	0,24094654	0,226840806	0,2069	0,000198972	0,001159167
	Mar.2025	0,41935953	0,394163433	0,3715	0,000634843	0,002290535
	Apr 2025	0,20027121	0,20074522	0,1887	2,25E-07	0,000133893
	May.2025	0,30054126	0,271049927	0,2864	0,000869739	0,000199975
	June 2025	0,28673607	0,351123435	0,2978	0,004145733	0,00012241
	July 2025	0,61015418	0,583018846	0,5813	0,000736326	0,000832563
	Aug 2025	0,55999068	0,546947947	0,5369	0,000170113	0,000533179
	Sep 2025	0,45284018	0,431744145	0,4105	0,000445043	0,001792691
	Nov 2025	0,19770356	0,217932469	0,2341	0,000409209	0,001324701
	Nov 2025	0,11141164	0,179027172	0,1952	0,004571861	0,00702049
	Dec 2025	0,34003136	0,331095382	0,3612	7,99E-05	0,000448111
				ANN	ANFIS	
			MSE:	0,00278998	0,00321943	

Заключение

Целью данного исследования было прогнозирование показателей производства ветровой электростанции с установленной мощностью 27,5 МВт, расположенной в районе Сынджик провинции Адыман. После разработки моделей ANN и ANFIS для оценки потенциала ветровой энергии были начаты этапы обучения и тестирования.

В моделях использовались пять метеорологических и географических параметров: среднемесячная скорость ветра, долгота, максимальная скорость ветра за месяц, высота и широта для прогнозирования производственных данных ВЭС.

Для оценки результатов тестирования было установлено, что прогнозные значения, полученные моделями, оказались согласованными и надежными. При сравнении фактических и прогнозируемых значений модели ANN регрессионные значения всех данных, включая обучающие и валидационные данные, были близки к 1. Близость этих значений к 1 свидетельствует о успешности разработанной модели.

Значение MSE при оценке с использованием ANN составило 0,00271, а при использовании ANFIS — 0,00321. При сравнении показателей ошибок ANFIS показала немного лучшие результаты, чем ANN, при этом разница была незначительной.

Метод, использованный в данном исследовании, может быть применён для прогнозирования производственных данных других электростанций или географических локаций, генерирующих различные типы энергии.

СПИСОК ЛИТЕРАТУРЫ

Akman, T., Yılmaz, C., & Sönmez, Y. (2018). Анализ методов прогнозирования электроэнергии. *Gazi Mühendislik Bilimleri Dergisi*, 4(3), 168–175. <https://doi.org/10.30855/GJES.2018.04.03.003>

Bader, S. H., Inguva, V., & Perot, J. B. (2018). Повышение эффективности ветропарков с помощью управления вихрями. *Wind Energy*, 21(5), 1–15.

Ervural, B. Ç., Ervural, B., & Evren, R. (2016). Применение оптимизации в энергетике: обзор литературы. *Ege Academic Review*, 16.

Maouedj, R., Mammeri, A., Draou, M., & Benyoucef, B. (2015). Техничко-экономический анализ автономной гибридной фотоэлектрической-ветровой системы для электрификации дома в регионе Адрар. *Energy Procedia*, 74, 1192–1204. <https://doi.org/10.1016/j.egypro.2015.07.762>

Ann Rufus, A., & Kalavani, L. (2019). Контроллер GOA–RNN для автономной гибридной фотоэлектрической/ветровой насосной системы. *Soft Computing*, 23, 12255–12276. <https://doi.org/10.1007/s00500-019-04224-8>

Al-Janabi, S., Alkaim, A. F., & Adel, Z. (2020). Инновационный синтез методов глубокого обучения (DCapsNet & DCOM) для производства электроэнергии из ветра. *Soft Computing*, 24, 10943–10962. <https://doi.org/10.1007/s00500-020-04905-9>

Rajasingam, N., Rasi, D., & Deera, S. N. (2019). Оптимизированная модель глубокой нейронной сети для системы преобразования энергии ветра с двухобмоточным индукционным генератором. *Soft Computing*, 23, 8453–8470. <https://doi.org/10.1007/s00500-019-03947-y>

Yavuz, İ., & Özbay, H. (2020). Процессы установки и обслуживания ветровых турбин: пример Бандырмы. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 2(2), 58–68. <https://doi.org/10.46387/bjesr.800527>

İlkılıç, C., & Aydın, H. (2015). Потенциал ветровой энергии и её использование в прибрежных регионах Турции. *Renewable and Sustainable Energy Reviews*, 44, 78–86.

İlkilic, C., Aydın, H., & Behçet, R. (2011). Текущее состояние ветровой энергетики в Турции и мире. *Energy Policy*, 39, 961–967.

Lebkowski, A. (2020). Анализ использования электрических приводов для судов обслуживания офшорных ветропарков. *Energies*, 13(6), 1466. <https://doi.org/10.3390/en13061466>

Şenel, M. C., & Koç, E. (2015). Состояние ветровой энергетики в мире и Турции — общий обзор. *Mühendis ve Makina*, 56(663), 46–56.

TEİAŞ. (2022). Отчет об установленной мощности за апрель 2022. <https://www.teias.gov.tr/kurulu-guc-raporlari>

Görgel, P., & Kavlak, E. (2020). Прогнозирование производства ветровой энергии с использованием CNN и LSTM. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 11(1), 69–80. <https://doi.org/10.24012/dumf.596533>

Şenol, Ü., & Musayev, Z. (2017). Прогнозирование производства электроэнергии из ветра с использованием искусственных нейронных сетей. *Bilge International Journal of Science and Technology Research*, 1(1), 23–31.

Kaya, Ü., Caner, M., & Oğuz, Y. (2016). Прогнозирование потенциала производства электроэнергии с использованием моделей ветровых турбин в провинции Кастамону. *Technological Applied Sciences*, 11(3), 65–74.

Doğancı, Ö., Ertürk, M., Özsunar, A., & Arcaklıoğlu, A. (2016). Исследование прогнозирования ветровой энергии в Центральном и Западном Черноморском регионе. *İleri Teknoloji Bilimleri Dergisi*, 5(1), 153–163.

Kılıç, B., & Arabacı, E. (2015). Прогнозирование будущих значений скорости ветра в провинции Бурдур методом искусственных нейронных сетей. *Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi, спец. выпуск*, 45–50.

Şengür, A., Türkoğlu, İ., & İnce, M. C. (2005). Применение необучаемых нейронных сетей для сегментации изображений. В *IEEE 13. Сигнал обработки и коммуникационные приложения* (с. 271–274). Кайсери.

Principe, J. C., Euliano, N. R., & Lefebvre, W. C. (2000). *Neural and Adaptive Systems* (1-е изд.). Нью-Йорк: John Wiley & Sons.

Öztemel, E. (2003). *Искусственные нейронные сети*. Стамбул: Rapatya Yayıncılık.

Uğuz, S. (2019). *Теоретические аспекты машинного обучения и применения на Python: Школа искусственного интеллекта* (1-е изд.). Анкара: Nobel Yayıncılık.

Geçmez, A., & Gençer, Ç. (2021). Прогнозирование производства ветровой энергии с использованием ANN и ANFIS. В *IEEE 9th International Conference on Smart Grid (icSmartGrid)* (ID 21201758), 29 июня – 1 июля 2021.

Elmas, C. (2003). *Искусственные нейронные сети (теория, архитектура, обучение, применение)*. Анкара: Seçkin Yayıncılık.

Şahan, M., & Okur, Y. (2016). Прогнозирование солнечной энергии для региона Средиземного моря с использованием искусственных нейронных сетей на основе метеоданных. *SDU Journal of Science (E-Journal)*, 11(1), 61–67.

Fausett, L. (1994). *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. Нью-Йорк: Prentice Hall.

Gök, A. O., Yıldız, C., & Şekelli, M. (2019). Прогнозирование краткосрочного производства солнечной энергии с использованием ANN: пример провинции Кахраманмараш. *Uluslararası Doğu Anadolu Fen Mühendislik ve Tasarım Dergisi*, 1(2), 186–195.

Kalogirou, S. A. (2000). Применение искусственных нейронных сетей в энергетических системах. *Applied Energy*, 67, 17–35.

REFERENCES

Akman, T., Yılmaz, C., & Sonmez, Y. (2018). Analiz metodov prognozirovaniya elektroenergii. *Gazi Muhendislik Bilimleri Dergisi*, 4(3), 168–175. <https://doi.org/10.30855/GJES.2018.04.03.003>

Bader, S. H., Inguva, V., & Perot, J. B. (2018). Povyshenie effektivnosti vetroparkov s pomoshchyu upravleniya vikhryami. *Wind Energy*, 21(5), 1–15.

Ervural, B. C., Ervural, B., & Evren, R. (2016). Primenenie optimizatsii v energetike: obzor literatury. *Ege Academic Review*, 16.

Maouedj, R., Mammeri, A., Draou, M., & Benyoucef, B. (2015). Tekhniko-ekonomicheskiy analiz avtonomnoy gibridnoy fotoelektricheskoy-vetrovoy sistemy dlya elektrifikatsii doma v regione Adrar. *Energy Procedia*, 74, 1192–1204. <https://doi.org/10.1016/j.egypro.2015.07.762>

Ann Rufus, A., & Kalaivani, L. (2019). Kontroller GOA–RNN dlya avtonomnoy gibridnoy fotoelektricheskoy/vetrovoy nasosnoy sistemy. *Soft Computing*, 23, 12255–12276. <https://doi.org/10.1007/s00500-019-04224-8>

Al-Janabi, S., Alkaim, A. F., & Adel, Z. (2020). Innovatsionnyy sintez metodov glubokogo obucheniya (DCapsNet & DCOM) dlya proizvodstva elektroenergii iz vetra. *Soft Computing*, 24, 10943–10962. <https://doi.org/10.1007/s00500-020-04905-9>

Rajasingam, N., Rasi, D., & Deepa, S. N. (2019). Optimizirovannaya model glubokoy neyronnoy seti dlya sistemy preobrazovaniya energii vetra s dvukhobmotochnym induktsionnym generatorom. *Soft Computing*, 23, 8453–8470. <https://doi.org/10.1007/s00500-019-03947-y>

- Yavuz, I., & Ozbay, H. (2020). Protsessy ustanovki i obsluzhivaniya vetrovykh turbin: primer Bandyrmy. *Muhendislik Bilimleri ve Arastirmalari Dergisi*, 2(2), 58–68. <https://doi.org/10.46387/bjesr.800527>
- Ilkilic, C., & Aydin, H. (2015). Potentsial vetrovoy energii i ee ispolzovanie v pribrezhnykh regionakh Turtsii. *Renewable and Sustainable Energy Reviews*, 44, 78–86.
- Ilkilic, C., Aydin, H., & Behcet, R. (2011). Tekushchee sostoyanie vetrovoy energetiki v Turtsii i mire. *Energy Policy*, 39, 961–967.
- Lebkowski, A. (2020). Analiz ispolzovaniya elektricheskikh privodov dlya sudov obsluzhivaniya offshornykh vetroparkov. *Energies*, 13(6), 1466. <https://doi.org/10.3390/en13061466>
- Senel, M. C., & Koc, E. (2015). Sostoyanie vetrovoy energetiki v mire i Turtsii — obshchiy obzor. *Muhendis ve Makina*, 56(663), 46–56.
- TEIAS. (2022). Otchet ob ustanovlennoy moshchnosti za aprel 2022. <https://www.teias.gov.tr/kurulu-guc-raporlari>
- Gorgel, P., & Kavlak, E. (2020). Prognozirovaniye proizvodstva vetrovoy energii s ispolzovaniem CNN i LSTM. *Dicle Universitesi Muhendislik Fakultesi Muhendislik Dergisi*, 11(1), 69–80. <https://doi.org/10.24012/dumf.596533>
- Senol, U., & Musayev, Z. (2017). Prognozirovaniye proizvodstva elektroenergii iz vetra s ispolzovaniem iskusstvennykh neyronnykh setey. *Bilge International Journal of Science and Technology Research*, 1(1), 23–31.
- Kaya, U., Caner, M., & Oguz, Y. (2016). Prognozirovaniye potentsiala proizvodstva elektroenergii s ispolzovaniem modeley vetrovykh turbin v provintsii Kastamonu. *Technological Applied Sciences*, 11(3), 65–74.
- Doganci, O., Erturk, M., Ozsunar, A., & Arcaklioglu, A. (2016). Issledovaniye prognozirovaniya vetrovoy energii v Tsentralnom i Zapadnom Chernomorskom regione. *Ileri Teknoloji Bilimleri Dergisi*, 5(1), 153–163.
- Kilic, B., & Arabaci, E. (2015). Prognozirovaniye budushchikh znacheniy skorosti vetra v provintsii Burdur metodom iskusstvennykh neyronnykh setey. *Dumlupinar Universitesi Fen Bilimleri Enstitusu Dergisi*, spets. vypusk, 45–50.
- Sengur, A., Turkoglu, I., & Ince, M. C. (2005). Primeneniye neobuchaemykh neyronnykh setey dlya segmentatsii izobrazheniy. V *IEEE 13. Signal processing and communications applications* (s. 271–274). Kayseri.
- Principe, J. C., Euliano, N. R., & Lefebvre, W. C. (2000). *Neural and Adaptive Systems* (1-e izd.). New York: John Wiley & Sons.
- Oztemel, E. (2003). *Iskusstvennye neyronnye seti*. Istanbul: Papatya Yayinlik.
- Uguz, S. (2019). *Teoreticheskie aspekty mashinnogo obucheniya i primeneniya na Python: Shkola iskusstvennogo intellekta* (1-e izd.). Ankara: Nobel Yayinlik.
- Gecmez, A., & Gencer, C. (2021). Prognozirovaniye proizvodstva vetrovoy energii s ispolzovaniem ANN i ANFIS. V *IEEE 9th International Conference on Smart Grid (icSmartGrid)*, 29 iyunya – 1 iyulya 2021.
- Elmas, C. (2003). *Iskusstvennye neyronnye seti (teoriya, arkhitektura, obuchenie, primeneniye)*. Ankara: Seckin Yayinlik.
- Sahan, M., & Okur, Y. (2016). Prognozirovaniye solnechnoy energii dlya regiona Sredizemnomorya s ispolzovaniem iskusstvennykh neyronnykh setey na osnove meteodannykh. *SDU Journal of Science (E-Journal)*, 11(1), 61–67.
- Fausett, L. (1994). *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. New York: Prentice Hall.
- Gok, A. O., Yildiz, C., & Sekelli, M. (2019). Prognozirovaniye kratkosrochnogo proizvodstva solnechnoy energii s ispolzovaniem ANN: primer provintsii Kahramanmarash. *Uluslararası Dogu Anadolu Fen Muhendislik ve Tasarim Dergisi*, 1(2), 186–195.
- Kalogirou, S. A. (2000). Primeneniye iskusstvennykh neyronnykh setey v energeticheskikh sistemakh. *Applied Energy*, 67, 17–35.

Авторлар туралы мәліметтер
Информация об авторах
Information about authors

№	Информация об авторах (Ф.И.О. полностью, ученая степень, место работы или учебы, город, страна, E-mail, сотовый номер автора корреспондента:) на казахском, русском, английском языках
1	<p>Айтен Гечмез – докторант <i>Университет Фырат, Институт наук, Программа «Технология электротехники и электроники», Элязыг, Турция</i></p> <p>Айтен Гечмез – докторант кафедры электротехнической и электронной инженерии, Институт науки, Университет Фират, Элязыг, Турция</p> <p>Ayten Gecmez – Doctoral Student of the Department of Electrical and Electronic Engineering, Institute of Science, Firat University, Elazig, Turkey</p> <p>E-mail: aytengecmez@gmail.com</p> <p>ORCID:0000-0002-1388-2554</p>
2	<p>Калимбетова Жансая Сейдахановна – Электр инженериясы кафедрасының техникалық ғылымдар магистрі, Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ., Қазақстан</p> <p>Калимбетова Жансая Сейдахановна – магистр технических наук кафедры Электро инженерия, Международный казахско-турецкий университет им. Ходжи Ахмеда Ясави, г. Туркестан, Казахстан</p> <p>Kalimbetova Zhansaya Seydahanovna - master of technical sciences, Ahmet Yassawi University , Turkestan, Kazakhstan</p> <p>E-mail: zhansaya.kalimbetova@ayu.edu.kz</p> <p>ORCID: 0009-0001-2900-2507</p> <p>87718059955</p>
3	<p>Четин Генчер - Электроинженерия кафедрасының доценті, Инженерия факультеті, Халықаралық қазақ-түрік университеті. Қожа Ахмет Ясауи, Түркістан қ., Қазақстан</p> <p>Четин Генчер – доцент кафедры Электроинженерии, факультет Инженерия, Международный казахско-турецкий университет им. Ходжи Ахмеда Ясави, г. Туркестан, Казахстан</p> <p>Çetin Gençer - Associate Professor of the Department of Electrical Engineering, Faculty of Engineering, International Kazakh-Turkish University named after Khoja Ahmed Yasawi, Turkestan, Kazakhstan</p> <p>E-mail: cetin.gencer@ayu.edu.kz</p> <p>ORCID:0000-0002-1716-0516</p>
4	<p>Айнур Севинч - Компьютерлік Технологиялар факультетінің докторанты, Сильвания кәсіптік мектебі, Дикле университеті, Диярбакыр, Түркия</p> <p>Айнур Севинч – докторант факультета компьютерных технологий, Сильванское профессиональное училище, Университет Дикле, Диярбакыр, Турция</p> <p>Aynur Sevinc - Doctoral Student, Faculty of Computer Technology, Sylvan Vocational College, Dicle University, Diyarbakir, Turkey</p> <p>E-mail: aynur.sevinc@dicle.edu.tr</p> <p>ORCID:0000-0002-7519-1134</p>

МАЗМҰНЫ

АҚПАРАТТЫҚ ТЕХНОЛОГИЯЛАР ЖӘНЕ ЖАСАНДЫ ИНТЕЛЛЕКТ

Г.Н. КАЗБЕКОВА, Ә.Ж. ОҒҒАР

КӘСІПТІК КОЛЛЕДЖДЕГІ ОҚУ КЕСТЕСІН ИНТЕЛЛЕКТУАЛДЫ АВТОМАТТАНДЫРУ:
OR-TOOLS/ILP ЖӘНЕ LLM АССИСТЕНТІНІҢ ГИБРИДТІ МОДЕЛІ _____ 5-15

Е.У. СЕРДАЛИЕВ, Н.Т. ТОЙЛЫБАЕВА, Б.О. БАЙМУРЗАЕВ, Х. ЧАКЫР

КОМПЬЮТЕРЛІК КӨРУ ЖӘНЕ ТЕРЕҢ ОҚЫТУ МОДЕЛЬДЕРІ НЕГІЗІНДЕ ФИЗИКАЛЫҚ
ЖАТТЫҒУЛАРДЫ НАҚТЫ УАҚЫТ РЕЖИМІНДЕ БАҚЫЛАУДЫҢ КОНЦЕПТУАЛДЫҚ
НЕГІЗДЕРІ _____ 16-29

Б.А. АБДУВАХАПОВ, Н.М. ЖУНИСОВ, А.Т. БАЯЛЫ, А.С. БАЙМАХАНОВА

ОҚУ ЖОСПАРЫНЫҢ РӨЛІ ЖӘНЕ СТУДЕНТТЕР ҮЛГЕРІМІН КРІ МЕН Z-SCORE
НЕГІЗІНДЕ ТАЛДАУ _____ 30-38

Д.С. АСАН, А.Н. АМАНОВ

ЖАТТЫҒУ ҚОЗҒАЛЫСТАРЫН КОМПЬЮТЕРЛІК КӨРУ КӨМЕГІМЕН ТАЛДАУ ЖӘНЕ
ТИІМДІЛІГІН БАҒАЛАУ _____ 39-49

ИНЖЕНЕРЛІК ТЕХНОЛОГИЯЛАР, ЭНЕРГЕТИКА ЖӘНЕ АВТОМАТТАНДЫРУ

О.Д.МЕИРБЕКОВА, Н.Т.РУСТАМОВ

СУ АККУМУЛЯТОРЫ БАР БИОГАЗБЕН ЖҰМЫС ІСТЕЙТІН ГИБРИДТІ
ГАЗТУРБИНАЛЫҚ ҚОНДЫРҒЫНЫ ЗЕРТТЕУ _____ 50-60

А. ГЕЧМЕЗ, Ж. КАЛИМБЕТОВА, Ч. ГЕНЧЕР, А. СЕВИНЧ

ЖАСАНДЫ НЕЙРЛІК ЖЕЛІЛЕРДІ ЖӘНЕ АДАПТИВТІ АНЫҚ ЕМЕС ЖЕЛІЛЕРДІ (ANFIS)
ПАЙДАЛАНА ОТЫРЫП, ЖЕЛ ЭНЕРГИЯСЫН ӨНДІРУДІ БАҒАЛАУ _____ 61-75

МАЗМҰНЫ

_____ 76-78

CONTENT

INFORMATION TECHNOLOGIES AND ARTIFICIAL INTELLIGENCE

G.N. KAZBEKOVA, A.J. ONGAR

INTELLIGENT AUTOMATION OF A VOCATIONAL COLLEGE TIMETABLE: A HYBRID MODEL OF OR-TOOLS/ILP AND AN LLM ASSISTANT _____ 5-15

Y.U. SERDALIYEV, N.T. TOILYBAYEVA, B.O. BAYMURZAEV, H. CAKIR

CONCEPTUAL FOUNDATIONS OF REAL-TIME MONITORING OF PHYSICAL EXERCISES BASED ON COMPUTER VISION AND DEEP LEARNING MODELS _____ 16-29

B.A. ABDUVAKHAPOV, N.M. ZHUNISSOV, A.T. BAYALY, A.S. BAIMAKHANOVA

THE ROLE OF CURRICULUM IN STUDENT PERFORMANCE ANALYSIS USING KPI AND Z-SCORE _____ 30-38

D.S. ASAN, A.N. AMANOV

ANALYSIS OF TRAINING MOVEMENTS USING COMPUTER VISION AND EVALUATION OF THEIR EFFECTIVENESS _____ 39-49

ENGINEERING TECHNOLOGIES, ENERGY AND AUTOMATION

O.D.MEIRBEKOVA, N.T. RUSTAMOV

INVESTIGATION OF A BIOGAS HYBRID GAS TURBINE PLANT WITH A WATER BATTERY _____ 50-60

A. GEÇMEZ, ZH. KALIMBETOVA, Ç. GENÇER, A. SEVINÇ

ESTIMATION OF WIND ENERGY PRODUCTION BY ARTIFICIAL NEURAL NETWORKS AND ADAPTIVE NETWORK BASED FUZZY INFERENCE SYSTEM _____ 61-75

CONTENT _____ 76-78

СОДЕРЖАНИЕ

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ

Г.Н. КАЗБЕКОВА, Э.Ж. ОҒҒАР

ИНТЕЛЛЕКТУАЛЬНАЯ АВТОМАТИЗАЦИЯ УЧЕБНОГО РАСПИСАНИЯ В ПРОФЕССИОНАЛЬНОМ КОЛЛЕДЖЕ: ГИБРИДНАЯ МОДЕЛЬ OR-TOOLS/ILP И LLM-АССИСТЕНТА _____ 5-15

Е.У. СЕРДАЛИЕВ, Н.Т. ТОЙЛЫБАЕВА, Б.О. БАЙМУРЗАЕВ, Х. ЧАКЫР

КОНЦЕПТУАЛЬНЫЕ ОСНОВЫ МОНИТОРИНГА ФИЗИЧЕСКИХ УПРАЖНЕНИЙ В РЕАЛЬНОМ ВРЕМЕНИ НА ОСНОВЕ МОДЕЛЕЙ КОМПЬЮТЕРНОГО ЗРЕНИЯ И ГЛУБОКОГО ОБУЧЕНИЯ _____ 16-29

Б.А. АБДУВАХАПОВ, Н.М. ЖУНИСОВ, А.Т. БАЯЛЫ, А.С. БАЙМАХАНОВА

РОЛЬ УЧЕБНОГО ПЛАНА И АНАЛИЗ УСПЕВАЕМОСТИ СТУДЕНТОВ НА ОСНОВЕ КР1 И Z-SCORE _____ 30-38

Д.С. АСАН, А.Н. АМАНОВ

АНАЛИЗ ТРЕНИРОВОЧНЫХ ДВИЖЕНИЙ С ИСПОЛЬЗОВАНИЕМ КОМПЬЮТЕРНОГО ЗРЕНИЯ И ОЦЕНКА ИХ ЭФФЕКТИВНОСТИ _____ 39-49

ИНЖЕНЕРНЫЕ ТЕХНОЛОГИИ, ЭНЕРГЕТИКА И АВТОМАТИЗАЦИЯ

О.Д. МЕИРБЕКОВА, Н.Т. РУСТАМОВ

ИССЛЕДОВАНИЕ БИОГАЗОВОЙ ГИБРИДНОЙ ГАЗОТУРБИННОЙ УСТАНОВКИ С ВОДЯНЫМ АККУМУЛЯТОРОМ _____ 50-60

А. ГЕЧМЕЗ, Ж. КАЛИМБЕТОВА, Ч. ГЕНЧЕР, А. СЕВИНЧ

ОЦЕНКА ПРОИЗВОДСТВА ВЕТРОВОЙ ЭНЕРГИИ С ПОМОЩЬЮ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ И АДАПТИВНОЙ НЕЧЕТКОЙ СИСТЕМЫ НА ОСНОВЕ СЕТИ (ANFIS) _____ 61-75

СОДЕРЖАНИЕ _____ 76-78

YASSAWI JOURNAL OF ENGINEERING SCIENCE

Редакцияның мекен-жайы:

*161200, Қазақстан Республикасы, Түркістан қаласы,
Б. Саттарханов даңғылы, 29В
Байланыс тетіктері: +7 701 234 8885, +7 775 323 2299*

E-mail: journal.engineering@ayu.edu.kz

Ғылыми редакторлар:

Жунисов Н.М.

Техникалық редактор: Абдразах Ы. Қ.

Жарияланған мақала авторларының пікірі редакция көзқарасын білдірмейді.

Мақала мазмұнына автор жауап береді.

Қолжазбалар өңделеді және авторларға қайтарылмайды.

Yassawi Journal of Engineering Science журналына жарияланған материалдарды сілтемесіз көшіріп басуға болмайды.

31.03.2026 ж. баспаға жіберілді

*Журнал Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университетінің
«Тұран» баспаханасында көбейтілді.*

Қағаздың пішімі: 70x100. Қағазы офсеттік А4.

Офсеттік басылым. Шартты баспа табағы 6.

Таралымы 110 дана. Тапсырыс 145.