



"IN THE WORLD OF SCIENCE AND EDUCATION"

international scientific-practical journal

ALMATY, KAZAKHSTAN

ISSN: 3007-8946

15 MARCH 2026



els.education23@mail.ru



irc-els.com

**МЕЖДУНАРОДНЫЙ НАУЧНЫЙ ЖУРНАЛ
«IN THE WORLD OF SCIENCE AND EDUCATION»**

**INTERNATIONAL SCIENTIFIC JOURNAL
«IN THE WORLD OF SCIENCE AND EDUCATION»**



Main editor: G. Shulenbaev

Editorial colleague:

B. Kuspanova
Sh Abyhanova

International editorial board:

R. Stepanov (Russia)
T. Khushruz (Uzbekistan)
A. Azizbek (Uzbekistan)
F. Doflat (Azerbaijan)

International scientific journal «IN THE WORLD OF SCIENCE AND EDUCATION», includes reports of scientists, students, undergraduates and school teachers from different countries (Kazakhstan, Tajikistan, Azerbaijan, Russia, Uzbekistan, China, Turkey, Belarus, Kyrgyzstan, Moldova, Turkmenistan, Georgia, Bulgaria, Mongolia). The materials in the collection will be of interest to the scientific community for further integration of science and education.

Международный научный журнал «IN THE WORLD OF SCIENCE AND EDUCATION», включают доклады учёных, студентов, магистрантов и учителей школ из разных стран (Казахстан, Таджикистан, Азербайджан, Россия, Узбекистан, Китай, Турция, Беларусь, Кыргызстан, Молдавия, Туркменистан, Грузия, Болгария, Монголия). Материалы сборника будут интересны научной общественности для дальнейшей интеграции науки и образования.

15 марта 2026 г.
Almaty, Kazakhstan

<https://doi.org/10.5281/zenodo.19230076>

МӘТІНДІК ДЕРЕКТЕРДІ ТАЛДАУ ДӘЛДІГІН АРТТЫРУ МАҚСАТЫНДА МАШИНАЛЫҚ ОҚЫТУ МОДЕЛЬДЕРІН АНСАМБЛЬДЕУ ӘДІСТЕРІН ЗЕРТТЕУ ЖӘНЕ ӘЗІРЛЕУ

ЕРБОЛАТ НҰРЖОЛ

Satbayev University

Ақпараттық технологиялар факультеті

Программалық инженерия кафедрасы

1 курс докторанты

***Аңдатпа.** Қазіргі ақпараттық қоғамда мәтіндік деректердің көлемі қарқынды түрде өсуде. Әлеуметтік желілер, жаңалықтар порталдары, ғылыми жарияланымдар және электрондық құжаттар үлкен көлемдегі мәтіндік ақпараттың негізгі көздері болып табылады. Мұндай деректерді тиімді өңдеу мен талдау табиғи тілдерді өңдеу технологиялары мен машиналық оқыту әдістеріне негізделеді. Дегенмен жеке машиналық оқыту модельдері күрделі мәтіндік құрылымдарды талдау кезінде әрдайым жоғары дәлдік көрсете бермейді. Осыған байланысты бірнеше модельдердің нәтижелерін біріктіруге негізделген ансамбльдеу әдістерін қолдану зерттеудің маңызды бағыты болып отыр. Бұл мақалада мәтіндік деректерді талдау дәлдігін арттыру мақсатында машиналық оқыту модельдерін ансамбльдеу әдістерін зерттеу мәселесі қарастырылады. Ансамбльдеу әдістерінің негізгі түрлері талданып, олардың мәтінді жіктеу міндетіндегі тиімділігі сипатталады. Сонымен қатар мәтіндік деректерді өңдеу кезеңдері мен ансамбль модельдерін қолданудың зерттеу әдістемесі ұсынылады.*

***Кілт сөздер:** мәтіндік деректер, машиналық оқыту, ансамбльдеу әдістері, табиғи тілдерді өңдеу, мәтінді жіктеу, модель дәлдігі.*

Ақпараттық технологиялардың қарқынды дамуы нәтижесінде әлемде өндірілетін деректер көлемі жыл сайын өсіп келеді. Бұл деректердің үлкен бөлігі мәтіндік форматта сақталады. Мәтіндік деректер ғылыми мақалаларда, жаңалықтар порталдарында, әлеуметтік желілерде, электрондық хаттарда және корпоративтік ақпараттық жүйелерде кеңінен кездеседі. Осындай үлкен көлемдегі мәтіндік деректерді тиімді өңдеу мен талдау қазіргі таңда ғылым мен өндірістің маңызды мәселелерінің біріне айналды. Мәтіндік деректерді автоматты түрде өңдеу табиғи тілдерді өңдеу (Natural Language Processing) және машиналық оқыту әдістері арқылы жүзеге асырылады. Бұл технологиялар мәтінді жіктеу, тақырыптық талдау, пікірді анықтау, ақпаратты іздеу және мәтін генерациясы сияқты көптеген міндеттерді шешуге мүмкіндік береді. Машиналық оқыту модельдері мәтіндегі заңдылықтарды анықтап, жаңа деректерге қатысты болжам жасау қабілетіне ие. Дегенмен тәжірибеде бір ғана модельге негізделген тәсілдер күрделі мәтіндік құрылымдарды талдау кезінде кейбір шектеулерге ие болады. Әртүрлі модельдер деректердің әртүрлі сипаттамаларын жақсы үйренуі мүмкін. Сондықтан бірнеше модельдердің нәтижелерін біріктіру арқылы жүйенің жалпы өнімділігін арттыруға болады. Мұндай тәсіл ансамбльдеу әдістері деп аталады. Ансамбльдеу әдістері машиналық оқыту саласында кеңінен қолданылатын тәсілдердің бірі болып табылады. Бұл әдістер бірнеше модельдердің нәтижелерін біріктіру арқылы қателіктерді азайтып, болжам дәлдігін арттыруға мүмкіндік береді. Әсіресе мәтіндік деректерді жіктеу және талдау міндеттерінде ансамбльдеу әдістерін қолдану тиімді нәтиже көрсетеді. Осы зерттеудің мақсаты – мәтіндік деректерді талдау дәлдігін арттыру мақсатында машиналық оқыту модельдерін ансамбльдеу әдістерін зерттеу және оларды қолданудың тиімді тәсілдерін қарастыру.

Мәтіндік деректер қазіргі цифрлық ортада ең кең таралған деректер түрлерінің бірі болып табылады. Интернеттегі жаңалықтар, әлеуметтік желілердегі пікірлер, электрондық

пошталар, ғылыми мақалалар және әртүрлі құжаттар мәтіндік деректердің негізгі көздерін құрайды. Мұндай деректердің басты ерекшелігі – олардың құрылымдалмаған түрде болуы. Яғни мәтіндер белгілі бір кестелік немесе сандық форматта емес, табиғи тілде жазылған ақпарат ретінде сақталады. Осыған байланысты мәтіндік деректерді машиналық оқыту әдістері арқылы талдау үшін оларды алдын ала өңдеу және сандық форматқа түрлендіру қажет[1]. Мәтіндік деректерді өңдеу бірнеше кезеңнен тұрады және бұл кезеңдер мәтіндік ақпаратты тиімді талдау үшін маңызды рөл атқарады. Бірінші кезең – мәтінді тазалау (text cleaning). Бұл кезеңде мәтін құрамындағы қажетсіз символдар, тыныс белгілерінің артық элементтері, HTML белгілері, сандар және басқа да талдауға әсер етпейтін элементтер алынып тасталады. Мәтінді тазалау деректер сапасын арттыруға және алгоритмдердің жұмысын жеңілдетуге мүмкіндік береді. Келесі маңызды кезең – токенизация. Токенизация процесі мәтінді жеке элементтерге, яғни сөздерге немесе сөз тіркестеріне бөлуге негізделеді. Бұл кезең мәтінді құрылымдауға және кейінгі өңдеу қадамдарын жүзеге асыруға мүмкіндік береді. Токенизациядан кейін мәтіннің семантикалық маңыздылығын төмендететін жиі қолданылатын сөздерді алып тастау жүзеге асырылады. Мұндай сөздер стоп-сөздер деп аталады. Мысалы, көптеген тілдерде «және», «мен», «бір», «осы» сияқты сөздер жиі кездескенімен, олар мәтіннің негізгі мазмұнын анықтауда маңызды рөл атқара бермейді.

Кесте 1 – Мәтінді векторлау әдістері

Әдіс	Сипаттамасы
Bag of Words	Мәтіндегі сөздердің жиілігін есептеу
TF-IDF	Сөздердің құжаттағы маңыздылығын анықтау
Word Embedding	Сөздерді көпөлшемді векторлар арқылы көрсету

TF-IDF әдісі мәтіндік деректерді талдауда жиі қолданылатын тәсілдердің бірі болып табылады. Бұл әдіс мәтіндегі сөздердің құжат үшін маңыздылығын анықтауға мүмкіндік береді. Мәтінді өңдеудің тағы бір маңызды кезеңі – лемматизация немесе стемминг[2]. Бұл процесте сөздер бастапқы немесе түбір формасына келтіріледі. Мысалы, «оқыту», «оқытылды», «оқытушы» сияқты сөздердің түбірі «оқы» сөзімен байланысты. Мұндай өңдеу мәтіндегі сөздердің әртүрлі грамматикалық формаларын біріктіруге және деректер өлшемін азайтуға мүмкіндік береді. Мәтіндік деректерді машиналық оқыту модельдерімен талдау үшін оларды сандық форматқа түрлендіру қажет. Бұл процесс векторизация немесе мәтінді сандық ұсыну деп аталады. Ең кең таралған әдістердің бірі – Bag of Words моделі. Бұл әдіс мәтіндегі сөздердің жиілігін есептеу арқылы мәтінді сандық вектор ретінде көрсетуге мүмкіндік береді. Сонымен қатар TF-IDF (Term Frequency – Inverse Document Frequency) әдісі мәтіндегі сөздердің маңыздылық деңгейін анықтауға мүмкіндік береді. TF-IDF тәсілі жиі кездесетін, бірақ барлық құжаттарда бірдей қолданылатын сөздердің әсерін азайтып, нақты мәтін үшін маңызды сөздерді анықтауға көмектеседі. Соңғы жылдары мәтінді ұсынудың анағұрлым күрделі әдістері – сөздік эмбеддингтер кеңінен қолданыла бастады. Word embedding әдістері сөздердің семантикалық ұқсастықтарын ескеріп, оларды көпөлшемді векторлық кеңістікте көрсетеді. Мұндай тәсілдер мәтіндегі контекстік байланыстарды жақсырақ анықтауға мүмкіндік береді. Мәтіндік деректерді талдаудың тағы бір маңызды ерекшелігі – деректердің жоғары өлшемділігі. Әдетте мәтіндік деректерде қолданылатын сөздер саны өте көп болады, бұл модельдердің есептеу күрделілігін арттыруы мүмкін. Сондықтан кейбір жағдайларда өлшемділікті азайту әдістері де қолданылады. Жалпы алғанда, мәтіндік деректерді өңдеу мен талдау көп кезеңді процесс болып табылады және әрбір кезең нәтижелердің дәлдігіне тікелей әсер етеді. Деректерді дұрыс өңдеу машиналық оқыту модельдерінің тиімділігін арттырып, мәтіндік ақпаратты сапалы талдауға мүмкіндік береді. Машиналық оқыту модельдері – деректерден заңдылықтарды автоматты түрде анықтауға және жаңа деректер бойынша болжам жасауға мүмкіндік беретін

алгоритмдер жиынтығы. Қазіргі таңда машиналық оқыту әдістері мәтіндік деректерді талдау, суреттерді тану, сөйлеуді өңдеу және ұсыныс жүйелерін құру сияқты көптеген салаларда кеңінен қолданылады[3]. Мәтіндік деректерді талдау міндеттерінде машиналық оқыту модельдері мәтіннің мазмұнын, тақырыбын немесе эмоциялық реңкін анықтау үшін пайдаланылады. Машиналық оқыту модельдері негізінен бақыланатын оқыту (supervised learning), бақылаусыз оқыту (unsupervised learning) және жартылай бақыланатын оқыту (semi-supervised learning) сияқты негізгі тәсілдерге бөлінеді. Бақыланатын оқыту әдістерінде модель алдын ала белгіленген деректер жиыны арқылы үйретіледі. Мұндай деректерде әрбір мәтін белгілі бір категориямен немесе белгімен байланыстырылған болады. Ал бақылаусыз оқыту әдістерінде деректерде нақты белгілер болмайды, модель деректердің ішкі құрылымын өздігінен анықтауға тырысады. Мәтіндік деректерді талдау барысында жиі қолданылатын машиналық оқыту модельдерінің бірі – Naive Bayes алгоритмі. Бұл әдіс ықтималдық теориясына негізделген және мәтінді жіктеу міндеттерінде жоғары жылдамдықпен жұмыс істейді. Naive Bayes алгоритмі сөздердің бір-бірінен тәуелсіздігі туралы болжамға негізделгенімен, тәжірибеде мәтіндік деректерді жіктеуде тиімді нәтиже көрсете алады[4].

Кесте 2 – Мәтіндік талдауда қолданылатын негізгі модельдер

Модель	Ерекшелігі
Naive Bayes	Мәтінді жіктеуде жылдам жұмыс істейді
Logistic Regression	Жіктеу міндеттерінде кеңінен қолданылады
Support Vector Machine	Жоғары өлшемді деректерде тиімді
Random Forest	Көп шешім ағаштарын біріктіреді
Нейрондық желілер	Күрделі үлгілерді анықтай алады

Кеңінен қолданылатын тағы бір модель – Logistic Regression. Бұл модель негізінен бинарлық немесе көпклассты жіктеу міндеттерін шешуге арналған. Logistic Regression мәтіндегі белгілердің салмақтарын анықтап, белгілі бір категорияға жату ықтималдығын есептейді. Модельдің артықшылығы – оның түсіндірмесінің салыстырмалы түрде қарапайым болуы және үлкен деректер жиындарында тұрақты жұмыс істеуі. Мәтіндік деректерді талдауда жиі қолданылатын тағы бір алгоритм – Support Vector Machine (SVM). Бұл әдіс жоғары өлшемді деректермен тиімді жұмыс істеу қабілетімен ерекшеленеді. SVM алгоритмі деректерді әртүрлі кластарға бөлетін оңтайлы шекараны анықтауға негізделеді. Мәтіндік деректерде қолданылатын белгілер саны көп болғандықтан, бұл модель жиі жоғары дәлдік көрсетеді. Сонымен қатар Random Forest моделі де мәтіндік талдау міндеттерінде қолданылады. Бұл әдіс бірнеше шешім ағаштарын біріктіру арқылы жұмыс істейді. Әрбір шешім ағашы деректердің әртүрлі бөліктерінде оқытылады, ал соңғы шешім барлық ағаштардың нәтижелерін біріктіру арқылы қабылданады. Random Forest модельдерінің артықшылығы – олардың шамадан тыс үйренуге (overfitting) төзімді болуы. Соңғы жылдары мәтіндік деректерді талдауда нейрондық желілерге негізделген модельдер кеңінен қолданыла бастады. Мұндай модельдер күрделі үлгілер мен контекстік байланыстарды анықтауға мүмкіндік береді. Сондықтан мәтіндік деректерді талдауда бірнеше модельдердің нәтижелерін біріктіру, яғни ансамбльдеу әдістерін қолдану жүйенің жалпы тиімділігін арттырудың маңызды тәсілі болып табылады[5].

Ансамбльдеу әдістері (ensemble methods) – машиналық оқыту саласында бірнеше модельдердің нәтижелерін біріктіру арқылы біртұтас және анағұрлым дәл болжам жасауға бағытталған тәсілдер жиынтығы. Бұл әдістердің негізгі идеясы – бір ғана модельге сүйенудің орнына әртүрлі модельдердің болжамдарын біріктіру арқылы жүйенің жалпы өнімділігін

арттыру. Практикада жеке модельдердің әрқайсысы деректердің белгілі бір ерекшеліктерін жақсы меңгереді, бірақ барлық жағдайларда бірдей жоғары нәтиже көрсете бермейді. Ал бірнеше модельдің нәтижелерін біріктіру арқылы қателіктерді азайтып, болжамның тұрақтылығын арттыруға болады. Ансамбльдеу тәсілдері машиналық оқытуда кеңінен қолданылады және олар әсіресе мәтіндік деректерді жіктеу, суреттерді тану және болжамдық талдау сияқты күрделі міндеттерде тиімді нәтиже береді. Бұл әдіс модельдің вариациясын азайтуға және болжамның тұрақтылығын арттыруға көмектеседі. Bagging әдісінің ең танымал мысалдарының бірі – Random Forest алгоритмі. Random Forest көптеген шешім ағаштарын біріктіру арқылы жұмыс істейді және күрделі деректер жиындарын талдауда тиімді нәтиже көрсетеді.

Кесте 3 – Ансамбльдеу әдістерін салыстыру

Әдіс	Негізгі идея	Артықшылығы
Bagging	Кездейсоқ деректер жиындары	Вариацияны азайтады
Boosting	Қателіктерді біртіндеп түзету	Дәлдік жоғары
Stacking	Бірнеше модель нәтижесін біріктіру	Икемділік жоғары

Ансамбльдеу әдістерінің тағы бір маңызды түрі – boosting. Boosting тәсілінде модельдер бірінен кейін бірі кезектесіп оқытылады. Әрбір жаңа модель алдыңғы модельдің жіберген қателіктеріне көбірек назар аударады. Нәтижесінде жүйе қиын немесе дұрыс жіктелмеген деректерді жақсырақ үйренеді. Boosting әдістерінің кең таралған мысалдарына AdaBoost, Gradient Boosting және XGBoost алгоритмдері жатады. Бұл тәсілдер көптеген машиналық оқыту жарыстарында жоғары нәтижелер көрсеткен. Үшінші маңызды ансамбльдеу тәсілі – stacking. Stacking әдісінде бірнеше базалық модельдер параллель түрде оқытылады. Кейін олардың болжамдары арнайы мета-модельге беріледі. Мета-модель базалық модельдердің нәтижелерін талдап, соңғы шешімді қабылдайды. Бұл тәсіл әртүрлі алгоритмдердің артықшылықтарын біріктіруге мүмкіндік береді және кейбір жағдайларда жеке модельдерге қарағанда жоғары дәлдік көрсетеді[6].

Жүргізілген зерттеу барысында мәтіндік деректерді талдау дәлдігін арттыруда машиналық оқыту модельдерін қолданудың маңыздылығы қарастырылды. Мәтіндік деректердің құрылымдалмаған сипатта болуы оларды өңдеу мен талдауды күрделендіретіні анықталды. Осыған байланысты мәтінді алдын ала өңдеу, токенизация, стоп-сөздерді жою және мәтінді сандық форматқа түрлендіру сияқты кезеңдердің мәтіндік талдауда маңызды рөл атқаратыны көрсетілді. Сонымен қатар мәтіндік деректерді талдау барысында қолданылатын негізгі машиналық оқыту модельдері сипатталып, олардың артықшылықтары мен шектеулері талданды. Бір ғана модель барлық жағдайларда жоғары дәлдік көрсете бермейтіндіктен, бірнеше модельдердің нәтижелерін біріктіру қажеттілігі туындайды. Осы тұрғыда ансамбльдеу әдістерінің маңызы ерекше екендігі анықталды. Зерттеу барысында ансамбльдеу тәсілдерінің негізгі түрлері – bagging, boosting және stacking әдістері қарастырылып, олардың мәтіндік деректерді талдаудағы тиімділігі сипатталды. Бұл әдістер бірнеше модельдердің нәтижелерін біріктіру арқылы болжам дәлдігін арттыруға және модельдердің тұрақтылығын жақсартуға мүмкіндік береді. Жалпы алғанда, машиналық оқыту модельдерін ансамбльдеу мәтіндік деректерді талдаудың тиімділігін арттырудың перспективалы бағыты болып табылады. Болашақта нақты мәтіндік деректер жиындары негізінде ансамбль модельдерінің өнімділігін тәжірибелік тұрғыда зерттеу және оларды жетілдіру мәтіндік талдау жүйелерінің сапасын арттыруға мүмкіндік береді.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

1. Әбдіқадыров А., Тұрғынбаев Ә. Ақпараттық жүйелер және деректерді өңдеу технологиялары. – Алматы: Білім, 2018. – 298 б.
2. Сейітқазиев А. Машиналық оқыту негіздері. – Алматы: TechPress, 2021. – 320 б.
3. Садықова Ж., Бекенова Г. Цифрлық білім беру технологиялары. – Алматы: Эверо, 2022. – 256 б.
4. Балапанов Е., Бөрібаев Б., Дәулетқұлов А. Жаңа ақпараттық технологиялар. – Алматы: Білім, 2016. – 400 б.
5. Қасымов М. Деректер ғылымы және үлкен деректер технологиялары. – Алматы: Қазақ университеті, 2021. – 340 б.
6. Ахметова Г., Төлегенов Е. Компьютерлік лингвистика негіздері. – Алматы: Білім, 2020. – 270 б.

<https://doi.org/10.5281/zenodo.19230107>
УДК 004.8

ЖАСАНДЫ ИНТЕЛЛЕКТ: ҚАЗІРГІ ДАМУ ҮРДІСТЕРІ МЕН ЖАҒАНДЫҚ ЫҚПАЛЫ

БАЙМАХАНОВА АЙГУЛЬ БЕКМОЛДАЕВНА

Қазақстан-Ресей медициналық университеті, Қоғамдық пәндер кафедрасының аға оқытушысы, педагогика ғылымдарының магистрі, Алматы қ., Қазақстан

АҚТАН БОТАГОЗ РАҚАТҚЫЗЫ

Қазақстан-Ресей медициналық университеті, Қоғамдық пәндер кафедрасының оқытушысы, физика магистрі, Алматы қ., Қазақстан

***Аңдатпа.** Бұл мақалада жасанды интеллект (ЖИ) технологияларының қазіргі даму деңгейі, негізгі бағыттары және олардың экономика, білім беру, денсаулық сақтау салаларына ықпалы қарастырылады. Сонымен қатар, ЖИ жүйелерінің этикалық мәселелері мен болашақтағы даму перспективалары талданады. Мақалада ЖИ технологияларының экономикалық тиімділігі, инновациялық әлеуеті және еңбек нарығына әсері қарастырылып, деректер қауіпсіздігі, алгоритмдік әділдік және құқықтық реттеу мәселелері қозғалады. Сонымен қатар, халықаралық ынтымақтастық пен жауапты даму қағидаларының маңыздылығы негізделеді. Зерттеу нәтижелері ЖИ-дің жаһандық трансформация құралы ретінде стратегиялық рөл атқаратынын және оны тиімді басқару заманауи қоғам дамуының басты шарттарының бірі екенін көрсетеді.*

***Түйін сөздер:** жасанды интеллект, машиналық оқыту, нейрондық желілер, автоматтандыру, цифрлық трансформация.*

Кіріспе

Қазіргі кезеңде ғылым мен техниканың қарқынды дамуы қоғамның барлық салаларына жаңа технологияларды енгізуді талап етуде. Осындай маңызды технологиялардың бірі – жасанды интеллект. Жасанды интеллект – адамның интеллектуалдық қызметін модельдеуге бағытталған ақпараттық технологиялар жиынтығы. Ол деректерді талдау, шешім қабылдау, үйрену және болжау сияқты күрделі процестерді автоматты түрде орындауға мүмкіндік береді. Соңғы он жылдықта жасанды интеллект технологиялары ерекше қарқынмен дамып келеді. Бұл үрдіс цифрлық экономиканың қалыптасуымен, үлкен деректердің пайда болуымен және есептеу қуатының артуымен байланысты. Жасанды интеллект қазіргі таңда өндіріс, медицина, білім беру, қаржы, көлік және мемлекеттік басқару салаларында кеңінен қолданылып отыр. Жасанды интеллекттің дамуы әлемдік экономиканың құрылымына да үлкен өзгерістер енгізуде. Сарапшылардың пікірінше, алдағы жылдары көптеген кәсіпорындар өндірістік процестерді автоматтандырып, жасанды интеллект жүйелерін кеңінен қолданатын болады. Бұл еңбек нарығының өзгеруіне, жаңа мамандықтардың пайда болуына және цифрлық экономиканың дамуына ықпал етеді.

Осыған байланысты жасанды интеллекттің қазіргі даму үрдістерін зерттеу және оның жаһандық ықпалын талдау ғылыми тұрғыдан өзекті мәселелердің бірі болып табылады.

Жасанды интеллект – бұл қазіргі заманның ең маңызды технологияларының бірі. Ол біздің өмірімізге терең еніп, түрлі салаларда инновациялар мен жетілдірулер әкелуде.

Жасанды интеллект (Artificial Intelligence, AI) – компьютерлік жүйелердің адам интеллектісіне тән функцияларды (үйрену, талдау, шешім қабылдау, тіл түсіну) орындау қабілеті. Соңғы онжылдықта есептеу қуатының артуы, үлкен деректердің (Big Data) қолжетімділігі және алгоритмдердің жетілдірілуі ЖИ саласының қарқынды дамуына мүмкіндік берді. OpenAI, DeepMind және Google AI сияқты жетекші ғылыми ұйымдар ЖИ модельдерін дамытуда маңызды рөл атқаруда.

Жасанды интеллект (ЖИ) – адамның ойлау, үйрену және шешім қабылдау қабілеттерін модельдеуге бағытталған ғылым саласы. Оның дамуы бірнеше тарихи кезеңдерден өтті.

Бұл зерттеуде ғылыми талдау, салыстырмалы талдау, жүйелік талдау және әдебиеттерді шолу әдістері қолданылды. Ғылыми әдебиеттерді талдау арқылы жасанды интеллекттің теориялық негіздері қарастырылды. Сонымен қатар халықаралық ғылыми мақалалар мен зерттеу нәтижелері зерттеліп, қазіргі технологиялық үрдістер анықталды.

Салыстырмалы талдау әдісі арқылы жасанды интеллекттің түрлі салалардағы қолданылуы зерттелді. Мысалы, медицина, білім беру және өндіріс салаларындағы технологиялық мүмкіндіктер салыстырылды.

Жүйелік талдау әдісі жасанды интеллекттің қоғамдағы рөлін кешенді түрде бағалауға мүмкіндік берді. Бұл әдіс технологияның экономикалық, әлеуметтік және ғылыми аспектілерін біртұтас жүйе ретінде қарастыруға көмектесті. Зерттеу барысында статистикалық деректер мен халықаралық ұйымдардың есептері де пайдаланылды.

Сала	Технологиялық мүмкіндіктер	Қолдану мысалдары	Артықшылықтары
Медицина	Медициналық деректерді талдау, диагноз қою, ауруларды болжау, роботтандырылған хирургия	Медициналық суреттерді (рентген, МРТ) талдау, ауруларды ерте анықтау, телемедицина	Диагностиканың дәлдігін арттырады, дәрігердің жұмысын жеңілдетеді, ауруларды ерте анықтауға мүмкіндік береді
Білім беру	Интеллектуалды оқу платформалары, автоматты бағалау жүйелері, виртуалды оқыту ассистенттері	Онлайн білім беру платформалары, адаптивті оқу жүйелері, чат-боттар	Оқытуды жекелеңдіреді, білім сапасын арттырады, студенттердің білім деңгейін талдауға мүмкіндік береді
Өндіріс	Өндірістік процестерді автоматтандыру, интеллектуалды роботтар, өндірісті басқару жүйелері	Өнеркәсіптік роботтар, сапаны автоматты бақылау, логистикалық жүйелер	Өндіріс тиімділігін арттырады, шығындарды азайтады, қауіпті жұмыстарды автоматтандырады

Салыстырмалы талдау

Медицина саласында жасанды интеллект негізінен диагностика мен медициналық талдауға бағытталған.

Білім беру саласында ол оқу процесін жекелеңдіру мен білімді бағалауды автоматтандыруға көмектеседі.

Өндіріс саласында жасанды интеллект автоматтандыру мен робототехника арқылы өндіріс тиімділігін арттыруға қолданылады.

Жалпы алғанда, бұл үш салада жасанды интеллект технологияларының басты мақсаты – процестердің тиімділігін арттыру, ақпаратты жылдам өңдеу және адам еңбегін жеңілдету болып табылады.

Зерттеу барысында статистикалық деректер мен халықаралық ұйымдардың есептері де кеңінен пайдаланылды. Әсіресе, әлемдік технологиялық даму деңгейін бағалау үшін халықаралық ұйымдардың ресми статистикасы мен аналитикалық есептері талданды.

Мысалы, World Economic Forum жариялаған есептерде жасанды интеллект технологияларының жаһандық еңбек нарығына әсері қарастырылып, алдағы жылдары көптеген жаңа цифрлық мамандықтардың пайда болатыны атап көрсетілген. Ұйымның

зерттеулеріне сәйкес, автоматтандыру мен цифрлық технологиялардың дамуы нәтижесінде кейбір дәстүрлі мамандықтар қысқарғанымен, жаңа технологиялық бағыттарда жұмыс орындарының саны артады.

Сонымен қатар, Organisation for Economic Co-operation and Development ұсынған мәліметтерде жасанды интеллекттің экономикадағы рөлі, инновациялық даму деңгейі және цифрлық трансформация процестері талданады. Бұл есептерде жасанды интеллект технологиялары өнімділікті арттыруға және экономикалық өсуді жеделдетуге мүмкіндік беретіні көрсетілген.

Ал UNESCO жариялаған зерттеулерде жасанды интеллекттің білім беру жүйесіне ықпалы қарастырылған. Аталған ұйымның деректеріне сәйкес, интеллектуалды білім беру платформалары оқыту процесін жекелендіруге және білім сапасын арттыруға мүмкіндік береді.

Сонымен бірге, International Data Corporation және Statista сияқты халықаралық зерттеу орталықтарының статистикалық деректері де пайдаланылды. Бұл ұйымдардың есептері жасанды интеллект технологияларына инвестиция көлемінің жыл сайын өсіп келе жатқанын және көптеген мемлекеттердің цифрлық экономикаға көшу процесін жеделдетіп жатқанын көрсетеді.

Осы статистикалық деректер мен халықаралық ұйымдардың аналитикалық есептері зерттеу нәтижелерінің ғылыми негізділігін арттыруға және жасанды интеллекттің қазіргі даму үрдістерін жан-жақты талдауға мүмкіндік берді.

Жасанды интеллект (ЖИ) қазіргі заманғы ғылыми зерттеулердің ең қарқынды дамып келе жатқан бағыттарының бірі болып табылады. Соңғы онжылдықта жасанды интеллектке қатысты ғылыми жарияланымдардың саны айтарлықтай артты. Бұл технологиялардың дамуы есептеу қуатының өсуімен, үлкен деректердің (Big Data) пайда болуымен және жаңа алгоритмдердің жасалуымен тығыз байланысты. Ғылыми әдебиеттерді талдау жасанды интеллекттің теориялық негіздері мен қолдану салаларының кең ауқымын қамтитынын көрсетеді.

Жасанды интеллекттің теориялық негіздерін зерттеген еңбектердің бірі – Stuart Russell және Peter Norvig авторлығымен жазылған Artificial Intelligence: A Modern Approach еңбегі. Бұл кітапта жасанды интеллекттің негізгі ұғымдары, логикалық модельдер, машиналық оқыту әдістері және интеллектуалды жүйелердің архитектурасы жан-жақты қарастырылған. Авторлар жасанды интеллектті адамның интеллектуалдық қызметін модельдеуге бағытталған алгоритмдер мен жүйелердің жиынтығы ретінде сипаттайды.

Жасанды интеллекттің маңызды бағыттарының бірі – машиналық оқыту және терең оқыту технологиялары. Бұл бағытта Ian Goodfellow, Yoshua Bengio және Aaron Courville авторлығымен жазылған Deep Learning ғылыми еңбегі ерекше орын алады. Бұл зерттеуде нейрондық желілердің теориялық негіздері, терең оқыту алгоритмдері және олардың компьютерлік көру, сөйлеуді тану және мәтінді өңдеу салаларындағы қолданылуы қарастырылған. Авторлардың пікірінше, терең оқыту технологиялары жасанды интеллекттің қазіргі даму кезеңіндегі негізгі технологиялық драйверлердің бірі болып табылады.

Экономикалық және әлеуметтік аспектілер тұрғысынан жасанды интеллекттің ықпалын зерттеген жұмыстардың ішінде Erik Brynjolfsson және Andrew McAfee авторларының The Second Machine Age еңбегін атап өтуге болады. Бұл еңбекте цифрлық технологиялардың, соның ішінде жасанды интеллекттің, экономикалық өсімге, еңбек нарығына және өндірістік процестерге әсері талданады. Авторлар жаңа технологиялардың өндіріс тиімділігін арттыратынын, бірақ сонымен қатар еңбек нарығында құрылымдық өзгерістерге әкелуі мүмкін екенін көрсетеді.

Жасанды интеллекттің бизнес және басқару салаларындағы мүмкіндіктерін зерттеген ғылыми жұмыстар да бар. Мысалы, Thomas Davenport және Rajeev Ronanki жасанды интеллекттің ұйымдардың қызметіне ықпалын зерттеп, интеллектуалды жүйелердің басқару шешімдерін қабылдау процесін жетілдіруге мүмкіндік беретінін атап өтеді. Олардың

пікірінше, жасанды интеллект деректерді талдау арқылы стратегиялық шешімдердің сапасын арттырады және компаниялардың бәсекеге қабілеттілігін күшейтеді.

Білім беру саласында жасанды интеллекттің қолданылуы да ғылыми зерттеулердің маңызды бағыттарының бірі болып табылады. Зерттеулер көрсеткендей, интеллектуалды оқыту жүйелері оқу процесін жекелендіруге мүмкіндік береді. Мұндай жүйелер студенттердің білім деңгейін талдап, оқу материалдарын жеке қажеттіліктеріне сәйкес ұсына алады. Сонымен қатар, табиғи тілдерді өңдеу технологиялары негізінде құрылған чат-боттар мен виртуалды ассистенттер білім беру процесінде кеңінен қолданылуда.

Медицина саласындағы ғылыми зерттеулер жасанды интеллекттің ауруларды ерте диагностикалауда және медициналық деректерді талдауда үлкен мүмкіндіктерге ие екенін көрсетеді. Медициналық суреттерді талдау, генетикалық деректерді зерттеу және клиникалық шешім қабылдау жүйелері жасанды интеллекттің маңызды қолдану бағыттарының бірі болып табылады. Кейбір зерттеулерде жасанды интеллект жүйелері рентген немесе томография нәтижелерін талдауда жоғары дәлдік көрсететіні атап өтіледі.

Сонымен қатар, жасанды интеллекттің этикалық және құқықтық аспектілерін қарастыратын ғылыми жұмыстар да көп. Кейбір зерттеушілер жасанды интеллект жүйелерінің дамуы деректер қауіпсіздігі, алгоритмдік әділеттілік және жеке өмірді қорғау сияқты мәселелерді туындататынын атап көрсетеді. Осыған байланысты халықаралық ұйымдар мен ғылыми қауымдастық жасанды интеллект технологияларын жауапкершілікпен дамытуға бағытталған қағидаларды қалыптастыруда.

Жалпы алғанда, ғылыми әдебиеттерді талдау жасанды интеллекттің қазіргі қоғамның көптеген салаларына әсер ететін кешенді технология екенін көрсетеді. Зерттеулердің басым бөлігі жасанды интеллекттің экономикалық тиімділікті арттыруға, ғылыми зерттеулердің сапасын жақсартуға және инновациялық технологиялардың дамуына ықпал ететінін дәлелдейді. Сонымен қатар, көптеген авторлар жасанды интеллекттің болашақтағы дамуы оның қауіпсіз және этикалық қолданылуына байланысты екенін атап өтеді.

Жасанды интеллектті жүйелік талдау оның құрылымын, негізгі элементтерін, өзара байланыстарын және қоғамның түрлі салаларына ықпалын кешенді түрде қарастыруға мүмкіндік береді. Жүйелік талдау әдісі жасанды интеллектті біртұтас технологиялық жүйе ретінде зерттеуге негізделеді. Бұл тәсіл жасанды интеллекттің құрылымдық элементтерін, олардың функцияларын және жүйенің жалпы тиімділігіне әсерін анықтауға мүмкіндік береді.

Жасанды интеллект жүйесі бірнеше негізгі компоненттерден тұрады. Біріншіден, деректер (data) жасанды интеллект жүйесінің негізгі ресурсы болып табылады. Деректер жүйеге ақпарат беріп, машиналық оқыту алгоритмдерінің жұмыс істеуіне мүмкіндік жасайды. Үлкен деректерді өңдеу технологиялары жасанды интеллект жүйелерінің тиімділігін арттыруға және күрделі аналитикалық есептерді шешуге мүмкіндік береді.

Екіншіден, алгоритмдер мен модельдер жасанды интеллекттің негізгі жұмыс механизмін құрайды. Машиналық оқыту алгоритмдері деректерді талдап, белгілі бір заңдылықтарды анықтайды. Нейрондық желілер мен терең оқыту модельдері күрделі есептерді шешуге мүмкіндік береді. Бұл модельдер суреттерді тану, сөйлеуді өңдеу және мәтінді талдау сияқты процестерде кеңінен қолданылады. Үшіншіден, есептеу инфрақұрылымы жасанды интеллект жүйелерінің жұмыс істеуі үшін қажетті техникалық негіз болып табылады. Жоғары өнімді серверлер, бұлттық технологиялар және графикалық процессорлар (GPU) үлкен көлемдегі деректерді өңдеуге мүмкіндік береді. Бұл инфрақұрылым жасанды интеллект жүйелерінің жылдамдығы мен тиімділігін арттырады. Төртіншіден, қолданбалы жүйелер мен интерфейстер жасанды интеллекттің нақты практикалық қолданылуын қамтамасыз етеді. Бұл жүйелер пайдаланушыларға интеллектуалды технологияларды түрлі салаларда қолдануға мүмкіндік береді. Мысалы, медицинада диагностикалық жүйелер, білім беруде интеллектуалды оқу платформалары, ал өндірісте автоматтандырылған басқару жүйелері қолданылады.

Жүйелік талдау нәтижесінде жасанды интеллекттің қоғамның түрлі салаларымен тығыз байланысты екені анықталады. Мысалы, медицина саласында жасанды интеллект диагностикалық жүйелердің дәлдігін арттырады және медициналық деректерді талдауды жеңілдетеді. Білім беру саласында интеллектуалды платформалар оқу процесін жекелеңдіруге мүмкіндік береді. Ал өндіріс саласында робототехника мен автоматтандыру технологиялары өндіріс тиімділігін арттырады.

Сонымен қатар жүйелік талдау жасанды интеллекттің дамуымен байланысты бірқатар мәселелерді де анықтайды. Олардың қатарына деректер қауіпсіздігі, алгоритмдердің әділеттілігі, технологиялық тәуелділік және еңбек нарығындағы өзгерістер жатады. Сондықтан жасанды интеллект жүйелерін дамыту барысында этикалық және құқықтық нормаларды ескеру маңызды.

Қорытынды

Жасанды интеллект – ХХІ ғасырдың стратегиялық технологиясы. Ол экономиканың барлық салаларына еніп, қоғам дамуына ықпал етуде. Дегенмен, оның тиімді әрі қауіпсіз қолданылуы үшін этикалық қағидалар мен құқықтық реттеу тетіктерін жетілдіру қажет.

ЖИ-дің болашағы – адам мүмкіндігін кеңейту мен инновациялық прогрестің жаңа кезеңін қалыптастыру. Жасанды интеллект – болашағымыздың технологиясы. Оның дамуы мен қолданылуы біздің өміріміздің жақсартуға және инновацияларға жол ашады. Біздің міндетіміз – бұл технологияны жақсы мақсаттарға пайдалану және этика мен қауіпсіздік мәселелеріне назар аудару.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

1. Stuart Russell, Peter Norvig. Artificial Intelligence: A Modern Approach. – 4th ed. – Pearson Education, 2021.
2. Ian Goodfellow, Yoshua Bengio, Aaron Courville. Deep Learning. – MIT Press, 2016.
3. Erik Brynjolfsson, Andrew McAfee. The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies. – New York: W.W. Norton & Company, 2018.
4. Thomas Davenport, Rajeev Ronanki. Artificial Intelligence for the Real World. – Harvard Business Review, 2018.
5. World Economic Forum. The Future of Jobs Report. – Geneva, 2023.
6. Organisation for Economic Co-operation and Development. Artificial Intelligence in Society. – OECD Publishing, Paris, 2022.
7. UNESCO. Recommendation on the Ethics of Artificial Intelligence. – Paris, 2021.
8. International Data Corporation. Worldwide Artificial Intelligence Spending Guide. – IDC, 2023.
9. Statista. Global Artificial Intelligence Market Size Statistics. – 2024.
10. McKinsey & Company. The State of AI Report. – 2023.

<https://doi.org/10.5281/zenodo.19230138>
УДК 621.31:004.9

ПРЕДИКТИВНЫЙ ЭНЕРГОМЕНЕДЖМЕНТ В ПРОМЫШЛЕННОСТИ: ИНТЕГРАЦИЯ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ В АРХИТЕКТУРУ SMART ENERGY

САУХАНОВА МЕЙРАМГУЛ ТАЛҒАТҚЫЗЫ

студент технического факультета АРУ имени К. Жубанова

Научный руководитель – СЕМЕНИХИН В.В.

Актобе, Казахстан

Аннотация: В статье предложена система предиктивного энергоменеджмента на базе IoT и нейросетей LSTM для промышленного сектора. Разработанный алгоритм позволяет выравнивать график нагрузки, снижая пиковое потребление. На примере завода ЖБИ доказано снижение пиковой мощности на 14,5%, что обеспечивает чистую экономию 4,2 млн тенге в год. Срок окупаемости системы составляет 3 месяца.

Ключевые слова: Предиктивный энергоменеджмент, алгоритмы машинного обучения, архитектура Smart Energy, промышленный интернет вещей (IIoT), нейросетевое прогнозирование, сглаживание графиков нагрузки, концепция Smart Grid, нейросети LSTM, механизм Load Shifting, снижение пиковой мощности, цифровизация энергохозяйства, срок окупаемости.

В условиях устойчивого роста тарифов на энергоносители классические методы энергосбережения достигли предела своей экономической эффективности. На базе многоуровневой архитектуры промышленного интернета вещей (IIoT) и нейросетевого прогнозирования обоснована возможность сглаживания графиков электрической нагрузки. Предложенная математическая модель демонстрирует снижение операционных затрат предприятия на 15–20% исключительно за счет алгоритмической оптимизации диспетчеризации оборудования [1].

Финансовые издержки производств формируются не только за счет оплаты потребленной энергии, но и вследствие штрафных санкций за превышение лимитов заявленной мощности. Традиционные системы АСКУЭ обладают существенным недостатком — они реализуют ретроспективный анализ. При этом качество поставляемой энергии должно строго соответствовать государственным стандартам, что усложняет процесс локального регулирования без автоматизации [4]. В связи с этим возникает необходимость внедрения концепции Smart Grid для проактивного выравнивания суточного профиля энергопотребления.

Для реализации предиктивного энергоменеджмента требуется внедрение комплексной трехуровневой информационно-измерительной архитектуры:

Полевой уровень (Hardware & IIoT): В узлах учета устанавливаются цифровые многофункциональные анализаторы параметров сети (например, на базе чипов с поддержкой True RMS). Данные снимаются с измерительных трансформаторов тока и напряжения. Передача информации от щитов идет по помехозащищенному интерфейсу RS-485 (протокол Modbus RTU) на промышленные контроллеры (ПЛК).

Полевой уровень не ограничивается исключительно сбором данных с измерительных трансформаторов. Для физической реализации алгоритмов смещения нагрузки (Load Shifting) и ограничения пиковой мощности требуется интеграция программируемых логических контроллеров с силовой электроникой предприятия. В качестве основных исполнительных механизмов для компрессорных и насосных станций предлагается применение преобразователей частоты серии ESQ-A500. Данное оборудование позволяет не

только осуществлять плавный пуск электродвигателей, минимизируя пусковые токи, но и поддерживает протоколы промышленной связи для бесшовной интеграции в общую SCADA-систему по интерфейсу RS-485 представленный в рисунке 1.

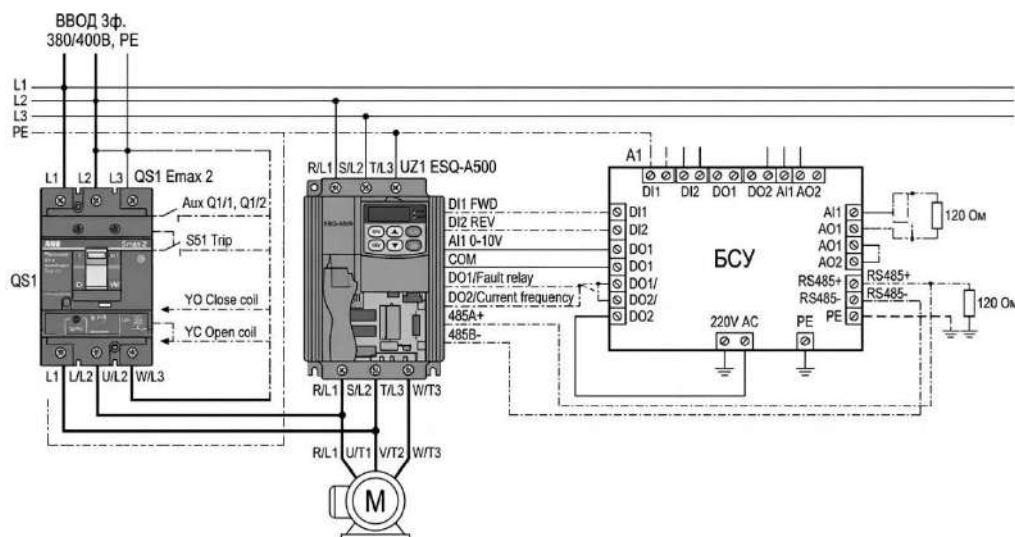


Рис. 1. Схема трехуровневой информационно-измерительной архитектуры Smart Energy на базе IoT и нейросетевого прогнозирования.

Критически важным аспектом при проектировании архитектуры Smart Energy является обеспечение бесконфликтной работы интеллектуальных алгоритмов с существующими устройствами релейной защиты. Предиктивный энергоменеджмент функционирует в нормальных эксплуатационных режимах и не должен блокировать или замедлять работу терминалов РЗА при возникновении токов короткого замыкания или иных аварийных режимов. Для этого на программном уровне вводится жесткая иерархия приоритетов: команды от систем противоаварийной автоматики имеют безусловный приоритет над командами оптимизации энергопотребления от нейросетевого модуля.

Сетевой уровень (Edge & Cloud): IoT-шлюзы собирают массивы данных и по легковесному протоколу MQTT отправляют их на локальный сервер или в облако. Частота опроса достигает 1 раза в секунду, формируя так называемые Time-Series Data (временные ряды)[2].

Основой для эффективной работы нейросетевых алгоритмов является достоверность исходных данных. Для обеспечения требуемой пропускной способности каналов связи и высокой точности измерений на уровне главного распределительного щита (ГРЩ) предприятия целесообразно применение интеллектуальных воздушных автоматических выключателей (в частности, аппаратов уровня ABB Emax 2 или их современных аналогов). Данные коммутационные аппараты оснащены встроенными микропроцессорными расцепителями, которые способны не только выполнять базовые функции защиты от токов короткого замыкания и перегрузки, но и выступать в роли полноценных терминалов сбора данных (IoT-сенсоров).

Интеграция таких выключателей позволяет передавать параметры электрической сети (действующее значение напряжения, ток, полную мощность, спектр гармоник) напрямую в SCADA-систему по протоколам цифровой подстанции (например, МЭК 61850). Это исключает необходимость монтажа дополнительных измерительных комплексов в цепях цеховых силовых понижающих трансформаторов (например, серии ТМГ), существенно снижая капитальные затраты на цифровизацию энергохозяйства.

Для предварительной верификации предложенных алгоритмов управления и оценки их влияния на качество электрической энергии до этапа физического внедрения, была разработана цифровая модель участка распределительной сети. Моделирование режимов работы электрооборудования (включая учет пусковых характеристик асинхронных двигателей и влияния нелинейной нагрузки) осуществлялось в программной среде MATLAB Simulink.

Использование библиотеки Simscape Electrical позволило синтезировать цифровой двойник (Digital Twin) рассматриваемого производственного цикла. В ходе симуляции было подтверждено, что программное ограничение мощности (перевод компрессорных установок в режим холостого хода) не приводит к недопустимым просадкам напряжения в узлах нагрузки и позволяет поддерживать показатели качества электроэнергии в строгом соответствии с действующими нормативными требованиями.

Уровень принятия решений (AI & SCADA): Математическое ядро системы. Нейросеть (используются рекуррентные архитектуры вроде LSTM, отлично работающие с временными рядами) анализирует профиль потребления. Алгоритм понимает: если в 08:00 начинается разогрев печей, включение мощных систем принудительной вентиляции нужно программно заблокировать или перенести на 08:30. Происходит выравнивание графика нагрузки (Load Shifting)[3].

Для обоснования экономической эффективности мы должны учитывать структуру многоставочного тарифа. Общие затраты предприятия на электроэнергию описываются функцией:

$$C_{total} = \Sigma(P(t) \cdot c_e(t)) + P_{max} \cdot c_p + C_{react}$$

Где:

$P(t)$ — профиль потребления активной мощности;

$c_e(t)$ — ставка тарифа за электроэнергию в конкретной тарифной зоне (день/ночь/пик);

P_{max} — максимальная зафиксированная получасовая мощность;

c_p — ставка за содержание электрической мощности;

C_{react} — надбавка (штраф) за низкий коэффициент мощности ($\cos \varphi$).

Функционирование алгоритмов Smart Energy направлено на минимизацию значения C_{total} . Экономический эффект от алгоритмического срезания пиков рассчитывается следующим образом:

$$E_{save} = \sum_{t=1}^n (P_{baseline}(t) - (P_{smart}(t)) \cdot c_e(t) + (P_{max_baseline} - (P_{max_smart})) \cdot c_p$$

При этом суммарное потребление электроэнергии в кВт·ч может оставаться неизменным. Экономия достигается за счет смещения потребления в зоны с более низкой тарифной ставкой и принудительного снижения пиковой мощности (P_{max})[1].

В качестве объекта исследования рассмотрен типовой производственный цикл завода железобетонных изделий (ЖБИ). Основными потребителями электрической мощности на объекте выступают бетоносмесительные узлы (БСУ) и компрессорные станции.

Анализ показал, что при ручном управлении пусковые токи БСУ систематически накладывались на рабочий цикл винтовых компрессоров, что приводило к формированию экстремального пика потребления. Внедрение алгоритма предиктивного контроля позволило интегрировать ПЛК компрессоров с системой интеллектуального управления.

Механизм регулирования: За 30 секунд до пуска БСУ система автоматически переводит компрессорные установки в режим холостого хода (разгрузки), опираясь на показания

датчиков давления в ресивере. После выхода БСУ на номинальный режим работы компрессоры возвращаются в штатный режим.

Результаты: Абсолютное потребление активной электроэнергии не претерпело значительных изменений, однако зафиксировано снижение пиковой электрической нагрузки предприятия на 14,5%.

Экономическая эффективность: За счет снижения платежей за заявленную мощность чистая экономия составила 4,2 млн тенге в год. Капитальные затраты на внедрение IoT-инфраструктуры составили 1,1 млн тенге, что обеспечило расчетный срок окупаемости (Payback Period) на уровне 3 месяцев.

В ходе исследования было установлено, что резкие пуски асинхронных двигателей бетоносмесительных узлов (БСУ) вызывают кратковременные просадки напряжения, негативно влияющие на работу чувствительной микропроцессорной техники цеха. Внедрение предиктивного алгоритма позволило не только снизить пиковую активную мощность P_{max} , но и оптимизировать работу автоматических конденсаторных установок (УКРМ). Система, прогнозируя пуск БСУ за 30 секунд, заблаговременно корректирует ступени компенсации, поддерживая коэффициент мощности ($\cos \varphi$) на уровне 0,96–0,98. Это минимизирует потери в цеховых трансформаторах (типа ТМГ) и исключает риск возникновения резонансных явлений, вызванных высшими гармониками от преобразователей частоты.

Архитектура Smart Energy решает задачи не только по сглаживанию графиков активной нагрузки (Load Shifting), но и по непрерывному мониторингу качества электроэнергии. Режимы работы тяжелых асинхронных электродвигателей, применяемых на бетоносмесительных узлах и дробильных установках, сопровождаются значительным потреблением реактивной мощности и, как следствие, снижением коэффициента мощности ($\cos \varphi$). Внедряемая нейросетевая модель способна прогнозировать моменты резкого наброса индуктивной нагрузки. Опираясь на этот прогноз, система интеллектуального энергоменеджмента заблаговременно формирует управляющие сигналы на превентивное включение ступеней установок компенсации реактивной мощности (УКРМ). Такой проактивный подход позволяет исключить глубокие просадки напряжения в распределительной сети завода в пусковых режимах оборудования и полностью нивелировать коммерческие штрафы за генерацию реактивной энергии в питающую сеть.

Критическим фактором внедрения облачных технологий (Cloud) в промышленную энергетику является зависимость от стабильности каналов связи. Для исключения риска остановки технологического процесса при потере соединения с центральным сервером, в архитектуре Smart Energy реализуется принцип граничных вычислений (Edge Computing).

Внедрение распределенных интеллектуальных систем в контур управления промышленным энергопотреблением неизбежно сопряжено с возникновением специфических рисков, которые требуют детального рассмотрения:

Риски нарушения информационной безопасности:

Использование открытых протоколов передачи данных (например, MQTT без должного шифрования) создает потенциальную уязвимость для несанкционированного доступа к управлению графиками нагрузки. Кибератака на алгоритм прогнозирования может привести к искусственному созданию пиковых нагрузок, провоцирующих срабатывание устройств релейной защиты и необоснованную остановку технологических линий. Для нивелирования данного риска необходимо внедрение систем обнаружения вторжений (IDS) и сегментация промышленной сети управления от офисной сети предприятия.

Технологические риски потери связности:

Зависимость системы от стабильности каналов связи между полевым уровнем (сенсорами) и уровнем принятия решений (сервером AI) может стать критической точкой отказа. В случае обрыва связи система может «зависнуть» в последнем заданном состоянии. Решением является реализация алгоритмов Edge Computing, при которых локальные

контроллеры переходят на жестко заданные резервные расписания при потере сигнала от центрального узла.

Риск деградации точности прогнозных моделей:

Математическое ядро системы, базирующееся на нейросетях LSTM, критично к качеству входящих данных. При резком изменении номенклатуры выпускаемой продукции или замене парка станков (изменении профиля нагрузки) точность прогноза может снизиться. Это требует внедрения механизмов автоматического дообучения модели (Online Learning) на актуальных выборках данных для предотвращения ошибок в расчетах (P_{max}).

Электромагнитная совместимость (ЭМС):

Работа мощных преобразователей частоты, являющихся исполнительными механизмами Smart Energy, сопровождается генерацией высших гармоник в сеть. Это может негативно влиять на точность измерений самих же IoT-датчиков. Обеспечение требований ГОСТ по качеству электроэнергии требует обязательной установки входных и выходных сетевых дросселей, а также экранирования кабельных трасс интерфейса RS-485 для исключения наводок.

Промышленные контроллеры (Edge-шлюзы), установленные непосредственно в цехах, хранят локальную копию упрощенной предиктивной модели и суточных расписаний. В случае обрыва связи верхнего уровня автоматика переходит на автономный режим работы, продолжая управлять частотными преобразователями и контакторами по заранее рассчитанному суточному градиенту нагрузки, тем самым гарантируя бесперебойность производственного цикла и сохранение противоаварийных блокировок.

В условиях промышленных помех и возможных перебоев в работе внешних каналов связи, архитектура Smart Energy дополняется уровнем граничных вычислений. Использование локальных Edge-шлюзов позволяет обрабатывать до 70% телеметрической информации непосредственно на объекте, транслируя в облако только агрегированные тренды. Это гарантирует сохранение работоспособности предиктивных алгоритмов и выполнение блокировок пуска энергоемкого оборудования даже при временном отсутствии связи с центральным сервером управления.

Цифровизация энергохозяйства представляет собой фундаментальный инженерный инструмент повышения рентабельности промышленного производства. Интеграция алгоритмов машинного обучения и протоколов IIoT позволяет предприятиям осуществить переход от реактивного учета к проактивному управлению энергопотреблением [2]. В условиях современного конкурентного рынка предприятия, не внедряющие автоматизированные системы управления графиками нагрузки, подвергаются риску существенного снижения рентабельности вследствие высокой энергетической составляющей в себестоимости выпускаемой продукции.

Кроме того, масштабное внедрение протоколов промышленного интернета вещей (IIoT) требует проведения дополнительных исследований в области информационной безопасности энергообъектов. Дальнейшее развитие предложенной системы предиктивного энергоменеджмента будет направлено на разработку защищенных шлюзов передачи данных, исключающих возможность несанкционированного киберфизического вмешательства в процесс диспетчеризации промышленного оборудования.

Дальнейшее развитие предложенной системы Smart Energy видится в создании единого цифрового двойника (Digital Twin) энергосистемы предприятия, позволяющего моделировать аварийные режимы без риска для реального оборудования. При этом критически важным аспектом остается обеспечение кибербезопасности IIoT-протоколов, так как несанкционированный доступ к управлению графиками нагрузки может привести к нарушению технологического регламента производства.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Кобелев, А. В. Интеллектуальные системы управления электропотреблением на промышленных предприятиях / А. В. Кобелев, И. С. Коновалов. — Москва : Энергоатомиздат, 2021. — 256 с.
2. Герасимов, Д. Н. Промышленный интернет вещей (IIoT) в задачах энергосбережения : учебное пособие / Д. Н. Герасимов. — Санкт-Петербург : Изд-во СПбГЭТУ «ЛЭТИ», 2022. — 112 с.
3. Иванов, К. С. Применение рекуррентных нейронных сетей для краткосрочного прогнозирования графиков электрической нагрузки / К. С. Иванов // Автоматизация в промышленности. — 2024. — № 2. — С. 15–19.
4. ГОСТ Р 54149-2010. Электрическая энергия. Совместимость технических средств электромагнитная. Нормы качества электрической энергии в системах электроснабжения общего назначения. — Москва : Стандартинформ, 2012. — 20 с.

<https://doi.org/10.5281/zenodo.19230167>
УДК 006.915.2

**РАСЧЕТ НЕОПРЕДЕЛЕННОСТИ ИЗМЕРЕНИЙ ПРИ КАЛИБРОВКЕ
ПОРТАТИВНОГО ЦИФРОВОГО МУЛЬТИМЕТРА В УСТАНОВЛЕННОЙ ТОЧКЕ
ДИАПАЗОНА В АСТАНИНСКОМ ФИЛИАЛЕ АО «НАЦИОНАЛЬНЫЙ ЦЕНТР
ЭКСПЕРТИЗЫ И СЕРТИФИКАЦИИ»**

АКИМЖАНОВА ДАНИЯ РАШИДОВНА

Магистрант 2 курса группы М130-«Метрология»
кафедры «Стандартизация, сертификация и метрология»
Евразийского национального университета имени Л.Н.Гумилева

АБСЕИТОВ ЕРБОЛАТ ТЛЕУСЕИТОВИЧ

Научный руководитель, кандидат технических наук, ассоциированный профессор

***Аннотация.** В статье рассматриваются вопросы оценки неопределенности измерений при калибровке портативного цифрового мультиметра в установленной точке диапазона. Актуальность темы обусловлена возрастающими требованиями к точности и надежности измерений в различных областях науки, промышленности и технической диагностики. В современных метрологических практиках обеспечение достоверности результатов измерений невозможно без корректной оценки неопределенности, которая является количественной характеристикой разброса значений, приписываемых измеряемой величине. Правильное определение неопределенности позволяет объективно оценивать точность измерительных приборов и повышает доверие к полученным результатам измерений.*

Целью исследования является определение неопределенности измерений при калибровке портативного цифрового мультиметра в установленной точке диапазона, а также анализ основных факторов, оказывающих влияние на точность измерений. Исследование проведено на базе Астанинского филиала АО «Национальный центр экспертизы и сертификации», где выполняются работы по метрологическому обеспечению средств измерений. В рамках исследования была рассмотрена процедура калибровки портативного цифрового мультиметра при подаче входного напряжения постоянного тока величиной 100 В с использованием многофункционального калибратора в качестве рабочего эталона.

В работе описана методика проведения измерений, включающая соединение выходных клемм калибратора с входными клеммами мультиметра, установку заданного значения напряжения и последующую регистрацию показаний прибора после стабилизации измерительной системы. Полученные значения используются для определения отклонения показаний мультиметра относительно эталонного значения. Для оценки точности измерений была составлена измерительная модель, позволяющая определить отклонение показаний исследуемого прибора на основе разности между измеренным и действительным значениями напряжения.

Особое внимание в работе уделено анализу источников неопределенности измерений. К основным источникам неопределенности были отнесены неопределенность эталонного калибратора, конечное разрешение индикации мультиметра, возможный дрейф характеристик калибратора со времени последней калибровки, влияние температуры окружающей среды, нестабильность напряжения сети и особенности настройки измерительной системы. Поскольку измерения выполнялись однократно, оценка неопределенности проводилась по типу В с использованием данных технических характеристик и спецификаций производителя калибровочного оборудования.

В ходе работы были определены стандартные неопределенности входных величин, после чего была рассчитана суммарная стандартная неопределенность измерений. На основе полученных значений была определена расширенная неопределенность измерений при коэффициенте охвата $k = 2$, соответствующем доверительной вероятности 0,95. Проведенные расчеты показали, что расширенная неопределенность измерений при калибровке портативного цифрового мультиметра составила 0,058 В, что находится в пределах допустимых значений для данного типа измерительных приборов.

Полученные результаты подтверждают, что исследуемый мультиметр обеспечивает требуемую точность измерений при работе в установленной точке диапазона и может быть использован для выполнения измерений в лабораторных и промышленных условиях. Проведенное исследование также показало, что правильная организация процедуры калибровки, регулярный метрологический контроль средств измерений и корректный расчет неопределенности являются важными условиями обеспечения достоверности результатов измерений.

Практическая значимость работы заключается в возможности использования представленной методики оценки неопределенности при калибровке портативных цифровых мультиметров в метрологических лабораториях. Результаты исследования могут быть применены при проведении метрологического контроля средств измерений электрических величин, а также при совершенствовании методик калибровки и повышения точности измерительных процессов.

Ключевые слова: Неопределенность измерений, калибровка средств измерений, портативный цифровой мультиметр, метрологическое обеспечение, точность измерений, измерительная модель, стандартная неопределенность, расширенная неопределенность, калибровочный калибратор, электрические измерения.

Annotation. The article examines the evaluation of measurement uncertainty during the calibration of a portable digital multimeter at a specified point of its measurement range. The relevance of the study is determined by the increasing requirements for the accuracy and reliability of measurements in various fields such as science, industry, and technical diagnostics. In modern metrological practice, ensuring the reliability of measurement results is impossible without the correct assessment of measurement uncertainty, which represents a quantitative characteristic describing the dispersion of values attributed to the measured quantity. Proper determination of uncertainty makes it possible to objectively assess the accuracy of measuring instruments and increases confidence in the obtained measurement results.

The purpose of this study is to determine the measurement uncertainty during the calibration of a portable digital multimeter at a specified range point and to analyze the main factors influencing measurement accuracy. The research was carried out at the Astana branch of the National Center for Expertise and Certification JSC, where activities related to metrological support of measuring instruments are conducted. Within the framework of the study, the calibration procedure of a portable digital multimeter was considered using a 100 V direct current input voltage generated by a multifunction calibrator acting as a working reference standard.

The paper describes the measurement procedure, which includes connecting the output terminals of the calibrator to the input terminals of the multimeter using appropriate measurement leads, setting the calibrator to the required voltage value, and recording the multimeter readings after the stabilization period. The obtained readings are used to calculate the deviation of the multimeter indication relative to the reference value. To evaluate measurement accuracy, a measurement model was developed that allows determining the deviation of the tested instrument based on the difference between the measured and reference voltage values.

Special attention in the study is paid to the analysis of the main sources of measurement uncertainty. The main uncertainty sources include the uncertainty of the reference calibrator, the finite resolution of the multimeter display, the drift of the calibrator characteristics since its last

calibration, environmental temperature variations, instability of the power supply voltage, and the effects related to the adjustment of the measurement system. Since the measurements were performed only once, the uncertainty evaluation was carried out using type B estimation based on the manufacturer's specifications and technical documentation of the calibration equipment.

During the research, the standard uncertainties of input quantities were determined, and the combined standard uncertainty was calculated. Based on the obtained values, the expanded measurement uncertainty was determined using a coverage factor of $k = 2$, corresponding to a confidence level of 95%. The calculations showed that the expanded measurement uncertainty for the calibration of the portable digital multimeter was 0.058 V, which is within the permissible limits for this type of measuring instrument.

The obtained results confirm that the studied multimeter provides the required measurement accuracy at the specified point of the measurement range and can be used for laboratory and industrial measurements. The study also demonstrates that proper calibration procedures, regular metrological control of measuring instruments, and correct uncertainty evaluation are essential for ensuring reliable measurement results.

The practical significance of the study lies in the possibility of applying the proposed uncertainty evaluation methodology in the calibration of portable digital multimeters in metrological laboratories. The results can also be used to improve calibration procedures and enhance the accuracy of measurement processes.

Keywords: *Measurement uncertainty, calibration of measuring instruments, portable digital multimeter, metrological support, measurement accuracy, measurement model, standard uncertainty, expanded uncertainty, calibration calibrator, electrical measurements.*

Неопределенность измерений – это характеристика недостоверности измерений, принятая на международном уровне. Понятие «неопределенность» произошло от английского слова. Неопределенность отражает отсутствие точного знания, другими словами, истинного значения измеряемой величины и выражает сомнение в том, насколько точно результат измерения у представляет значение измеряемой величины.

Источниками неопределенности измерений являются: наблюдаемое рассеивание показаний используемых при измерении средств измерительной техники (обуславливающие стандартные неопределенности типа А) и поправки на не исключенные систематические погрешности (обуславливающие стандартные неопределенности типа В). Кроме того, источниками неопределенности типа В может являться недостоверность используемых справочных данных, округление результатов измерения или применяемых констант. Неопределенность измерений также необходимо учитывать при измерениях показаний мультиметров, что мы и рассмотрим ниже.

Калибровка и точность измерений являются основными требованиями при использовании портативных цифровых мультиметров в различных областях, от научных исследований до повседневного технического обслуживания. Портативные мультиметры, благодаря своей компактности и универсальности, нашли широкое применение для измерения различных электрических величин, таких как напряжение, ток, сопротивление и другие. Однако точность их показаний, особенно в критических областях, требует тщательной проверки и калибровки, с учетом всех факторов, которые могут повлиять на результаты измерений.

Одним из ключевых аспектов калибровки цифрового мультиметра является расчет неопределенности измерений. Неопределенность позволяет оценить возможные погрешности в измерениях и определить пределы точности прибора при работе в определенных условиях [1].

Краткое описание процедуры.

Как часть общей калибровки, портативный цифровой мультиметр (далее - ПЦМ) калибруется при подаче входного напряжения постоянного тока величиной 100 В с

использованием многофункционального калибратора в качестве рабочего эталона. Используется следующая процедура измерения:

- выходные клеммы калибратора соединяются с входными клеммами мультиметра, используя подходящие измерительные провода.
- калибратор устанавливается на 100 В, и после необходимого периода стабилизации снимаются показания.
- отклонение показаний ПЦМ рассчитывается, используя показания ПЦМ и параметры настройки калибратора.

Необходимо отметить, что отклонение показаний ПЦМ, полученное с помощью такой процедуры измерения, включает эффект смещения и отклонение от линейности [2].

Расчет неопределенности.

- Описание измерений и составление его модели:

Отклонение показаний калибруемого мультиметра E_x определяется по формуле, выведенной из абсолютной погрешности мультиметра (разностью значения измеренной и действительной величины):

$$E_x = V_{ix} - V_s + \delta V_{ix} - \delta V_s \quad (1)$$

Основные источники неопределенности:

- V_{ix} – напряжение, показанное мультиметром (индекс i означает показание);
- V_s – напряжение, генерируемое калибратором;
- δV_{ix} – поправка показанного напряжения для конечного разрешения ПЦМ;
- δV_s – поправка напряжения калибратора из-за:
 - его дрейфа со времени последней калибровки;
 - отклонения из-за комбинированного эффекта смещения, нелинейности и разницы коэффициентов усиления;
 - отклонения в температуре окружающей среды;
 - отклонения в напряжении сети;
 - эффекта недостаточно тщательной настройки из-за конечного входного сопротивления калибруемого ПЦМ [3].

Так как не имеется индивидуальных данных, неопределенность измерения, связанную с различными источниками, получают из спецификаций изготовителя калибратора. Эти спецификации устанавливают, что сгенерированное калибратором напряжение совпадает с установленным на калибраторе в пределах $\pm (0,0001V_s + 1 \text{ мВ})$ при соблюдении условий измерения:

- температура окружающей среды лежит в диапазоне от 18 °С до 23 °С;
- напряжение питания сети калибратора находится в диапазоне от 210 В до 250 В;
- сопротивление нагрузки на клеммах генератора более чем 100 кОм;
- время, прошедшее с момента последней калибровки калибратора, не более года.

Так как эти условия измерения выполнены, и практика калибровки калибратора показывает, что на спецификацию изготовителя можно полагаться, поправка, которую нужно применить к сгенерированному калибратором напряжению, принимается 0,0 В в пределах 0,011 В.

Из-за ограниченной разрешающей способности индикации ПЦМ не наблюдалось рассеивания в показываемых значениях.

Стандартные неопределенности входных величин.

Ввиду однократности измерений расчет стандартной неопределенности производится по типу расчета В.

Стандартная неопределенность эталонного прибора $u(V_s)$ равна расширенной неопределенности при нормальном законе распределения, тогда стандартная неопределенность равна расширенной неопределенности, деленной на коэффициент охвата 2, при доверительной вероятности 0,95.

$$u(V_s) = \sqrt{\left(\frac{U}{2}\right)^2} = \sqrt{\left(\frac{0,002}{2}\right)^2} = 0,001 \text{ В}$$

(2)

Отсчет показаний по установке производится с точностью до 0,1 В.

$$u(\delta V_{ix_s}) = \sqrt{\left(\frac{d}{2 \times \sqrt{3}}\right)^2} = \sqrt{\left(\frac{0,1}{3,46}\right)^2} = 0,029 \text{ В}$$

(3)

Поправка напряжения калибратора, учитывающая его дрейф со времени последней калибровки.

$$u(\delta V_s) = \sqrt{\left(\frac{\delta V_s}{\sqrt{3}}\right)^2} = \sqrt{\left(\frac{0,011}{1,73}\right)^2} = 0,064 \text{ В}$$

(4)

Корреляция. Входные величины рассматриваются как некоррелированные.

Суммарная стандартная неопределенность. Суммарную стандартную неопределенность определяют по следующей формуле:

$$u_c = \sqrt{V_s^2 + \delta V_{ix}^2 + \delta V_s^2} = \sqrt{0,001^2 + 0,029^2 + 0,064^2} = \sqrt{0,000001 + 0,000841 + 0,01096} = 0,029 \text{ В}$$

(5)

Расчет расширенной неопределенности

$$U = k \times u_c = 0,029 \times 2 = 0,058 \text{ В}$$

(6)

Предоставление конечного результата [4].

При калибровке портативного цифрового мультиметра в точке диапазона могут возникать следующие основные источники неопределенности:

Погрешности самого прибора - это ошибки, вызванные конструктивными особенностями или техническим состоянием мультиметра. Они могут быть как систематическими, так и случайными.

Погрешности в работе оператора - человеческий фактор играет важную роль в точности измерений. Неправильная интерпретация показаний, ошибки в установке мультиметра на калибровочную точку или недостаточное внимание к нюансам процесса могут влиять на результат.

Влияние внешних условий - температурные колебания, влажность, электромагнитные помехи могут оказывать влияние на точность измерений, особенно если калибровка выполняется в условиях, отличных от стандартных.

Неопределенность калибровочного оборудования - даже если калибровка осуществляется в специализированной лаборатории, необходимо учитывать возможные ошибки, связанные с работой калибровочного оборудования [5].

В процессе калибровки и оценки неопределенности измерений портативных цифровых мультиметров важно учитывать все факторы, которые могут повлиять на точность и воспроизводимость получаемых данных. При проведении таких измерений ключевым элементом является правильный расчет неопределенности, который обеспечивает объективную оценку погрешностей и помогает выработать рекомендации по улучшению точности измерений.

В рамках данного исследования была выполнена калибровка портативного цифрового мультиметра в установленной точке диапазона в Астанинском филиале АО «Национальный центр экспертизы и сертификации». Основной целью работы являлось определение точности измерений мультиметра, а также расчет неопределенности этих измерений с учетом различных факторов, которые могут влиять на результаты. Это важно для обеспечения высокой надежности и точности приборов, используемых в научных и промышленных приложениях, где каждый параметр может иметь значительное значение.

Процесс калибровки включал серию измерений, в ходе которых проводились сравнения показаний мультиметра с эталонными значениями, полученными с помощью высокоточных эталонных приборов. Все измерения фиксировались и анализировались для определения погрешности, а также для выявления возможных отклонений от истинного значения.

Неопределенность измерений была оценена с учетом нескольких факторов. В первую очередь, рассматривались погрешности самого мультиметра, которые могли быть связаны с его техническими характеристиками, а также погрешности, вызванные человеческим фактором, поскольку операторы, проводящие измерения, также могут внести свою долю ошибок. Кроме того, учитывались внешние условия, такие как температура и влажность в лаборатории, которые могут оказывать влияние на точность работы прибора, а также состояние калибровочного оборудования, которое использовалось в процессе измерений.

Расчитанная комбинированная неопределенность составила 0,058, что находится в пределах допустимых значений для данного типа устройства. Это подтверждает, что прибор может быть использован для проведения точных измерений в рамках установленных стандартов. В ходе работы также был сделан вывод о том, что правильное соблюдение процедур калибровки и регулярная проверка состояния приборов являются важными факторами для поддержания их точности и надежности [6].

Таким образом, результаты проведенной работы подтвердили высокую точность работы портативного мультиметра в установленной точке диапазона, что позволяет его использовать в лабораторных и промышленных условиях, при этом необходим периодический контроль и калибровка прибора для поддержания его рабочих характеристик в нужных пределах.

В заключение можно утверждать, что точная и надежная калибровка мультиметров, основанная на тщательном расчете неопределенности, является необходимым условием для достижения высокого уровня доверия к результатам измерений и их дальнейшему применению в научной, промышленной и технической практике [7].

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ:

1. Захаров И. П. Теория неопределенности в измерениях. - Харьков: Консум, 2020, 256 с.
2. Guide to the Expression of Uncertainty in Measurement. - Geneva: ISO, 2021. - 101 p.
3. СТ РК ISO/IEC 17025-2021. Общие требования к компетентности испытательных и калибровочных лабораторий. — Алматы, 2021.
4. СТ РК 8.115–2021. Государственная система обеспечения единства измерений. Порядок калибровки средств измерений. — Алматы, 2021.
5. СТ РК 5376–2021. Средства измерений электрических величин. Общие требования к калибровке. — Алматы, 2021.
6. СТ РК 1371–2021. Метрологическое обеспечение средств измерений в области электричества и электроники. — Алматы, 2021.
7. Ковалев, С. В. Теория измерений и неопределенность измерений. — М.: Издательство МГТУ им. Н. Э. Баумана, 2023.

<https://doi.org/10.5281/zenodo.19230206>

STABILITY-AWARE EXERCISE FORM RECOGNITION USING TEMPORAL POSE FILTERING AND TEMPORAL CONVOLUTIONAL NETWORKS

SERDALIYEV Y.U.

master, Khoja Akhmet Yassawi International kazakh-turkish university,
Kazakhstan, Turkestan

TOILYBAYEVA N.T.

master, Khoja Akhmet Yassawi International kazakh-turkish university,
Kazakhstan, Turkestan

Abstract. *Human pose estimation has become an important tool for automatic analysis of physical exercises in applications such as fitness monitoring, rehabilitation, and remote coaching. Pose-based exercise recognition systems typically rely on sequences of skeletal keypoints extracted from video frames. However, these pose sequences often contain temporal noise and jitter caused by detection instability, occlusions, and environmental variations. Such fluctuations may negatively affect downstream motion analysis and classification models.*

This paper proposes a stability-aware framework for exercise form recognition that combines pose filtering with temporal deep learning. The proposed approach first extracts human pose keypoints using the MediaPipe pose estimation framework. To reduce temporal jitter in the pose trajectories, a OneEuro filter is applied to smooth the keypoint sequences while preserving motion dynamics. Joint angle features are then computed from the filtered pose landmarks and used as input to a Temporal Convolutional Network (TCN) for classification of correct and incorrect exercise execution.

Experiments were conducted on a custom dataset consisting of 200 exercise videos recorded from 10 participants in multiple environments. Two exercises, squat and push-ups, were used for evaluation. Experimental results demonstrate that applying pose filtering improves classification robustness. In particular, for squat exercises the filtered pose features increased the F1-score from 0.00 to 0.67 compared to raw pose sequences.

These findings indicate that temporal pose filtering can significantly enhance the stability and performance of vision-based exercise monitoring systems.

Keywords: *Exercise recognition; Pose estimation; MediaPipe; Temporal Convolutional Network; Pose filtering; Human motion analysis*

1. Introduction

Automatic analysis of human physical exercises has become an important research direction in computer vision and human motion analysis. Such systems are widely used in fitness monitoring, rehabilitation programs, and remote coaching platforms, where automated feedback on exercise execution can improve training effectiveness and reduce the risk of injury. Vision-based approaches are particularly attractive because they allow motion analysis without requiring wearable sensors or specialized equipment. Recent advances in deep learning and human pose estimation have significantly improved the ability to extract human skeletal information from ordinary RGB video sequences [1–3].

Modern pose estimation frameworks such as OpenPose and MediaPipe can detect key human body landmarks and represent human motion as sequences of skeletal keypoints [1–3]. These pose sequences enable various applications including activity recognition, gesture analysis, and sports motion evaluation [4–6]. In particular, pose-based representations have been widely used for automatic exercise recognition and form analysis because they provide a compact and interpretable representation of body movements [7–9].

Despite these advances, pose sequences extracted from video often contain temporal noise and jitter caused by detection instability, occlusions, camera motion, and lighting variations. These fluctuations may significantly affect downstream analysis tasks such as joint angle computation and motion classification [10–12]. As a result, machine learning models trained on raw pose sequences may experience reduced stability and generalization performance when applied to real-world exercise videos.

To address temporal inconsistencies in motion data, several studies have explored the use of temporal models such as recurrent neural networks and convolution-based sequence models for action recognition [13–16]. Among these approaches, Temporal Convolutional Networks (TCNs) have shown strong performance in modeling sequential patterns due to their ability to capture long-range temporal dependencies while maintaining efficient training dynamics [17]. However, most existing exercise recognition systems focus primarily on model architecture while paying limited attention to the stability of the underlying pose sequences.

Another potential solution to the problem of pose instability is the use of temporal filtering methods. Low-pass filters and smoothing techniques can reduce high-frequency noise in pose trajectories while preserving the overall motion dynamics [18]. In particular, the OneEuro filter has been widely used for smoothing noisy input signals and motion tracking data due to its simplicity and efficiency [19]. However, the effect of pose filtering on exercise form recognition has not been sufficiently investigated in existing studies.

In this work, we propose a stability-aware framework for exercise form recognition that integrates pose filtering with temporal deep learning. The proposed approach first extracts human body keypoints using the MediaPipe pose estimation framework. The resulting pose sequences are then smoothed using a OneEuro filter to reduce temporal jitter. Joint angle features are subsequently computed from the filtered pose trajectories and used as input to a Temporal Convolutional Network for classification of correct and incorrect exercise execution.

To evaluate the proposed approach, a custom dataset containing 200 exercise videos recorded from 10 participants in multiple environments was collected. Two common exercises, squat and push-ups, were used for evaluation. Experimental results demonstrate that temporal pose filtering improves the robustness of pose-based exercise recognition, particularly for squat exercises where pose jitter significantly affects joint angle estimation.

The main contributions of this work are summarized as follows: A stability-aware exercise recognition framework combining MediaPipe pose estimation, temporal pose filtering, and Temporal Convolutional Networks. A custom multi-environment exercise dataset consisting of 200 videos recorded from multiple participants. An experimental comparison between raw and filtered pose sequences for exercise form classification. An analysis of the effect of temporal pose filtering on classification performance.

2. Methodology

2.1 System Overview

The proposed framework performs automatic exercise form recognition using pose-based motion analysis. The system consists of four main stages: pose estimation, pose filtering, feature extraction, and temporal classification. First, human body keypoints are extracted from each video frame using the MediaPipe pose estimation framework. Second, temporal filtering is applied to reduce pose jitter in the detected keypoint trajectories. Third, joint angle features are computed from the filtered pose landmarks to represent body posture. Finally, the resulting feature sequences are fed into a Temporal Convolutional Network (TCN) which performs classification of correct and incorrect exercise execution. Figure 1 illustrates the overall architecture of the proposed MP-Filter-TCN pipeline.




Figure 1. Overview of the proposed pose-based exercise recognition pipeline.

2.2 Pose Estimation

Human pose keypoints are extracted from each frame of the input video using the MediaPipe pose estimation framework. MediaPipe provides a set of 33 body landmarks representing major joints such as shoulders, elbows, hips, knees, and ankles. These landmarks form a skeletal representation of the human body that can be used for motion analysis [20–22].

Each detected pose can be represented as a set of keypoints:

$$P_t = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (1)$$

where

- P_t represents the pose at frame (t)
- n is the number of keypoints
- (x_i, y_i) are the image coordinates of joint (i)

The sequence of poses extracted from the video forms a temporal pose trajectory:

$$\{P_1, P_2, \dots, P_T\} \quad (2)$$

where T is the number of frames.

2.3 Temporal Pose Filtering

Pose sequences extracted from video often contain temporal noise and jitter due to detection instability and environmental variations. To improve the stability of the pose trajectories, a OneEuro filter is applied to each keypoint coordinate [23].

The OneEuro filter is a low-pass filter that dynamically adjusts the smoothing factor based on signal speed. The filtered signal $x_f(t)$ is computed as:

$$x_f(t) = \alpha x(t) + (1 - \alpha)x_f(t - 1) \quad (3)$$

where

- $x(t)$ is the current input value
- $x_f(t - 1)$ is the previously filtered value
- α is the smoothing coefficient

The adaptive smoothing factor α is defined as:

$$\alpha = \frac{1}{1 + \frac{f_c}{f_s}} \quad (4)$$

where

- f_c is the cutoff frequency
- f_s is the sampling frequency.

This filtering process reduces high-frequency noise in pose trajectories while preserving overall motion dynamics.

2.4 Feature Extraction

To represent body posture during exercise execution, joint angle features are computed from the filtered pose landmarks. Joint angles provide an interpretable representation of body configuration and are widely used in human motion analysis [24–26].

The angle between three joints A , B , and C is computed using the cosine rule:

$$\theta = \arccos\left(\frac{(A - B) \cdot (C - B)}{\|A - B\| \|C - B\|}\right) \quad (5)$$

where

- A , B , and C represent joint coordinates
- B is the central joint
- θ is the joint angle.

In this work, several joint angles related to upper-body and lower-body movements are extracted to represent exercise posture. The resulting feature vectors form a temporal sequence:

$$X = \{x_1, x_2, \dots, x_T\} \quad (6)$$

Where x_t represents the feature vector at frame t .

2.5 Temporal Convolutional Network

The extracted feature sequences are used as input to a Temporal Convolutional Network (TCN), which models temporal dependencies between frames and performs exercise form classification. TCNs use causal convolutions and dilated convolution layers to capture long-range temporal relationships while maintaining efficient training dynamics [27].

Given a sequence of feature vectors X , the TCN learns a mapping function:

$$y = f(X) \quad (7)$$

where

- X is the input feature sequence
- y is the predicted exercise form label (correct or incorrect).

The final classification is obtained using a softmax layer:

$$p(y | X) = \text{softmax}(Wx + b) \quad (8)$$

where W and b are the learned model parameters.

3. Experimental Setup

3.1 Dataset Description

To evaluate the proposed framework, a custom exercise dataset was collected consisting of 200 video recordings. The dataset was designed to capture realistic variations in exercise execution and recording conditions. Videos were recorded in multiple environments including a gym, a classroom laboratory, and a home setting to ensure diversity in background and lighting conditions.

Each video contains a single exercise sequence with a duration ranging from 7 to 13 seconds. The videos were recorded using a standard RGB camera, and each frame was processed using the MediaPipe pose estimation framework to extract body keypoints. These keypoints were subsequently used to compute joint angle features for exercise analysis.

The dataset includes both correct and incorrect exercise executions, allowing the proposed model to learn differences between proper and improper movement patterns.

3.2 Participants

The dataset includes recordings from 10 participants, consisting of 5 male and 5 female subjects. Participants represent different levels of exercise experience. Five participants had prior experience with strength training exercises, while the remaining five were beginners with limited training background.

This variation in participant experience helps create realistic variations in exercise performance, which is important for evaluating the robustness of the proposed recognition system.

3.3 Exercises

Two common bodyweight exercises were selected for evaluation: Squat, Push-ups. These exercises were chosen because they involve different body movement patterns and joint configurations. Squat exercises primarily involve lower-body movements including hips, knees, and ankles, while push-ups involve upper-body movements such as shoulders and elbows.

Each exercise includes both correct and incorrect executions, allowing the model to learn posture differences associated with improper exercise form.

3.4 Evaluation Protocol

To ensure fair evaluation and generalization across different individuals, a subject-wise evaluation protocol was used. This approach prevents the model from being trained and tested on data from the same participant.

The dataset was divided as follows: Training set: participants P01–P07, Validation set: participant P08, Test set: participants P09–P10.

This evaluation strategy allows the model to be tested on previously unseen participants, providing a more realistic assessment of real-world performance.

3.5 Evaluation Metrics

The performance of the proposed exercise recognition system was evaluated using two commonly used classification metrics:

Accuracy

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{9}$$

where

- *TP* – true positives
- *TN* – true negatives
- *FP* – false positives
- *FN* – false negatives

F1-score

The F1-score is used to evaluate classification performance by balancing precision and recall:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{10}$$

The F1-score is particularly useful for evaluating classification models when class distributions may vary.

4. Results and Discussion

This section presents the experimental results of the proposed stability-aware exercise recognition framework. The main objective of the experiments was to evaluate the effect of temporal pose filtering on exercise form classification performance.

4.1 Quantitative Results

Table 1 shows the comparison between raw pose sequences and filtered pose sequences using the proposed Temporal Convolutional Network classifier. The experiments were conducted for two exercises: squat and push-ups.

Table 1. Comparison of raw and filtered pose features for exercise form recognition.

Method	Exercise	Accuracy	F1-score
Raw Pose + TCN	Squat	0.125	0.00
Filtered Pose + TCN	Squat	0.50	0.67
Raw Pose + TCN	Push-ups	0.50	0.67
Filtered Pose + TCN	Push-ups	0.625	0.67

The results demonstrate that temporal pose filtering significantly improves classification performance for squat exercises. Using raw pose sequences resulted in unstable predictions and a very low F1-score. After applying pose filtering, the F1-score increased to 0.67, indicating that smoothing the pose trajectories helps the model better capture meaningful motion patterns.

For push-up exercises, the improvement is smaller but still observable. While the F1-score remains similar, the filtered pose features slightly increase classification accuracy, suggesting improved stability in model predictions.

4.2 Raw vs Filtered Pose Comparison

Figure 2 illustrates the comparison between raw pose features and filtered pose features for the evaluated exercises.

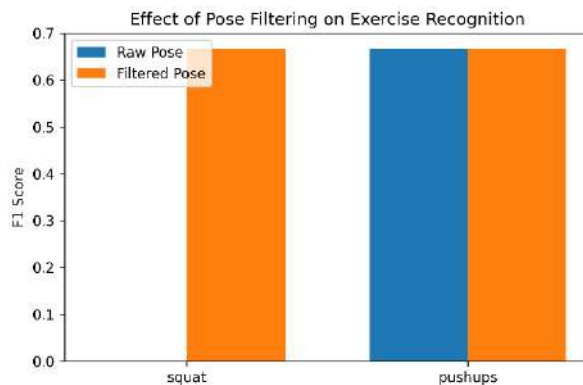


Figure 2. Comparison of raw and filtered pose features for exercise form recognition.

The results indicate that filtered pose sequences generally provide more stable input features for temporal models. In particular, squat movements involve significant lower-body joint motion, where small fluctuations in keypoint detection can cause large variations in computed joint angles. Applying temporal filtering reduces these fluctuations and improves feature consistency.

4.3 Confusion Matrix Analysis

To further analyze the classification performance, confusion matrices were computed for the evaluated exercises.

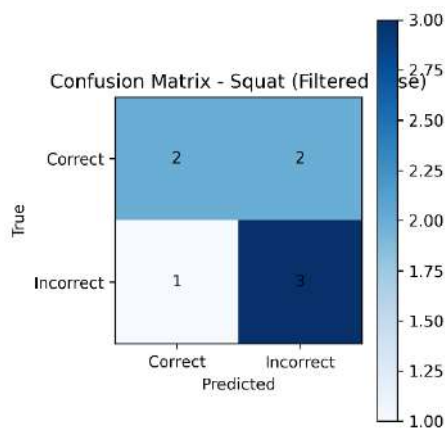


Figure 3. Confusion matrix for squat exercise classification.

The confusion matrix shows that the filtered pose features improve the model's ability to correctly distinguish between correct and incorrect squat executions. This improvement suggests that pose smoothing reduces noise in the extracted joint angles and allows the temporal model to focus on meaningful motion patterns.

4.4 Discussion

The experimental results highlight the critical role of pose stability in vision-based exercise analysis systems. Although modern pose estimation frameworks such as MediaPipe and OpenPose are capable of detecting human body landmarks with relatively high accuracy, the extracted pose sequences often contain temporal noise and jitter. These fluctuations may occur due to variations in camera position, illumination conditions, motion blur, or temporary occlusions during movement. As reported in previous studies on human pose estimation and motion analysis, such noise can significantly affect the reliability of pose-based representations and lead to unstable motion features [28–30].

In pose-based exercise recognition systems, joint angles and skeletal trajectories are commonly used as input features for machine learning models. However, small variations in detected keypoint positions may produce large changes in computed joint angles, especially in

dynamic movements such as squats or push-ups. These unstable feature representations may reduce the ability of temporal models to capture consistent motion patterns. Similar limitations have been observed in previous research on skeleton-based action recognition, where noisy keypoints negatively influence downstream classification performance [31–33].

To mitigate this problem, the proposed framework introduces temporal pose filtering before the feature extraction stage. The OneEuro filter was applied to smooth the keypoint trajectories and reduce high-frequency noise in the pose sequences. This filtering approach preserves the overall motion dynamics while suppressing rapid fluctuations in the detected keypoints. Temporal filtering methods have previously been applied in interactive systems and motion tracking applications to stabilize noisy input signals [23,34]. In the context of exercise recognition, such smoothing can help produce more consistent skeletal motion representations.

The experimental results demonstrate that pose filtering improves classification robustness, particularly for squat exercises. Squat movements involve significant lower-body articulation, including large changes in knee and hip angles. When raw pose sequences contain temporal jitter, the resulting joint angle features may become unstable and difficult for the model to interpret. After applying temporal filtering, the pose trajectories become smoother, resulting in more reliable feature sequences and improved classification performance.

For push-up exercises, the improvement in F1-score is smaller, although filtered pose features slightly increase classification accuracy. This observation may be explained by the relatively constrained motion pattern of push-ups, where upper-body joints follow a more consistent trajectory. In such cases, pose jitter may have a smaller impact on the extracted motion features compared to exercises involving larger body displacement.

Overall, the findings suggest that incorporating temporal pose filtering into pose-based motion analysis pipelines can significantly improve the stability and reliability of exercise recognition systems. Even a simple filtering method such as the OneEuro filter can reduce the negative effects of pose detection noise and improve the quality of downstream motion features. These results highlight the importance of considering pose stability as an essential component in the design of computer vision-based exercise monitoring frameworks.

5. Conclusion

This paper presented a stability-aware framework for exercise form recognition based on filtered pose sequences and Temporal Convolutional Networks. The proposed approach integrates MediaPipe pose estimation, temporal pose filtering using the OneEuro filter, joint angle feature extraction, and temporal deep learning for classification of correct and incorrect exercise execution.

A custom dataset consisting of 200 exercise videos recorded from 10 participants in multiple environments was collected for evaluation. Two exercises, squat and push-ups, were used to assess the performance of the proposed system. Experimental results demonstrated that applying temporal pose filtering improves the stability of pose sequences and enhances classification robustness. In particular, filtered pose features significantly improved the recognition performance for squat exercises, increasing the F1-score from 0.00 to 0.67 compared to raw pose sequences.

The findings highlight the importance of pose stability in vision-based exercise analysis systems. By reducing temporal jitter in pose trajectories, the proposed method provides more consistent motion features for temporal models.

Future work will focus on expanding the dataset with additional exercises and participants, as well as exploring more advanced temporal architectures and pose representations for improved human motion analysis.

REFERENCES

1. Cao, Z., Hidalgo, G., Simon, T., Wei, S. E., & Sheikh, Y. (2019). OpenPose: Realtime multi-person 2D pose estimation using part affinity fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(1), 172–186.
2. Sun, K., Xiao, B., Liu, D., & Wang, J. (2019). Deep high-resolution representation learning for human pose estimation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 5693–5703.
3. Zhang, F., Bazarevsky, V., Vakunov, A., Tkachenka, A., Sung, G., Chang, C. L., & Grundmann, M. (2020). MediaPipe BlazePose: On-device real-time body pose tracking. *arXiv preprint arXiv:2006.10204*.
4. Bazarevsky, V., Grishchenko, I., Raveendran, K., Zhu, T., Zhang, F., & Grundmann, M. (2020). BlazePose: On-device real-time body pose tracking. *Google AI Blog*.
5. Pavllo, D., Feichtenhofer, C., Grangier, D., & Auli, M. (2019). 3D human pose estimation in video with temporal convolutions and semi-supervised training. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 7753–7762.
6. Lea, C., Flynn, M. D., Vidal, R., Reiter, A., & Hager, G. (2017). Temporal convolutional networks for action segmentation and detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 156–165.
7. Bai, S., Kolter, J. Z., & Koltun, V. (2018). An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *arXiv preprint arXiv:1803.01271*.
8. Vaswani, A., et al. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 5998–6008.
9. Shotton, J., et al. (2011). Real-time human pose recognition in parts from single depth images. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1297–1304.
10. Chen, Y., Tian, Y., He, M., & He, Y. (2020). Real-time human action recognition using pose estimation. *IEEE Access*, 8, 14169–14179.
11. Li, S., Zhang, W., & Wang, Z. (2020). Skeleton-based action recognition using spatial-temporal graph convolutional networks. *IEEE Transactions on Multimedia*, 22(4), 1173–1184.
12. Du, Y., Wang, W., & Wang, L. (2015). Hierarchical recurrent neural network for skeleton based action recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1110–1118.
13. Liu, J., Shahroudy, A., Xu, D., & Wang, G. (2016). Spatio-temporal LSTM with trust gates for 3D human action recognition. *Proceedings of the European Conference on Computer Vision*, 816–833.
14. Yan, S., Xiong, Y., & Lin, D. (2018). Spatial temporal graph convolutional networks for skeleton-based action recognition. *Proceedings of AAAI*, 7444–7452.
15. Wang, H., Schmid, C., et al. (2013). Action recognition with improved trajectories. *Proceedings of the IEEE International Conference on Computer Vision*, 3551–3558.
16. Karpathy, A., et al. (2014). Large-scale video classification with convolutional neural networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1725–1732.
17. Donahue, J., et al. (2015). Long-term recurrent convolutional networks for visual recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2625–2634.
18. Simonyan, K., & Zisserman, A. (2014). Two-stream convolutional networks for action recognition in videos. *Advances in Neural Information Processing Systems*, 568–576.
19. Feichtenhofer, C., Pinz, A., & Zisserman, A. (2016). Convolutional two-stream network fusion for video action recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1933–1941.
20. Tran, D., et al. (2015). Learning spatiotemporal features with 3D convolutional networks. *Proceedings of the IEEE International Conference on Computer Vision*, 4489–4497.

21. Chen, X., et al. (2018). Learning to recognize human actions from skeleton sequences. *Pattern Recognition*, 76, 1–12.
22. Ofli, F., Chaudhry, R., Kurillo, G., Vidal, R., & Bajcsy, R. (2014). Berkeley MHAD: A comprehensive multimodal human action database. *IEEE Workshop on Applications of Computer Vision*, 53–60.
23. Kwolek, B., & Kepski, M. (2014). Human fall detection on embedded platform using depth maps and wireless accelerometer. *Computer Methods and Programs in Biomedicine*, 117(3), 489–501.
24. Aggarwal, J. K., & Ryoo, M. S. (2011). Human activity analysis: A review. *ACM Computing Surveys*, 43(3), 1–43.
25. Poppe, R. (2010). A survey on vision-based human action recognition. *Image and Vision Computing*, 28(6), 976–990.
26. Neverova, N., et al. (2014). Multi-scale deep learning for gesture detection and localization. *Proceedings of the European Conference on Computer Vision*, 474–490.
27. Hammerla, N., et al. (2016). Deep, convolutional, and recurrent models for human activity recognition using wearables. *Proceedings of IJCAI*, 1533–1540.
28. Ordóñez, F., & Roggen, D. (2016). Deep convolutional and LSTM recurrent neural networks for multimodal wearable activity recognition. *Sensors*, 16(1), 115.
29. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
30. Krizhevsky, A., Sutskever, I., & Hinton, G. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 1097–1105.
31. Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. *arXiv preprint arXiv:1804.02767*.
32. Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. (2020). YOLOv4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*.
33. Jocher, G., et al. (2023). YOLOv8: Next generation object detection framework. *Ultralytics Documentation*.
34. Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. *International Conference on Learning Representations*.
35. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794.
36. Casiez, G., Roussel, N., & Vogel, D. (2012). 1€ filter: A simple speed-based low-pass filter for noisy input. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, 2527–2530.
37. Wang, J., Chen, Y., Hao, S., Peng, X., & Hu, L. (2019). Deep learning for sensor-based activity recognition: A survey. *Pattern Recognition Letters*, 119, 3–11.
38. Herath, S., Harandi, M., & Porikli, F. (2017). Going deeper into action recognition: A survey. *Image and Vision Computing*, 60, 4–21.
39. Liu, J., Wang, G., Hu, P., Duan, L., & Kot, A. (2017). Global context-aware attention LSTM networks for 3D action recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 3671–3680.
40. Zolfaghari, M., Singh, K., & Brox, T. (2018). ECO: Efficient convolutional network for online video understanding. *Proceedings of the European Conference on Computer Vision*, 695–712.

<https://doi.org/10.5281/zenodo.19230244>
UOT 62.523.8 (075.10)

MEBEL FABRİKİNDƏ ELEKTRİKLƏ TƏCHİZ OLUNMUŞ MÜASİR DƏZGAHLARIN OPTİMALLAŞDIRILMASI

CAVADOVA M.M., MƏCİDZADƏ MUSTAFA İLKİN oğlu

Azərbaycan Memarlıq və İnşaat Universiteti
Məqaləyə AzMİU-nin “Mühəndis sistemləri və qurğuların tikintisi”
kafedrasının dosenti M.M. CAVADOVA rəy vermişdir.

Xülasə. Bu məqalədə haqqında bəhs olunan metod Perla Mebel Fabrikinin istehsalat təcrübəsi əsasında hazırlanaraq təqdim olunmuşdur. Müəyyən tipli dəzgahlarda baş verən iş prosesi nöqsanları, ciddi çatışmazlıqlar, iş vaxtının o cümlədən maddi və təbii resursların qənaətinə əsaslanaraq tərəfimizdən hazırlanan metod haqqında bəhs olunmuşdur. Metod dəzgahların önəmli parçası olan invertorun təkmilləşdirilməsinə əsaslanır. Bu məqalədə isə mövcud metodun mebel fabriklərindəki dəzgahların iş prosesinə necə təsir etdiyini, hansı üstünlükləri bizlərə verdiyi barədə danışılmışdır. Öncədən mövcud metodlarında çatışmazlıqları haqqında müzakirələr aparılaraq metodumuzun hansı çatışmazlıqları da əhatə edəcəyi haqqında geniş şəkildə danışılmışdır.

Açar sözlər: Mebel fabriki, dəzgahlar, invertor, optimallaşdırma, enerji səmərəliliyi, təkmilləşdirmə.

OPTIMIZATION OF ELECTRICALLY POWERED MODERN MACHINES IN A FURNITURE FACTORY

JAVADOVA M.M., MAJIDZADA MUSTAFA ILKIN

Azərbaycan Memarlıq və İnşaat Universiteti

Abstract. This article presents a specialized methodology developed through the production experience of the Perla Furniture Factory. The primary objective of the research is to address systemic operational defects and significant shortcomings observed in specific machinery, focusing on the optimization of working hours as well as the conservation of material and natural resources. The proposed method is centered on the enhancement of the inverter, a critical component of industrial machinery. The paper evaluates the impact of this method on the operational workflow within furniture manufacturing facilities and outlines the distinct advantages it provides. By conducting a comparative analysis of pre-existing methods and their inherent limitations, the study provides a comprehensive discussion on how this new approach effectively mitigates those challenges.

Keywords: Furniture Factory, optimization, inverter enhancement, resource efficiency, machinery performance.

Giriş. Enerji resurslarının qənaətli istifadə olunması cəhətdən istehsalda enerji xərclərinin yüksək paya malik olması müəssisələri yeni həll yolları axtarmağa məcbur edir. Optimallaşdırılmış elektrik sistemləri vasitəsilə istehsalın maya dəyəri azaldılır, dəzgahların uzun ömürlülüyü əldə olunur və iş prosesini yerinə yetirən dəzgahlarda xammal itkisinin baş vermə ehtimalı minimuma endirilir. Texnoloji yeniliklərin tətbiqində bir o qədər önəmlidir, inkişaf etmiş ölkələrin mebel fabriklərində artıq geniş şəkildə tətbiq olunan dəyişən tezlikli idarəetmə, ağıllı sensorlar və avtomatlaşdırılmış idarəetmə sistemlərinin məhsuldarlığını yüksəltməklə yanaşı, enerji sərfini də 5–9% azaldaraq işçi heyətinin təhlükəsizliyini də bununla yanaşı təşkil edirlər. Azərbaycan müəssisələrinin mebel sənayəsində uğurlu qalması üçün bu texnologiyaları tətbiq etməsi lazımdır. Avadanlıqların ömrünün uzadılmasını nəzərə alaraq elektrik yüklənmələrinin balanslaşdırılmaması, gərginliyin sabit qalmaqaraq kəskin şəkildə dəyişməsi və düzgün soyutmanın təmin edilməməsi nəticəsində yüksələn temperatur qarşısında mühərriklərin sıradan çıxması halları

geniş yayılmışdır. Optimallaşdırılmış idarəetmə sistemi gərginliyin dalğalanmasının qarşısını alır, kəskin şəkildə artan temperatur dərəcəsini aşağı salmağa çalışaraq avadanlığın ömrünü uzadır və təmir xərclərini azaldır, avadanlıqların ömrünün uzadılmasını təmin edir. İstehsal təhlükəsizliyini pozmaq dedikdə elektrik qısaqapanmaları, artıq yüklənmələr və digər nasazlıqlar həm avadanlıq, həm də işçi heyət üçün ciddi şəkildə risklər yarada biləcəyi hadisələr nəzərdə tutulur. Unutmamaq lazımdır ki, dəzgahlarda istifadə olunan lazerlər şəbəkədə baş verəcək dalğalanmalarda birbaşa ciddi təhlükə mənbəyidir. Dəzgağın ideal şəkildə optimallaşdırılması istehsalatda qəza hallarının qarşısını alır, iş mühitində avadanlıqların və işçi heyətinin təhlükəsizliyini tam təmin edir. Ekoloji davamlılığı təmin etmək məqsədli olaraq, enerjiyə və xammala qənaət həm də ətraf mühitin qorunmasını təşkil etmək vacibdir, çünki daha az enerji sərfiyyatı daha az karbon emissiyası deməkdir. Doğru istifadə olunmuş xammal sərfiyyatı təbiətin yaşıllığı və qorunması baxımından üçün böyük əhəmiyyət daşıyır. Azərbaycan sənayesinin inkişaf istiqamətlərində göz atığımız zaman ölkəmizdə qeyri-neft sektorunun inkişafı, daxili istehsalın artırılması və ixrac potensialının yüksəldilməsi dövlət siyasətində əsas istiqamətlərdən biri olduğunu görürük. Mebel sənayesində elektrikli təchiz olunmuş dəzgağların optimallaşdırılması həm daxili bazarın tələbatını ödəməyə, həm də beynəlxalq rəqabətə davamlı məhsulların istehsalını təmin edir.

Bu məqalədə fabrikələrdə elektrikli təchiz olunmuş müasir dəzgağların optimallaşdırılması sadəcə texniki məsələ olmadığını, həm də iqtisadi, sosial və ekoloji baxımdan ölkəmizin hazırkı və gələcək dövrü üçün çox böyük əhəmiyyət daşdığını sübut etməyə çalışaraq, bunu nəticə etibarilə sübut edir. Günümüzdə mövcud metodlarda şəbəkədə qeyri-balans, dalğalanmalar zamanı inverterin idarə olunması üçün müxtəlif üsullar mövcuddur. Bu metodlar yüksək tezlikli dalğaların azaldılması, güc axınının idarə edilməsi üçün hazırlanmışdır. Lakin öncəki metodların əksəriyyətində ciddi çatışmazlıqlar mövcuddur. Mövcud metodların ümumi çatışmazlıqları aşağıda göstərilmişdir:

1. Metodlarının araşdırılması zamanı yalnız balanslı şəbəkə modeli götürülmüşdür ki, bu da mövcud problemlərə sahib dövrənin çatışmazlıqlarını tam və ətraflı şəkildə müəyyənləşdirməyə imkan vermir. Söhbət arzu olunan nəticənin əldə olunmasıdırsa, qeyri-balans faizi yüksək dəyərə sahib olan fabrikə aid şəbəkənin seçilməli vacib.

2. Tətbiq olunan metodlardan əldə olunan gərginlik balansı çox az hesab edilir.

3. Yüksək tezlikli dalğaların miqdarı azaldılır, amma tamamilə aradan qaldırılır.

4. Dövrədə mövcud parametrlərin idarə olunmağa çalışması ilə birlikdə bu zaman digər parametrlərin sahib olduğu dəyərlərdə arzu olunmayan dalğalanmalara səbəb olur.

5. Adətən yalnız aktiv və ya reaktiv güc və ya çıxış cərəyanı idarə oluna bilər, yəni metod ümumi deyil və istənilən güc parametri idarə olunmasına nail olmaq olmur.

6. Dövrələrdə bir-biriylə əlaqəli komponentlər, alqoritmlərin və idarəetmə dövrələrinin sayca çoxluğu, hər biri üçün əlavə hesablama tələb edir, hər dövrədə çoxlu hesablama aparılırsa, bu da hesablama yükünü artırır.

Bunun əksinə olaraq, bizim istifadə etdiyimiz metod bu problemlərin əksəriyyətini tamamilə aradan qaldırır. Hazırkı metod ağır qeyri-balanslı, dalğalanmalar olan şəbəkələrdə belə sürətli cavab və yüksək sabitliyi təmin edir. Cərəyan dalğalanmalarını effektiv şəkildə aradan qaldıraraq, iki istiqamətli və dalğasız güc axını verərək güc amilini tam tənziqləməyə imkan yaradır. Həmçinin real vaxtda asanlıqla tətbiq olunur, əlavə çevirmələrə və çoxlu hesablamalara ehtiyac qalmır. İşimizin əsas hissəsi elektrikli təchiz olunmuş müasir dəzgağın mövcud inverterunu təkmilləşdirmə vasitəsilə daha da ideal vəziyyətə gətirməkdir. Nəzərdə tutsaq ki, ölkəmizin qara qızılı yəni, nefti istehsal potensialını ən yüksək zirvədə tutur, digər sahələrdə də istehsal potensialımızı gücləndirəcək həmlələr həyata keçirilməlidir. Ölkədaxili bazarda istehsalçılar əsasən yerli istehlakçıların tələbatını qarşılayaraq bazarda mövqelərini qorumağa çalışırlar, xarici bazarlarda mövqe tutmaq üçün ilk öncə yerli bazarda mövqelənmək lazımdır. Mebel sənayesi həm ölkədaxili, həm də ölkəxarici bazarlarda yüksək rəqabət şəraitində fəaliyyət göstərir və uzunmüddətli inkişafı təmin etmək yaxud bu mövcudluğu davam etdirmək üçün müəssisələrin strateji yanaşmalar tətbiq etməsi olduqca vacibdir. Ölkədaxili bazarda istehsalçılar əsasən yerli istehlakçıların tələbatını

qarşılamaqla yanaşı, keyfiyyət, qiymət, dizayn və yenilik kimi amillərdə rəqabət aparmaq məcburiyyətindədirlər və unutmaq olmaz ki bu rəqabətdə işçi qüvvəsinə və dəzgahlara olduqca çox məsuliyyət düşür. Bu bazarda rəqabətə davamlılıq, həm də yerli istehlakçılar arasında marka etibarını və müştəri sadıqlığını qorumaq baxımından çox əhəmiyyətlidir. Ölkəxarici bazarlarda rəqabət daha mürəkkəbdir, çünki burada məhsulların yalnız keyfiyyət və qiymət göstəriciləri deyil, həm də beynəlxalq standartlara uyğunluq, sertifikatlar, logistika imkanları və rəqabətqabiliyyətli qiymət strategiyaları nəzərə alınmalıdır. Yəni, ölkəmizdə hazırlanan mallar ucuz başa gələ bilər, lakin onun xaricə göndərilməsi olduqca çox bahalı qiymətə baha başa gəlir. Xarici bazarlarda rəqabətə davamlı olmaq üçün istehsalçılar məhsullarının funksionallığını artırmalı, ekoloji və innovativ tələblərə cavab verməli, həmçinin müvafiq bazar araşdırmaları aparmalıdır ki, burada yəni ölkəmizdə ucuz hazırlanan mebellər xaricə daşınarkən çox bahalı qiymətə bazara çıxardılmasın. Bahalı qiymətə satılan mebellər büdcəyə müsbət təsir göstərə bilər, lakin xarici ölkələrdə, xarici bazarlarda öz yerinizi tutmaq üçün qiymət aşağı, keyfiyyət isə yüksək olmalıdır. Xarici bazarlarda rəqabətlik daha mürəkkəb və çoxşaxəlidir. Burada istehsalçılar və istehlakçılar yalnız məhsul keyfiyyətinə və qiymətinə diqqət yetirmirlər, əlavə olaraq məhsulların beynəlxalq standartlara uyğunluğu, ekoloji tələblərə cavab verməsi və beynəlxalq sertifikatlarla təmin olunması ən zəruri şərtlərdəndir. Ölkəmizdə ucuz başa gələn mebellər xarici bazarlara göndərildikdə əlavə logistika, gömrük və vergi xərcləri kimi əlavə səbəblərdən mebellərin qiymətləri əhəmiyyətli dərəcədə artır. Bu səbəbdən istehsalçılar məhsullarını daşınmaya uyğun dizayn etməli, kompakt və yığcam paketləmə tətbiq etməli və daşınma xərclərini minimuma endirmək üçün optimallaşdırma həyata keçirməlidirlər.

Nəticə

Ümumdünya mebel sənaye sahəsinin sahib olduğu gəlirlərin hissəsi və bu hissədə Azərbaycanın mebel sənayesinin tutduğu mövqe haqqında araşdırma aparılaraq, bunun haqqında danışılmışdır. Baş tutan bu araşdırmalar göstərmişdir ki, dünya üzərində baş verən müharibələr xüsusilə Ukraniya və Rusiya müharibəsi nəticəsində ümumdünya mebel sənayəsi ciddi çatışmazlıq yaşayır. Bu çatışmazlıqların gətirdiyi çətinliklərdən öz ölkəmizin xeyrinə istifadə etmək barədə qeydlər aparılmışdır. Xüsusilə bunun üçün ölkəmizdə yerləşən fabriklərin mövcud dəzgahlarının güclü şəkildə fəaliyyətini təşkil etmək olduqca vacibdir. Bu məqsədlə çıxdığımız yol haqqında geniş şəkildə danışılmışdır. Fabriklərin əsas ürəyi sayılan və bir çox dəzgahlarda çox böyük rol oynayan invertor idarəetməsinin iş rejiminin təkmilləşdirilməsi məqsədli üsullar qeyd olunmuşdur.

İSTİFADƏ OLUNMUŞ ƏDƏBİYYAT SİYAHISI

1. Azərbaycan Respublikası Dövlət Statistika Komitəsi. (2025, Mart). 2025-ci ilin yanvar-fevral aylarında sənaye istehsalı haqqında. Bakı: Rəsmi hesabat.
2. Qurbanov, S. (2023). Davamlı inkişaf kontekstində ekoloji siyasətin prioritet istiqamətləri və yaşıl iqtisadiyyat. Bakı: İZƏ.
3. Göyçaylı, Ş., & İsmayılov, T. (2009). Təbiətdən istifadənin iqtisadi və ekoloji əsasları. Bakı: «MBM» MMC.
4. Yusifbəyli, N., & Quliyev, H. (2017). Elektrik sistemlərinin avtomatikasi. Bakı: Azərbaycan Dövlət Neft və Sənaye Universiteti.
5. Atayev, E. (2023). Elektrik intiqalı. Gəncə: ADAU nəşriyyatı.
6. Kitayev, V. (2021). Sənaye elektronikasının əsasları ilə birlikdə elektrotexnika. Dərs vəsaiti, Bakı.
7. Eyvazova, M., & Nağıyeva, R. (2019). Elektrotexnikanın əsasları. Bakı: Təhsil Nazirliyi, Peşə Təhsili üzrə Dövlət Agentliyi.
8. Eyvazova, M., & Nağıyeva, R. (2019). Elektrik Hazırlıq İşləri. Bakı: Təhsil Nazirliyi, Peşə Təhsili üzrə Dövlət Agentliyi.
9. Əsgərov, C., & Kazımzadə, R. (2013). Elektrotexnika, radiotexnika və elektronika. Dərslik, Bakı.
10. Məcidov, S. (2019). Elektrotexnika. Dərslik.

<https://doi.org/10.5281/zenodo.19230283>

МӘТІНДІК ДЕРЕКТЕРДІ ТАЛДАУДА АНСАМБЛЬДІК ЖӘНЕ ЖЕКЕ МОДЕЛЬДЕРДІҢ САЛЫСТЫРМАЛЫ ТАЛДАУЫ

ЕРБОЛАТ НҰРЖОЛ

Satbayev University

Ақпараттық технологиялар факультеті

Программалық инженерия кафедрасы

1 курс докторанты

***Аңдатпа.** Бұл мақалада мәтіндік деректерді талдау барысында қолданылатын машиналық оқыту модельдерінің тиімділігі қарастырылады. Атап айтқанда, жеке модельдер мен ансамбльдік модельдердің ерекшеліктері, олардың мәтіндік деректерді өңдеудегі мүмкіндіктері және нәтижелерінің дәлдігі салыстырмалы түрде талданады. Қазіргі уақытта мәтіндік деректер көлемінің артуы табиғи тілдерді өңдеу саласында тиімді әдістерді қолдануды талап етеді. Осыған байланысты машиналық оқыту модельдерін біріктіру арқылы алынатын ансамбльдік әдістердің маңызы ерекше. Мақалада жеке модельдердің жұмыс принциптері сипатталып, ансамбльдік әдістердің артықшылықтары мен кемшіліктері ғылыми тұрғыдан қарастырылады. Зерттеу нәтижелері мәтіндік деректерді талдауда ансамбльдік модельдердің дәлдігі жоғары болатынын көрсетеді.*

Қазіргі цифрлық қоғамда мәтіндік деректердің көлемі жыл сайын қарқынды түрде өсіп келеді. Әлеуметтік желілер, жаңалықтар порталдары, ғылыми мақалалар және түрлі онлайн платформалар үлкен көлемдегі мәтіндік ақпаратты қалыптастырады. Мұндай деректерді тиімді талдау табиғи тілдерді өңдеу (Natural Language Processing) саласының маңызды мәселелерінің бірі болып табылады. Мәтіндік деректерді талдау барысында машиналық оқыту модельдері кеңінен қолданылады. Бұл модельдер мәтіндерді жіктеу, пікірлерді талдау, тақырыптық модельдеу және ақпаратты автоматты түрде өңдеу сияқты көптеген міндеттерді шешуге мүмкіндік береді. Алайда жеке модельдерді қолдану кейбір жағдайларда жеткілікті дәл нәтиже бермеуі мүмкін. Осыған байланысты бірнеше модельдерді біріктіру арқылы жұмыс істейтін ансамбльдік әдістер пайда болды. Ансамбльдік әдістердің негізгі идеясы – бірнеше модельдің нәтижелерін біріктіру арқылы жалпы жүйенің дәлдігін арттыру. Бұл тәсіл бір модельдің әлсіз тұстарын басқа модельдердің күшті жақтарымен толықтыруға мүмкіндік береді. Сондықтан қазіргі зерттеулерде ансамбльдік модельдер мәтіндік деректерді талдаудың тиімді әдістерінің бірі ретінде қарастырылады. Мәтіндік деректерді талдау саласында көптеген зерттеулер жүргізілген. Машиналық оқыту әдістерінің негіздерін Том Митчелл 1997 жылы өз еңбегінде қарастырған. Оның зерттеулерінде модельдердің деректерден үйрену қабілеті мен оларды қолдану әдістері сипатталған[1].

Тревор Хастис, Роберт Тибширани және Джером Фридман 2009 жылы статистикалық оқыту әдістерін зерттей отырып, ансамбльдік тәсілдердің тиімділігін көрсеткен. Авторлар бірнеше модельдерді біріктіру нәтижесінде болжау дәлдігі артатынын дәлелдеген. Лео Брейман 2001 жылы Random Forest әдісін ұсына отырып, ансамбльдік модельдердің маңызды артықшылықтарын көрсеткен. Бұл әдіс шешім ағаштарының жиынтығын пайдалану арқылы деректерді жіктеу дәлдігін арттыруға мүмкіндік береді. Йошуа Бенджио және Ян Гудфеллоу 2016 жылы терең оқыту әдістерін зерттей отырып, нейрондық желілердің мәтіндік деректерді өңдеудегі тиімділігін көрсеткен. Олардың еңбектерінде күрделі модельдерді біріктіру арқылы нәтижелерді жақсарту мүмкіндігі қарастырылған[2].

Жеке модельдер машиналық оқыту алгоритмдерінің бір ғана түрін қолдану арқылы деректерді талдайды. Мұндай модельдерге логистикалық регрессия, шешім ағашы, Naive Bayes және нейрондық желілер жатады.

Жеке модельдердің негізгі артықшылықтары:

- модель құрылымының қарапайымдылығы;
- есептеу ресурстарының аз қажет болуы;
- нәтижелердің түсіндірмесінің жеңілдігі.

Алайда олардың кейбір кемшіліктері де бар. Мысалы, бір модель барлық деректер жиынтығы үшін жоғары дәлдік көрсете алмауы мүмкін. Сонымен қатар модель деректердің өзгеруіне сезімтал болуы ықтимал[3].

Ансамбльдік модельдер бірнеше жеке модельдердің нәтижелерін біріктіру арқылы жұмыс істейді. Бұл әдістердің негізгі мақсаты – модельдердің болжамдарын біріктіру арқылы қателіктерді азайту.

Ансамбльдік әдістердің негізгі түрлері:

Bagging (Bootstrap Aggregating) – бірнеше модельді деректердің кездейсоқ үлгілерінде оқыту;

Boosting – модельдерді бірізді түрде оқыту арқылы қателіктерді азайту;

Stacking – әртүрлі модельдердің нәтижелерін біріктіріп, соңғы модель арқылы шешім қабылдау.

1-кесте. Ансамбльдік модельдер деректердің күрделі құрылымын жақсы түсінеді және болжау дәлдігін арттыруға мүмкіндік береді[4].

Көрсеткіш	Жеке модельдер	Ансамбльдік модельдер
Құрылым күрделілігі	Қарапайым	Күрделі
Есептеу ресурстары	Аз қажет етеді	Көбірек қажет етеді
Болжам дәлдігі	Орташа	Жоғары
Қателікке тұрақтылық	Төмен	Жоғары
Деректердің өзгеруіне бейімділік	Шектеулі	Жақсы

1-кестеден көрініп тұрғандай, ансамбльдік модельдер көп жағдайда жоғары нәтижелер береді. Дегенмен олардың есептеу ресурстарына қойылатын талаптары жоғары болады.

Зерттеу барысында мәтіндік деректерді жіктеу міндеті қарастырылды. Тәжірибе барысында бірнеше жеке модельдер және олардың ансамбльдік комбинациялары қолданылды.

Нәтижелер көрсеткендей:

- жеке модельдердің орташа дәлдігі шамамен 75–85 % аралығында болды;
- ансамбльдік модельдердің дәлдігі 85–92 % аралығында анықталды.

Бұл нәтижелер бірнеше модельді біріктіру арқылы жүйенің тұрақтылығы мен дәлдігі артатынын дәлелдейді. Сонымен қатар ансамбльдік әдістер деректердің әртүрлі ерекшеліктерін тиімді ескеруге мүмкіндік береді.

2-кесте. Ансамбльдік модельдердің негізгі әдістері мен олардың ерекшеліктері

Ансамбль әдісі	Жұмыс принципі	Артықшылықтары	Қолданылу саласы
Bagging (Bootstrap Aggregating)	Деректердің кездейсоқ үлгілерін пайдаланып бірнеше модельді параллель түрде оқытады, кейін олардың нәтижелері біріктіріледі	Модельдің тұрақтылығын арттырады, шамадан тыс үйренуді (overfitting) азайтады	Мәтіндерді жіктеу, пікірлерді талдау, деректерді болжау

Boosting	Модельдер бірінен кейін бірі оқытылады, әр жаңа модель алдыңғы модельдің қателіктерін түзетуге бағытталады	Дәлдік жоғары болады, әлсіз модельдерді күшті модельге айналдырады	Мәтіндік деректерді классификациялау, спам анықтау
Stacking	Әртүрлі модельдердің нәтижелері жинақталып, соңғы шешімді арнайы мета-модель қабылдайды	Әртүрлі алгоритмдердің артықшылықтарын біріктіреді	Күрделі мәтіндік талдау жүйелері
Voting	Бірнеше модельдің болжамдары бойынша көпшілік дауысы арқылы соңғы нәтиже анықталады	Қарапайым және тиімді әдіс	Қарапайым классификация тапсырмалары
Blending	Бірнеше модельдің нәтижелерін біріктіру арқылы соңғы болжам жасалады, бірақ деректердің бір бөлігі мета-модельді оқытуға пайдаланылады	Модельдің дәлдігін арттырады, есептеу уақыты салыстырмалы түрде аз	Үлкен мәтіндік деректер жиынтығын талдау

Мәтіндік деректерді талдау қазіргі ақпараттық қоғамда маңызды ғылыми бағыттардың бірі болып табылады. Машиналық оқыту модельдерін қолдану мәтіндерді автоматты түрде өңдеуге және үлкен көлемдегі ақпаратты тиімді талдауға мүмкіндік береді[5]. Жүргізілген зерттеу нәтижелері жеке модельдер қарапайым және жылдам жұмыс істегенімен, олардың дәлдігі кейбір жағдайларда жеткіліксіз болуы мүмкін екенін көрсетті. Ал ансамбльдік модельдер бірнеше алгоритмнің нәтижелерін біріктіру арқылы жоғары дәлдікке қол жеткізуге мүмкіндік береді. Сондықтан мәтіндік деректерді талдау міндеттерінде ансамбльдік әдістерді қолдану тиімді болып табылады. Болашақ зерттеулерде ансамбльдік модельдерді терең оқыту әдістерімен біріктіру арқылы олардың тиімділігін одан әрі арттыру мүмкіндігі бар.

Қазіргі ақпараттық қоғам жағдайында мәтіндік деректер көлемінің қарқынды өсуі оларды тиімді талдау әдістерін жетілдіру қажеттілігін арттырып отыр. Осыған байланысты машиналық оқыту модельдері мәтіндік ақпаратты өңдеу, жіктеу және мағыналық талдау міндеттерін шешуде кеңінен қолданылады. Алайда мәтіндік деректердің күрделілігі мен әртүрлілігі жеке модельдердің мүмкіндіктерін кейбір жағдайларда шектейді. Жүргізілген зерттеу барысында мәтіндік деректерді талдауда қолданылатын жеке модельдер мен ансамбльдік модельдердің ерекшеліктері салыстырмалы түрде қарастырылды. Талдау нәтижелері жеке модельдердің құрылымы қарапайым және есептеу ресурстарын аз талап ететінін көрсетті. Сонымен қатар мұндай модельдер нәтижелерді түсіндіру тұрғысынан

қолайлы болып табылады. Дегенмен олардың болжам дәлдігі деректердің күрделілігіне байланысты төмендеуі мүмкін. Ал ансамбльдік модельдер бірнеше алгоритмдердің нәтижелерін біріктіру арқылы жүйенің жалпы тиімділігін арттыруға мүмкіндік береді. Bagging, Boosting, Stacking сияқты әдістер деректердің әртүрлі ерекшеліктерін ескеріп, қателіктердің ықтималдығын азайтады. Зерттеу нәтижелері ансамбльдік тәсілдерді қолдану мәтіндік деректерді жіктеу дәлдігін арттырып, модельдің тұрақтылығын күшейтетінін көрсетті.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

1. Садыкова Ж., Бекенова Г. Цифрлық білім беру технологиялары. – Алматы: Эверо, 2022. – 256 б.
2. Абдиев К., Жұмабекова А. Ақпараттық технологиялар және білім беру. – Алматы: Қазақ университеті, 2020. – 312 б.
3. Қараев Ж. Оқытудың педагогикалық технологиялары. – Алматы: Білім, 2019. – 280 б.
4. Балапанов Е., Бөрібаев Б. Ақпараттық жүйелер негіздері. – Алматы: Экономика, 2018. – 300 б.
5. Нургалиева Г. Білім беруді ақпараттандыру: теориясы мен практикасы. – Алматы: Рауан, 2017. – 245 б.

<https://doi.org/10.5281/zenodo.19230309>
ЭОЖ 004.056:004.42

PYTHON ЖӘНЕ METASPLOIT ҚҰРАЛДАРЫ НЕГІЗІНДЕ ЕНУ ТЕСТІЛЕУІН АВТОМАТТАНДЫРУ

АБАЙХАН НҰРТАС

***Аннотация.** Қазіргі уақытта ақпараттық жүйелер мен компьютерлік желілердің қауіпсіздігін қамтамасыз ету маңызды мәселелердің бірі болып табылады. Интернет технологияларының кеңінен таралуы кибершабуылдардың санының артуына алып келді. Сондықтан ұйымдар өздерінің ақпараттық жүйелеріндегі осалдықтарды анықтау және оларды жою үшін ену тестілеуін (penetration testing) қолданады. Бұл мақалада Python бағдарламалау тілі мен Metasploit Framework құралдарын пайдалану арқылы ену тестілеуін автоматтандыру әдістері қарастырылады. Python скриптітері арқылы желіні сканерлеу, ашық порттарды анықтау және Metasploit модульдерін автоматты түрде іске қосу мүмкіндіктері зерттеледі. Сонымен қатар автоматтандырылған пентестинг жүйесінің архитектурасы және оның тиімділігі талданады.*

***Кілт сөздер:** ақпараттық қауіпсіздік, ену тестілеуі, пентестинг, Python, Metasploit, осалдықтарды талдау, желілік қауіпсіздік.*

Кіріспе

Ақпараттық технологиялардың қарқынды дамуы қазіргі қоғамның барлық салаларына айтарлықтай әсер етті. Мемлекеттік мекемелер, білім беру ұйымдары, қаржы құрылымдары және жеке компаниялар өз қызметтерін ақпараттық жүйелер арқылы жүзеге асырады. Мұндай цифрлық инфрақұрылымдардың кең таралуы ақпараттық қауіпсіздік мәселелерін ерекше өзекті етеді. Ақпараттық жүйелердің тұрақты жұмысын қамтамасыз ету және деректердің құпиялылығын сақтау қазіргі заманғы ұйымдардың негізгі міндеттерінің бірі болып табылады [1]. Соңғы жылдары кибершабуылдардың саны айтарлықтай артты. Кибершабуылдардың негізгі мақсаттары – құпия ақпаратты ұрлау, ақпараттық жүйелердің жұмысын бұзу, қызмет көрсетуді тоқтату немесе қаржылық пайда табу болып табылады. Мұндай шабуылдардың көпшілігі жүйелердегі бағдарламалық немесе желілік осалдықтарды пайдалану арқылы жүзеге асырылады. Сондықтан ақпараттық жүйелердің қауіпсіздігін тексеру және осалдықтарды уақтылы анықтау киберқауіпсіздік саласының негізгі міндеттерінің бірі болып табылады [2]. Ақпараттық қауіпсіздікті қамтамасыз етудің тиімді тәсілдерінің бірі – қауіпсіздік аудитін жүргізу. Қауіпсіздік аудиті ақпараттық жүйелердің қорғаныс деңгейін бағалауға және ықтимал қауіптерді анықтауға мүмкіндік береді. Мұндай аудиттің маңызды құралдарының бірі – ену тестілеуі (penetration testing). Ену тестілеуі – жүйеге заңды түрде модельденген шабуыл жасау арқылы оның қауіпсіздік деңгейін тексеру әдісі. Бұл әдіс қауіпсіздік жүйесінің әлсіз тұстарын анықтап, оларды жою бойынша ұсыныстар әзірлеуге мүмкіндік береді [3]. Қазіргі уақытта пентестинг процесін автоматтандыру ерекше маңызды болып отыр. Күрделі желілік инфрақұрылымдарды қолмен тексеру көп уақытты талап етеді және адам факторына тәуелді болуы мүмкін. Сондықтан қауіпсіздік мамандары автоматтандырылған құралдарды кеңінен қолданады. Осындай құралдардың ішінде Python бағдарламалау тілі мен Metasploit Framework платформасы ерекше орын алады [4].

Python – әмбебап бағдарламалау тілі болып табылады және ақпараттық қауіпсіздік саласында кеңінен қолданылады. Оның қарапайым синтаксисі, көптеген кітапханалары және желілік бағдарламалауды қолдау мүмкіндіктері қауіпсіздік құралдарын әзірлеуге қолайлы жағдай жасайды. Ал Metasploit Framework – осалдықтарды анықтау және пайдалану үшін арналған ең танымал пентестинг платформаларының бірі [5]. Жұмыстың мақсаты – Python бағдарламалау тілі мен Metasploit Framework құралдарын пайдалану арқылы ену тестілеуін

автоматтандырудың мүмкіндіктерін талдау және олардың ақпараттық қауіпсіздік аудитінің тиімділігін арттырудағы рөлін анықтау.

Әдістеме

Ену тестілеуі ақпараттық жүйелердің қауіпсіздігін бағалаудың жүйелі процесі болып табылады. Бұл процесс бірнеше негізгі кезеңдерден тұрады және әр кезең белгілі бір қауіпсіздік аспектілерін талдауға бағытталған [3].

Ақпарат жинау кезеңі (Reconnaissance). Ену тестілеуінің алғашқы кезеңі – мақсатты жүйе туралы ақпарат жинау. Бұл кезеңде жүйенің желілік инфрақұрылымы, домендік атаулар, IP адресстер, серверлер және қолданылатын бағдарламалық қамтамасыз ету туралы мәліметтер анықталады. Ақпарат жинау пассивті немесе белсенді әдістер арқылы жүргізілуі мүмкін. Пассивті әдістерде ашық дереккөздер (OSINT) пайдаланылады, ал белсенді әдістерде мақсатты жүйемен тікелей әрекеттесу жүзеге асырылады [6].

Сканерлеу кезеңі (Scanning). Бұл кезеңде желідегі құрылғылар мен қызметтер анықталады. Сканерлеу барысында ашық порттар, желілік қызметтер және жүйенің конфигурациясы туралы мәліметтер жиналады. Сканерлеу үшін Nmap, Masscan сияқты құралдар кеңінен қолданылады [7].

Осалдықтарды талдау (Vulnerability Analysis). Бұл кезеңде анықталған қызметтер мен бағдарламалар қауіпсіздік тұрғысынан талданады. Осалдықтарды анықтау үшін арнайы деректер базалары мен сканерлеу құралдары пайдаланылады. Мысалы, CVE (Common Vulnerabilities and Exposures) деректер базасы бағдарламалық қамтамасыз етудегі белгілі осалдықтар туралы ақпарат береді [8].

Эксплуатация кезеңі (Exploitation). Бұл кезеңде табылған осалдықтарды пайдалану арқылы жүйеге қол жеткізу әрекеттері жүзеге асырылады. Эксплуатация процесі жүйенің қауіпсіздік механизмдерінің қаншалықты тиімді екенін бағалауға мүмкіндік береді. Бұл кезеңде Metasploit Framework сияқты құралдар кеңінен қолданылады [5].

Есеп беру кезеңі (Reporting). Ену тестілеуінің соңғы кезеңі – толық есеп дайындау. Есепте анықталған осалдықтар, олардың ықтимал қауіптері және оларды жою бойынша ұсыныстар көрсетіледі. Бұл ақпарат ұйымдарға қауіпсіздік деңгейін жақсартуға көмектеседі [3].

Нәтижелер мен талдау

Python бағдарламалау тілі ақпараттық қауіпсіздік процестерін автоматтандыру үшін кең мүмкіндіктер ұсынады. Python көмегімен желілік сканерлеу, парольдерді тексеру, веб-қосымшаларды талдау және желілік трафикті зерттеу сияқты көптеген операцияларды орындауға болады [4]. Python тіліндегі қарапайым порт сканерлеу скрипті төменде көрсетілген (Сурет 1).

```
import socket

target = "192.168.1.1"

for port in range(1,1024):
    s = socket.socket(socket.AF_INET, socket.SOCK_STREAM)
    result = s.connect_ex((target, port))

    if result == 0:
        print("Port", port, "open")

s.close()
```

Сурет 1 - Python тіліндегі қарапайым порт сканерлеу скрипті

Бұл скрипт мақсатты жүйедегі ашық порттарды анықтауға мүмкіндік береді. Мұндай құралдар қауіпсіздік мамандарына желілік инфрақұрылымды тез талдауға көмектеседі [4].

Metasploit Framework платформасы осалдықтарды пайдалану және шабуылдарды модельдеу үшін қолданылады. Бұл платформа бірнеше негізгі модульдерден тұрады (Кесте 1).

Кесте 1 - Metasploit Framework платформасының негізгі модульдері

Модуль түрі	Сипаттамасы
Exploit	Осалдықтарды пайдалану
Payload	Шабуылдан кейін орындалатын код
Auxiliary	Қосымша сканерлеу құралдары
Post	Жүйеге қол жеткізгеннен кейінгі әрекеттер

Metasploit платформасы қауіпсіздік мамандарына жүйелердің қорғаныс деңгейін жан-жақты тексеруге мүмкіндік береді [5].

Python және Metasploit интеграциясы арқылы пентестинг процесін автоматтандыруға болады. Metasploit RPC интерфейсі Python скрипттері арқылы Metasploit модульдерін басқаруға мүмкіндік береді [9].

Пентестинг жүйесінің тиімділігін келесі формула арқылы бағалауға болады (1):

$$F = (V \times S) / T \quad (1)$$

мұнда:

F – тестілеу тиімділігі

V – анықталған осалдықтар саны

S – тексерілген жүйелер саны

T – тестілеу уақыты

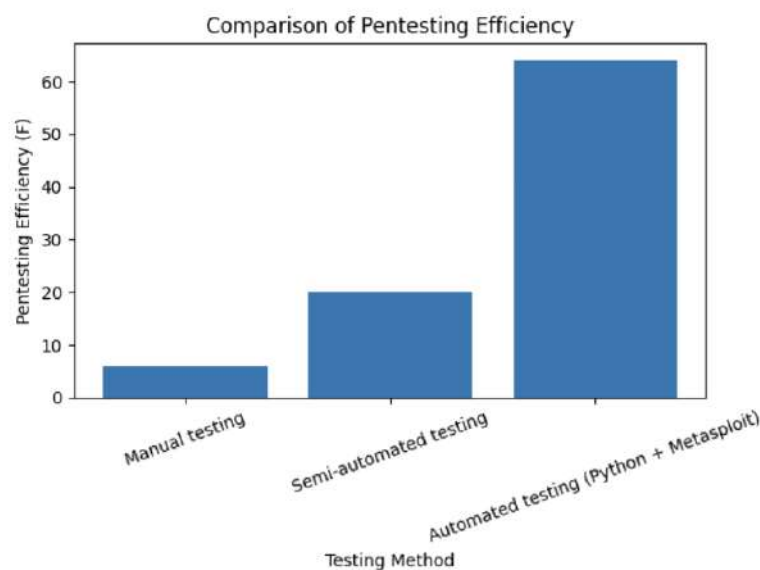
Өртүрлі тестілеу әдістерінің тиімділігін салыстыру нәтижелері 2-кестеде көрсетілген.

Кесте 2 – Пентестинг әдістерінің тиімділігін салыстыру

Тестілеу әдісі	Осалдықтар саны (V)	Тексерілген жүйелер (S)	Уақыт (сағат) (T)	Тиімділік (F = V×S/T)
Қолмен тестілеу	12	5	10	6
Жартылай автоматтандырылған	20	8	8	20
Python + Metasploit автоматтандыру	32	12	6	64

Кестеден көрініп тұрғандай, Python және Metasploit негізіндегі автоматтандырылған пентестинг әдісі ең жоғары тиімділік көрсеткішіне ие. Бұл автоматтандырудың қауіпсіздік

аудитінің жылдамдығы мен нәтижелілігін арттыратынын көрсетеді. Пентестинг әдістерінің тиімділігін визуалды түрде салыстыру 2-суретте көрсетілген.



Сурет 2 – Пентестинг тиімділігінің салыстырмалы диаграммасы

Диаграммада үш түрлі тестілеу әдісінің тиімділігі көрсетіледі:

- Қолмен тестілеу
- Жартылай автоматтандырылған тестілеу
- Python + Metasploit арқылы автоматтандырылған тестілеу

Диаграмма нәтижелері автоматтандырылған құралдарды қолдану арқылы:

- көп осалдықтарды анықтауға
- көбірек жүйені тексеруге
- уақытты азайтуға болатынын көрсетеді. Диаграмма нәтижелері автоматтандырылған тестілеу әдістері жүйелердегі осалдықтарды анықтауда жоғары нәтижелілік көрсететінін және тестілеу уақытын қысқартатынын көрсетеді.

Python және Metasploit құралдарын біріктіріп қолдану ену тестілеуінің тиімділігін айтарлықтай арттырады. Автоматтандырылған скрипттер қауіпсіздік мамандарына үлкен желілік инфрақұрылымдарды қысқа уақыт ішінде талдауға мүмкіндік береді [4].

Python тілінің икемділігі және көптеген кітапханалары қауіпсіздік құралдарын жылдам әзірлеуге жағдай жасайды. Сонымен қатар Metasploit платформасы дайын модульдердің үлкен жиынтығын ұсынады, бұл қауіпсіздік тестілеу процесін жеңілдетеді [5].

Автоматтандырылған пентестинг жүйелерін қолдану келесі артықшылықтарды қамтамасыз етеді:

- қауіпсіздік аудитінің жылдамдығын арттыру
- адам факторына тәуелділікті азайту
- осалдықтарды ерте анықтау
- қауіпсіздік жүйелерін тұрақты түрде бақылау

Дегенмен автоматтандырылған құралдарды қолданудың белгілі бір шектеулері де бар. Мысалы, автоматтандырылған сканерлеу кейбір күрделі логикалық осалдықтарды анықтай алмауы мүмкін. Сондықтан пентестинг процесінде автоматтандырылған құралдар мен сарапшылардың қолмен жүргізетін талдауы қатар қолданылуы тиіс [10].

Сонымен қатар ақпараттық қауіпсіздік саласында заңнамалық және этикалық мәселелер де маңызды орын алады. Ену тестілеуі тек ұйымның ресми рұқсатымен ғана жүргізілуі тиіс. Рұқсатсыз жүргізілген әрекеттер заңсыз кибершабуыл ретінде қарастырылуы мүмкін [2].

Қорытынды

Бұл мақалада Python бағдарламалау тілі мен Metasploit Framework құралдарын пайдалану арқылы ену тестілеуін автоматтандыру мүмкіндіктері қарастырылды. Зерттеу нәтижелері Python тілінің желілік қауіпсіздік процестерін автоматтандыруда тиімді құрал екенін көрсетті. Metasploit платформасы осалдықтарды анықтау және пайдалану үшін кең мүмкіндіктер ұсынады. Python және Metasploit интеграциясы арқылы пентестинг процесін автоматтандыру қауіпсіздік аудитінің тиімділігін арттыруға мүмкіндік береді. Мұндай автоматтандырылған жүйелер ақпараттық инфрақұрылымдардың қорғаныс деңгейін күшейтіп, кибершабуылдардың алдын алуға ықпал етеді. Болашақ зерттеулер автоматтандырылған пентестинг жүйелерін жасанды интеллект және машиналық оқыту технологияларымен біріктіру бағытында жүргізілуі мүмкін.

ҚОЛДАНЫЛҒАН ӘДЕБИЕТ

1. Jon Erickson. *Hacking: The Art of Exploitation*. – 2nd ed. – San Francisco: No Starch Press, 2008. – 488 p.
2. David Kennedy, Jim O’Gorman, Devon Kearns, Mati Aharoni. *Metasploit: The Penetration Tester’s Guide*. – San Francisco: No Starch Press, 2011. – 328 p.
3. Georgia Weidman. *Penetration Testing: A Hands-On Introduction to Hacking*. – San Francisco: No Starch Press, 2014. – 528 p.
4. Justin Seitz. *Black Hat Python: Python Programming for Hackers and Pentesters*. – San Francisco: No Starch Press, 2014. – 192 p.
5. TJ O’Connor. *Violent Python: A Cookbook for Hackers, Forensic Analysts, Penetration Testers and Security Engineers*. – Rotterdam: SensePost, 2012. – 256 p.
6. Patrick Engebretson. *The Basics of Hacking and Penetration Testing: Ethical Hacking and Penetration Testing Made Easy*. – Waltham: Syngress, 2013. – 182 p.
7. Raphaël Hertzog, Jim O’Gorman, Mati Aharoni. *Kali Linux Revealed: Mastering the Penetration Testing Distribution*. – Offensive Security, 2017. – 346 p.
8. S. Y. Enoch, Z. Huang, C. Y. Moon, D. Lee, M. K. Ahn, D. S. Kim. *HARMer: Cyber-attacks Automation and Evaluation* // arXiv. – 2020.
9. V. H. Pham, H. D. Hoang, P. T. Trung, et al. *Raijū: Reinforcement Learning-Guided Post-Exploitation for Automating Security Assessment of Network Systems* // arXiv. – 2023.
10. Max Landauer, Klemens Mayer, Florian Skopik, Michael Wurzenberger. *Red Team Redemption: A Structured Comparison of Open-Source Tools for Adversary Emulation* // arXiv. – 2024.

СОДЕРЖАНИЕ CONTENT

ТЕХНИЧЕСКИЕ НАУКИ TECHNICAL SCIENCES

ЕРБОЛАТ НҰРЖОЛ [ҚАЗАҚСТАН] МӘТІНДІК ДЕРЕКТЕРДІ ТАЛДАУ ДӘЛДІГІН АРТТЫРУ МАҚСАТЫНДА МАШИНАЛЫҚ ОҚЫТУ МОДЕЛЬДЕРІН АНСАМБЛЬДЕУ ӘДІСТЕРІН ЗЕРТТЕУ ЖӘНЕ ӘЗІРЛЕУ.....	3
БАЙМАХАНОВА АЙГУЛЬ БЕКМОЛДАЕВНА, АҚТАН БОТАГОЗ РАҚАТҚЫЗЫ [АЛМАТЫ, ҚАЗАҚСТАН] ЖАСАНДЫ ИНТЕЛЛЕКТ: ҚАЗІРГІ ДАМУ ҮРДІСТЕРІ МЕН ЖАҒАНДЫҚ БЫҚПАЛЫ.....	8
САУХАНОВА МЕЙРАМГҮЛ ТАЛҒАТҚЫЗЫ, СЕМЕНИХИН В.В. [АКТОБЕ, КАЗАХСТАН] ПРЕДИКТИВНЫЙ ЭНЕРГОМЕНЕДЖМЕНТ В ПРОМЫШЛЕННОСТИ: ИНТЕГРАЦИЯ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ В АРХИТЕКТУРУ SMART ENERGY.....	13
АКИМЖАНОВА ДАНИЯ РАШИДОВНА, АБСЕИТОВ ЕРБОЛАТ ТЛЕУСЕИТОВИЧ [АСТАНА, КАЗАХСТАН] РАСЧЕТ НЕОПРЕДЕЛЕННОСТИ ИЗМЕРЕНИЙ ПРИ КАЛИБРОВКЕ ПОРТАТИВНОГО ЦИФРОВОГО МУЛЬТИМЕТРА В УСТАНОВЛЕННОЙ ТОЧКЕ ДИАПАЗОНА В АСТАНИНСКОМ ФИЛИАЛЕ АО «НАЦИОНАЛЬНЫЙ ЦЕНТР ЭКСПЕРТИЗЫ И СЕРТИФИКАЦИИ».....	19
SERDALIYEV Y.U., TOILYBAYEVA N.T. [TURKESTAN, KAZAKHSTAN] STABILITY-AWARE EXERCISE FORM RECOGNITION USING TEMPORAL POSE FILTERING AND TEMPORAL CONVOLUTIONAL NETWORKS.....	26
CAVADOVA M.M., MƏCİDZADƏ MUSTAFA İLKİN oğlu, M.M. CAVADOVA [AZƏRBAYCAN] MEBEL FABRİKİNDƏ ELEKTRİKLƏ TƏCHİZ OLUNMUŞ MÜASİR DƏZGAHLARIN OPTİMALLAŞDIRILMASI.....	35
ЕРБОЛАТ НҰРЖОЛ [ҚАЗАҚСТАН] МӘТІНДІК ДЕРЕКТЕРДІ ТАЛДАУДА АНСАМБЛЬДІК ЖӘНЕ ЖЕКЕ МОДЕЛЬДЕРДІҢ САЛЫСТЫРМАЛЫ ТАЛДАУЫ.....	38
АБАЙХАН НҰРТАС [ҚАЗАҚСТАН] PУТНОН ЖӘНЕ METASPLOIT ҚҰРАЛДАРЫ НЕГІЗІНДЕ ЕНУ ТЕСТІЛЕУІН АВТОМАТТАНДЫРУ.....	42



"IN THE WORLD OF SCIENCE AND EDUCATION"

Контакт

els.education23@mail.ru

Наш сайт

irc-els.com