

ҚАЗАҚСТАН РЕСПУБЛИКАСЫ ҒЫЛЫМ ЖӘНЕ ЖОҒАРҒЫ БІЛІМ МИНИСТРЛІГІ
«Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті» коммерциялық
емес акционерлік қоғамы



Автоматика және ақпараттық технологиялар институты
«Робототехника және автоматиканың техникалық құралдары» кафедрасы

Қойбағаров Мейіржан Қойбағарұлы

«Машиналық оқыту негізінде өнеркәсіптегі техникалық қызмет көрсетуді болжау
жүйесін жобалау»

МАГИСТРЛІК ДИССЕРТАЦИЯ

7М07107 – Робототехника және мехатроника

Алматы 2025

ҚАЗАҚСТАН РЕСПУБЛИКАСЫ ҒЫЛЫМ ЖӘНЕ ЖОҒАРҒЫ БІЛІМ МИНИСТРЛІГІ

«Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті» коммерциялық
емес акционерлік қоғамы



SATBAYEV
UNIVERSITY

Автоматика және ақпараттық технологиялар институты

ӘОЖ 665.622.43.046.6-52 (043)

Қолжазба құқығында

Қойбағаров Мейіржан Қойбағарұлы

Магистр академиялық дәрежесін алу үшін
МАГИСТРЛІК ДИССЕРТАЦИЯ (ЖОБА)

Диссертацияның атауы

Машиналық оқыту негізінде өнеркәсіптегі техникалық қызмет
көрсетуді болжау жүйесін жобалау

Дайындау бағыты

7M07107 – Робототехника және мехатроника

Ғылыми жетекші

Физ.- мат. ғылым.

канд., қауымдастырылған профессор

 Алдиров Н. У.

«10» 06 2025 ж.

Рецензент

Техника ғылымының кандидаты,

қауымдастырылған профессор

 Сейдилдаева А. К.

«__» 06 2025 ж.

Норма бақылаушы

Тех. ғылым. маг., оқытушы,

 Игембай Е. А.

«10» 06 2025 ж.

ҚОРҒАУҒА ЖІБЕРІЛДІ

Кафедра меңгерушісі РТЖАТК

Техника ғылымының кандидаты,
профессор

 К. А. Өжікенов

«__» 06 2025 ж.

Алматы 2025

ҚАЗАҚСТАН РЕСПУБЛИКАСЫ ҒЫЛЫМ ЖӘНЕ ЖОҒАРҒЫ БІЛІМ МИНИСТРЛІГІ
«Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті» коммерциялық
емес акционерлік қоғамы



SATBAYEV
UNIVERSITY

Автоматика және ақпараттық технологиялар институты

«Робототехника және автоматиканың техникалық құралдары» кафедрасы

7M07107 – Робототехника және мехатроника

БЕКІТЕМІН

Кафедра меңгерушісі РТЖАТҚ
Техника ғылымының кандидаты,
профессор

Қ.Ә. Өжікенов

«___» * 2025 ж.

Магистрлік диссертацияны орындауға арналған ТАПСЫРМА

Магистрант Қойбағаров Мейіржан Қойбағарұлы

Тақырыбы Машиналық оқыту негізінде өнеркәсіптегі техникалық қызмет көрсетуді
болжау жүйесін жобалау

Университет ректорының 2022 ж. « 25 » 03 № 430 - М бұйрығымен бекітілген

Аяқталған жұмысты тапсыру мерзімі «___» маусым 2025 ж.

Магистрлік диссертацияның бастапқы деректері:

Магистрлік диссертацияда қарастырылатын мәселелер тізімі:

а) *Өнеркәсіптік ақауларды болжау міндетін модельдеу*

б) *Интеллектуалды жүйе архитектурасын жобалау*

в) *Roboflow, Google Colab орталарында техникалық көру және болжалды қызмет
модельдерін әзірлеу*

г) *Жүйенің тиімділігін бағалау және эксперименттік нәтижелер*

Графикалық материалдың тізімі (міндетті сызбаларды дәл көрсете отырып):

жұмыс презентациясы слайтарда 20 көрсетілген

Ұсынылатын негізгі әдебиеттер: 51 әдебиеттер тізімі және 2 қосымша


**Магистрлік диссертацияны дайындау
КЕСТЕСІ**

Бөлімдер атауы, әзірленетін сұрақтар тізбесі	Ғылыми жетекшіге ұсыну мерзімдері	Ескерту
Өнеркәсіптік ақауларды болжау міндетін модельдеу	16.01-12.02.2025 ж	Орындалды
Интеллектуалды жүйе архитектурасын жобалау	12.02-20.04.2025 ж.	Орындалды
Roboflow, Google Colab орталарында техникалық көру және болжалды қызмет модельдерін әзірлеу	20.03-17.04.2025 ж.	Орындалды
Жүйенің тиімділігін бағалау және эксперименттік нәтижелер	17.04-15.05.2025 ж.	Орындалды
Қорытынды бөлім	16.05-19.05.2025 ж	Орындалды

Аяқталған магистрлік диссертация үшін, оған қытысты бөлімдердегі диссертациялар кеңесшілері мен қалып бақылаушының қолдары


Бөлімдердің атауы	Кеңесшілер, тегі, аты, әкесінің аты, (ғылыми дәрежесі, атағы)	Қол қойылған күні	Қол
Еңбекті қорғау бөлімі	Аймуханбетов Е.А., техника ғылымдарының магистрі, аға оқытушы.	10.06.2025	
Норма бақылаушы	Игембай Е.А, техника ғылымдарының магистрі, оқытушы	10.06.2025	

Ғылыми жетекшісі



Алдияров Н.У.

Білім алушы тапсырманы орындауға алды



Койбағаров М.К.

Күні

«10» 06 2025 ж.

АҢДАТПА

Бұл жұмыс қазіргі заманғы өнеркәсіп жағдайында өндірістік процестерді автоматтандыру үшін машиналық оқыту (ML) әдістерін қолдана отырып, болжамды техникалық қызмет көрсету жүйесін зерттеуге және дамытуға арналған. Жылдам технологиялық даму кезеңінде және көптеген елдерде, соның ішінде Қазақстанда инженерлік кадрлардың жетіспеушілігі жағдайында машиналық оқыту ML және жасанды интеллект (AI) негізінде зияткерлік жүйелерді енгізу жабдықтың сенімділігі мен тиімділігін арттырудың негізгі құралына айналууда. Негізгі назар ток, температура, қысым, діріл және дыбыс сенсорларынан, сондай-ақ компьютерлік көру деректерінен келетін деректерді кешенді талдау негізінде жабдықтың ықтимал бұзылуын болжауға қабілетті модельді әзірлеуге бағытталған. Ұсынылған тәсіл аномалияларды ерте кезеңдерде анықтауға және операциялық шығындарды азайту арқылы жоспарланбаған тоқтап қалу қаупін азайтуға мүмкіндік береді.

Жұмыс автоматтандырудың, сапаның және сыртқы факторларға төзімділіктің жоғары деңгейін қамтамасыз ете отырып, өндірістерді цифрландырудың маңызды құрамдас бөлігі ретінде болжамды қызмет көрсетудің жоғары әлеуетін көрсетеді.

АННОТАЦИЯ

Данная работа посвящена исследованию и разработке системы предиктивного технического обслуживания с использованием методов машинного обучения (ML) для автоматизации производственных процессов в условиях современной промышленности. В условиях быстрого технологического развития и нехватки инженерных кадров во многих странах, включая Казахстан, внедрение интеллектуальных систем на основе машинного обучения ML и искусственного интеллекта (ИИ) становится ключевым инструментом повышения надёжности и эффективности оборудования. Основное внимание уделено разработке модели, способной предсказывать потенциальные поломки оборудования на основе комплексного анализа данных, поступающих от сенсоров тока, температуры, давления, вибрации и звука, а также данных компьютерного зрения. Предложенный подход позволяет выявлять аномалии на ранних стадиях и минимизировать риск незапланированных простоев, снижая эксплуатационные расходы.

Работа демонстрирует высокий потенциал предиктивного обслуживания как важного компонента цифровизации производств, обеспечивая более высокий уровень автоматизации, качества и устойчивости к внешним факторам.

ANNOTATION

This paper is devoted to the research and development of predictive maintenance system using machine learning (ML) methods for automation of production processes in the conditions of modern industry. In the conditions of rapid technological development and shortage of engineering personnel in many countries, including Kazakhstan, the introduction of intelligent systems based on ML and artificial intelligence (AI) becomes a key tool to improve the reliability and efficiency of equipment. The main attention is paid to the development of a model capable of predicting potential equipment failures based on the integrated analysis of data from current, temperature, pressure, vibration and sound sensors, as well as computer vision data. The proposed approach allows early detection of anomalies and minimizes the risk of unplanned downtime, reducing operating costs.

The work demonstrates the high potential of predictive maintenance as an important component of the digitalization of production facilities, providing a higher level of automation, quality and fault tolerance.

ҚЫСҚАРТЫЛҒАН ТЕРМИНДЕР ТІЗІМІ

OPC UA	Бірыңғай ашық коммуникация архитектурасы	Open Platform Communications Unified Architecture
PLC	Бағдарламаланатын логикалық контроллер	Programmable Logic Controller
IoT	Заттар интернеті	Internet of Things
CNN	Конволюциялық нейрондық желі	Convolutional Neural Network
VAE	Вариациялық автоэнкодер	Variational Autoencoder
RUL	Қалған пайдалану ресурсы	Remaining Useful Life
SCADA	Диспетчерлік басқару және деректерді жинау	Supervisory Control and Data Acquisition
Power BI	Microsoft корпорациясының іскерлік интеллект платформасы	Business Intelligence Platform by Microsoft
MQTT	Хабарламаларды кезекпен телеметриялық беру хаттамасы	Message Queuing Telemetry Transport
ML	Машиналық оқыту	Machine Learning
PdM	Болжалды техникалық қызмет көрсету	Predictive Maintenance
RNN	Қайталанатын нейрондық желі	Recurrent Neural Network
LTSM	Ұзақ-қысқа мерзімді жады	Long Short-Term Memory
SVM	Анықтамалық векторлар әдісі	Support Vector Machine
ARIMA	Авторегрессиялық интеграцияланған жылжымалы орташа	AutoRegressive Integrated Moving Average
mAP	орташа дәлдік	mean Average Precision
F1-score	Дәлдік пен толықтық арасындағы гармоникалық орта	F-score
ELBO	Ықтималдықтың төменгі шегі	Evidence Lower Bound
ROC	Қабылдағыштың жұмыс сипаттамасы	Receiver Operating Characteristic
MTBF	Бас тарту арасындағы орташа уақыт	Mean Time Between Failures

МАЗМҰНЫ

КІРІСПЕ	10
1 Теориялық негіздер	14
1.1 Техникалық қызмет көрсету тәсілдері және оның эволюциясы. Ағымдағы мәселелер және индустрия 4.0 маңыздылығы	14
1.2 Машиналық оқытудың индустрия 4.0 және индустрия 5.0 дегі рөлі.	20
1.3 Төртінші өнеркәсіптік революция жағдайындағы Қазақстан өнеркәсібін дамытудың заманауи сын-тегеуріндері мен перспективалары	24
1.4 Болжалды техникалық қызмет көрсетуді іске асырылған жобалар мен шешімдерге шолу	27
2 Зерттелетін жүйенің әдіснамасы	33
2.1 Болжалды қызмет үшін машиналық оқыту түрлеріне шолу. Машиналық оқыту түрін таңдау	33
2.2 Сенсорлардан деректерді жинау және эксперименттік хаттама	38
2.3 Талдау үшін деректерді өңдеу және жинақтау	40
2.4 Сенсорлық деректер мен компьютерлік көруді біріктіру	44
2.5 Тұрақты оқыту механизмдері және Байес теоремасы	47
3 Жүйені жасау және енгізу	53
3.1 Өнеркәсіпте компьютерлік көруді қолдану	53
3.2 Болжалды өнеркәсіптік қызметке арналған машиналық оқыту	57
3.3 Болжалды қызмет көрсету жүйесін әзірлеу және енгізу. Болашақ даму бағыттары.	65
Қорытынды	
Пайдаланылған әдебиеттер тізімі	
Қосымша А	
Қосымшасы Б	

КІРІСПЕ

Өнеркәсіптік автоматтандырудың қарқынды дамуының және өндіріс ауқымының кеңеюінің қазіргі жағдайында дәстүрлі техникалық қызмет көрсету стратегиялары – реактивті және профилактикалық – тиімділігі төмен болып келеді. Істен шыққаннан кейін жабдықты қалпына келтіруге негізделген реактивті тәсіл жоспарланбаған тоқтап қалуға, айтарлықтай қаржылық шығындарға және технологиялық процестердің бұзылу қаупіне әкеледі. Тораптар мен компоненттерді ауыстыру күнтізбелік кесте бойынша жүзеге асырылатын профилактикалық техникалық қызмет көрсету көбінесе жұмыс істейтін бөлшектерді мерзімінен бұрын ауыстыруға әкеледі, бұл кәсіпорындардың өзіндік құны мен ресурстық шығындарына да әсер етеді. Жабдықтың сенімділігін арттыру және пайдалану шығындарын азайту үшін машиналар мен механизмдердің техникалық жағдайы туралы деректерді талдауға негізделген болжамды қызмет көрсетуге көшу өзекті болып отыр. Бұл жұмыс істемеу белгілері пайда болғанға дейін жабдықтың тозуы мен ақауларының ерте белгілерін анықтауға қабілетті Машиналық оқыту негізінде өнеркәсіптік желілерге болжамды техникалық қызмет көрсетудің (PdM) кешенді интеллектуалды жүйесін әзірлеуге арналған. Аналитикалық ядроның негізгі элементі ретінде Вариациялық автоэнкодерді (VAE) тек жабдықтың қалыпты жұмыс істеу деректерінде оқыту әдістемесі ұсынылған, бұл ең көп таралған шектеуді айналып өтуге мүмкіндік береді – ескірген техникасы бар кәсіпорындарда апаттық үлгілердің болмауы. Көп арналы сенсорлық деректерді (ток, температура, қысым, діріл, акустикалық сигналдар) және компьютерлік көруді талдау синергиясы аномалияларды анықтау дәлдігін арттыруға және беткі ақаулар мен жабдық түйіндерінің пайда болуын көзбен бақылауға мүмкіндік береді. Деректерді сенімді жинау мен беруді қамтамасыз ету үшін Siemens контроллері мен UA өнеркәсіптік OPC протоколына негізделген архитектура ұсынылған, бұл қолданыстағы SCADA жүйелерімен үйлесімділікке кепілдік береді және ақпараттың жоғалу қаупін азайтады. Қорытынды қорытындылар VAE және CNN әдістерін өнеркәсіптік протоколдармен және бейнелеу платформаларымен байланыстыра қолдану саланың цифрлық трансформациясын дамытудың перспективалық бағыты болып табылатынын және өндірістік процестердің тиімділігі мен тұрақтылығын арттыруға елеулі үлес қосуға мүмкіндік беретінін көрсетеді.

Адаптивті болжамды қызмет көрсетуді енгізу жабдықты пайдалану коэффициентінің өсуіне, пайдалану шығындарының төмендеуіне және диагностиканы автоматтандыру арқылы кадрлық мәселелерді шешуге ықпал етеді. Алынған нәтижелер ұсынылған тәсілді Қазақстанның өнеркәсіптік секторын цифрлық трансформациялау мен экономикалық дамытудың тиімді құралы деп санауға мүмкіндік береді.

Зерттеудің мақсаты мен міндеттері - ариациялық автоэнкодер (VAE), компьютерлік көру және OPC UA хаттамасы негізінде өнеркәсіптік жабдыққа болжамды техникалық қызмет көрсетудің интеллектуалды жүйесін әзірлеу және эксперименттік негіздеу. Басқаша айтқанда, жүйе Siemens PLC-ден көп арналы деректерді (ток, температура, қысым, діріл, дыбыс) автоматты түрде жинауы, оларды өңдеуі. VAE көмегімен ауытқуларды анықтауы және ақауларды бейнелеуді визуалды талдаумен қорытындыларды толықтыруы керек. Болжамдардың дәлдігі мен енгізудің экономикалық тиімділігін бағалау.

Зерттеу міндеттері: осы мақсатқа жету үшін келесі ғылыми және қолданбалы міндеттер дәйекті түрде шешілді:

1. PdM интеллектуалды жүйесіне қойылатын талаптарды негіздеу мақсатында қолданыстағы техникалық қызмет көрсету стратегияларына (реактивті, профилактикалық және болжамды) жүйелі талдау жүргізу және өнеркәсіптік автоматтандыруда машиналық оқытудың заманауи әдістеріне шолу жасау;

2. Сенсорлық түйіндерді (ток, температура, қысым, діріл, дыбыс), Siemens PLC және сенімді деректерді жинау және беру үшін OPC UA протоколына негізделген серверді қамтитын болжамды қызмет көрсету кешенінің аппараттық және бағдарламалық архитектурасын жобалау;

3. "Үлкен деректерді" алдын ала өңдеу әдістемесін әзірлеу: шуды сүзу, арналарды синхрондау, рұқсаттарды қалпына келтіру және VAE оқыту үшін қолтаңба векторларын шығару;

4. Жабдықтың қалыпты күйінде VAE моделін жасаңыз және үйретіңіз, жаңа деректер келген сайын модель параметрлерін үздіксіз (Байес) жаңарту процедурасын жасаңыз;

5. Ақаулықтарды автоматты түрде анықтау және конволюциялық нейрондық желілерге негізделген визуалды диагностика үшін компьютерлік көру модулін біріктіру, VAE анализаторымен бірлескен жұмысты қамтамасыз ету;

6. PdM жүйесінің демонстрациялық прототипін Power BI-де бірыңғай SCADA интерфейсімен және нәтижелерді визуализациялаумен жүзеге асырыңыз, бұл сәтсіздік болжамдары мен нақты уақыттағы өнімділіктің негізгі көрсеткіштерін көрсетуге мүмкіндік береді;

7. Нәтижелерді қорытындылау, ұсынылған тәсілдің тиімділігін дәстүрлі техникалық қызмет көрсету стратегияларымен салыстыру, зерттеу шектеулерін анықтау және PdM жүйесін одан әрі жетілдіру бағыттарын анықтау.

Зерттеу нысаны мен тәсілі

Зерттеу объектісі Қазақстан Республикасының кәсіпорындарында сусындар (үрлеу және құю машиналары, тасымалдау желілері, дозаны өлшеу

қондырғылары және т.б.) және тамақ (өнімдерді буып-түю және фасовка желілері) өндірісінің технологиялық процестері болып табылады. Басқаша айтқанда, тамақ өнеркәсібі кәсіпорындарында технологиялық операциялардың үздіксіз циклін қамтамасыз ететін өндірістік машиналар мен жүйелер объект болып табылады. Болашақта әзірленген тәсілдің жұмыс қабілеттілігін сәтті тексере отырып, болжамды қызмет көрсету жүйесін өнеркәсіптік кәсіпорындардың басқа түрлерінің (машина жасау, мұназ және газ, металлургия және т.б.) жабдықтарына бейімдеуге болады.

Зерттеудің тақырыбы - вариациялық автоэнкодерлерге, компьютерлік көруге және OPC UA хаттамасына негізделген интеллектуалды болжамды техникалық қызмет көрсету жүйесін құрудың әдістері мен бағдарламалық-аппараттық құралдары. Пән аясында: көп арналы сенсорлық деректерден белгілерді өңдеу және алу алгоритмдері; Siemens PLC-нің VAE моделін оқыту және үздіксіз жаңарту үшін серверлік модульмен интеграциялау архитектурасы қарастырылады; сондай-ақ, жабдықтың ақауларын Автоматты диагностикалау үшін компьютерлік көру модулін енгізу және SCADA жүйесінде және Power BI-де нәтижелерді визуализациялау.

Ғылыми жаңалық

Зерттеу барысында жұмыстың ғылыми жаңалығын құрайтын жаңа нәтижелер алынды. Негізгі инновациялық аспектілерге мынадай ережелер жатады:

- Технологиялық жабдыққа болжамды қызмет көрсету үшін алғаш рет VAE моделін тек қалыпты жұмыс істеу деректерінде (ток, температура, қысым, діріл, дыбыс) оқыту тәсілі ұсынылды және іске асырылды. Бұл ескі жабдықта апаттық үлгілердің болмауы мәселесін айналып өтуге және таңбаланған деректерсіз жұмыс кезінде ауытқуларды жоғары тиімділікпен анықтауға мүмкіндік береді;

- Көп арналы сенсорлық деректерді және конволюциялық нейрондық желілер негізінде компьютерлік көру модулімен алынған ақаулардың суреттерін бірлесіп талдаудың өзіндік әдісі жасалды. Бұл тәсілдердің синергиясы әр әдістің жеке қолданылуымен салыстырғанда сәтсіздіктерді анықтаудың дәлдігі мен сенімділігін арттырады;

- Жабдықтың пайдалану режимдері өзгерген кезде болжамның тұрақтылығын қамтамасыз ететін және авариялық сценарийлер туралы білімді біртіндеп жинақтайтын жаңа деректер түскен кезде Байес теоремасы негізінде VAE-моделінің таразылары мен гиперпараметрлерін бейімдеу (онлайн) жаңарту механизмі енгізілді;

- VAE және компьютерлік көру негізіндегі сәтсіздіктерді болжау модулін Power BI-де визуализациясы бар өнеркәсіптік SCADA жүйесіне қосу алғаш рет ұсынылды және жүзеге асырылды. Бұл инженерлер мен менеджерлерге болжамдарды, негізгі көрсеткіштерді және іске асырудың

экономикалық әсерін жылдам көрсетуге мүмкіндік беретін бірыңғай интерфейсін қамтамасыз етеді;

- Қазақстанның тамақ және сусын өндірістерінің нақты үрлеу және құю машиналарында әзірленген жүйеге эксперименттік тексеру жүргізілді. Нәтижелер жалған позитивтердің азаюын және бас тартуға арналған орташа әзірлемелердің ұзаруын көрсетеді, бұл ұсынылған тәсілдің басқа салалар үшін практикалық маңыздылығы мен ауқымдылығын растайды.

Практикалық маңыздылығы

- Диссертациялық зерттеу нәтижелері Қазақстанның өнеркәсіптік секторын жаңғырту үшін жоғары практикалық құндылыққа ие және тамақ және сусын саласы кәсіпорындарында өндірістің сенімділігі мен экономикалық тиімділігін арттыру үшін пайдаланылуы мүмкін;

- Ұсынылған болжамды қызмет көрсету жүйесі үрлеу және құю желілеріндегі істен шығуды алдын-ала анықтауға мүмкіндік береді, бұл жабдықтың жоспарланбаған тоқтауын азайтады. Analytic Company "Алгоритм" бағалауы бойынша Қазақстанның өңдеу салаларында жоспарланбаған тоқтап қалудың ағымдағы деңгейі жалпы жұмыс уақытының 12-15% - на жетеді [15];

- Білікті инженерлердің өткір тапшылығы жағдайында, кадр тапшылығы 2025 жылға қарай 1,5 млн адамнан асуы мүмкін, мониторинг пен диагностикуны автоматтандыру қызметкерлерден жүктеменің бір бөлігін алып тастайды. Жүйе сенсорлық деректер мен бейне ағындарын өз бетінше талдайды, ықтимал проблемалық түйіндерді бөліп көрсетеді, бұл инженерлерге маңызды міндеттерге назар аударуға мүмкіндік береді;

- Пайдалану ауытқуларын алдын-ала анықтау бөлшектерді қажетсіз ауыстырусыз "нүктелік" техникалық қызмет көрсетуге мүмкіндік береді. Бұл жабдықты пайдаланудың жалпы коэффициентін (OEE) арттырады және ақаулар кезінде шикізаттың жоғалуын азайтады;

- ML модульдері мен OPC UA-ны SCADA жүйелеріне біріктіру кәсіпорындарды жедел цифрландыруға ықпал етеді. "Алгоритм" Analytic Company деректері бойынша Қазақстандық өнеркәсіптік кәсіпорындардың тек 35% - цифров цифрлық жетілу моделі бойынша II және III деңгейдегі шешімдер бар, ал ұсынылған тәсілді енгізу кәсіпорындарды автоматтандыру мен талдаудың жоғары деңгейіне шығаруға мүмкіндік береді;

- Әзірленген архитектура жабдықтар мен салалардың басқа түрлеріне оңай бейімделеді: Қазақстанның тау-кен, химия және ауыр өнеркәсіптерінде болжамды қызмет көрсету технологиясын кеңінен таратуға жол ашатын VAE-модельін және компьютерлік көру модулін жаңа деректерге толық үйрету жеткілікті.

Автордың жеке үлесі

Осы жұмыста ұсынылған болжамды техникалық қызмет көрсету жүйесін (PdM) зерттеудің, жобалаудың, іске асырудың және бағалаудың барлық кезеңдерін автордың өзі орындады. Автор өнеркәсіптік жабдыққа қызмет көрсету проблемасының қазіргі жағдайына жан-жақты талдау жүргізді: ғылыми жарияланымдар, жетекші консалтингтік компаниялардың (PwC, Deloitte) есептері зерттелді, реактивті және профилактикалық тәсілдердің кемшіліктері анықталды, сондай-ақ mL, VAE, OPC UA және компьютерлік көруді қолданудың перспективалық бағыттары анықталды.

Автор интеллектуалды PdM жүйесінің архитектурасын ұсынды: сенсорларды (ток, температура, діріл, дыбыс) және Siemens PLC көмегімен деректерді жинау процесі жасалды, UA OPC хаттамасы бойынша орталықтандырылған деректерді беру тұжырымдамасы жүзеге асырылды. Талдау модульдерінің құрылымы жасалды: ауытқулар үшін вариациялық автоэнкодер (VAE) оқытылды, визуалды бақылау үшін CNN модулі құрылды. Datasets жеке дайындалды, roboflow-да суреттерге аннотация жасалды, Ultralytics YOLOv8 көмегімен Google colab ортасында модельдерді оқыту жүргізілді.


Сонымен қатар, зерттеу нәтижелерін автор жыл сайынғы «SATBAYEV INTERNATIONAL CONFERENCE - 2025. ARTIFITIAL INTELLEGENCE IN ENGENEERING AND PRODUCTION SYSTEMS: SOLUTION FOR OPTIMIZATION AND AUTOMATIZATION OF PROCESSES» ғылыми конференциясында ұсынды және жоғары бағаланды, онда автор "Машина жасаудағы жасанды интеллект: интеграция, цифрлық егіздер және өндірістік жүйелерді оңтайландыру" секциясында 2-ші орынды иеленді. Дайындалған ғылыми мақала "Шәкәрім университетінің хабаршысы" журналында жариялауға қабылданды, техникалық ғылымдар сериясы №2(18), 2025, маусым айына жоспарланған. Бұдан басқа, "GALANZ BOTTLERS" АҚ техникалық директорынан оң пікір алынды, онда сәулет өнерінің инновациялылығы, жетілуі, жобаның практикалық құндылығы және оның бүкіл сала деңгейінде масштабтау үшін әлеуеті ерекше атап өтілді.

Диссертацияда көрсетілген ғылыми және инженерлік нәтижелер автордың жеке еңбегінің нәтижесі болып табылады және одан әрі енгізу мен жариялауға негіз бола алады.

1 Теориялық негіздер

1.1 Техникалық қызмет көрсету тәсілдері және оның эволюциясы

Жабдықты өнеркәсіптік пайдаланудың негізгі міндеттерінің бірі оның минималды шығындармен және максималды сенімділікпен жұмыс істеуін қамтамасыз ету болып табылады. Соңғы онжылдықтарда жабдыққа техникалық қызмет көрсету тәсілдері реактивті жөндеуден бастап деректерді талдауға және машиналық оқытуды қолдануға негізделген интеллектуалды болжамды қызмет көрсетуге дейін айтарлықтай эволюциядан өтті. Мұндай трансформация өнеркәсіптің цифрлық платформаларға көшуімен, индустрия 4.0 және индустрия 5.0 тұжырымдамаларымен, заттар интернетін (IoT) және нақты уақыттағы жүйелерді енгізумен тығыз байланысты. 1.1-суретте техникалық қызмет көрсетудің стратегияларының эволюциясы схемалық түрде көрсетілген [7].



1.1-сурет – Уақыт келе техникалық қызмет көрсету стратегияларының эволюциясы

Реактивті техникалық қызмет көрсету (немесе істен шығу фактісі бойынша қызмет көрсету, ағылш. Run-to-Failure, (RTF) индустрияландырудың алғашқы кезеңдерінде ең қарабайыр және сонымен бірге кеңінен қолданылатын тәсілді білдіреді [1]. Анықтамаға сәйкес, техникалық қызмет көрсету жабдықтың істен шығуы басталғаннан кейін, ол енді өз функцияларын орындай алмаған кезде ғана жүзеге асырылады. Бұл тәсілді жабдықты ауыстыру құны төмен, өндіріс процесіне маңызды әсер етпейтін және бөлшектердің қол жетімділігі жоғары жағдайларда ақтауға болады.

Алайда, тәжірибе көрсеткендей, мұндай стратегия жоғары жүктемелі өндіріс жағдайында ауыр зардаптарға әкелуі мүмкін. Deloitte мәліметтері бойынша, реактивті қызмет жоғары үзілістермен, байланысты компоненттердің каскадты зақымдалуымен және өнім сапасының айтарлықтай төмендеуімен сипатталады [3]. Сонымен қатар, басқарылмайтын ақаулар төтенше жағдайларға және қауіпсіздікке қауіп төндіруі мүмкін - мысалы, азық-түлік жабдықтарындағы түйіннің бұзылуы өнімнің материал сынықтарымен ластануына әкелуі мүмкін. Төмендегі 1.2-суретте жабдыққа реактивті қызмет көрсетудің әсері көрсетілген.



1.2-сурет – Реактивті техникалық қызмет көрсетудің салдары

Іске асырудың қарапайымдылығына қарамастан, реактивті тәсілдің негізгі кемшілігі кенеттен тоқтап қалу, сәтсіздіктердің алдын-ала болжанбауы және жоспарлаудың болмауы болып қала береді, бұл әсіресе жоғары автоматтандырылған өндіріс желілерінде өте маңызды.

Профилактикалық қызмет көрсету (ағылш. Preventive Maintenance, PM) техникалық қызмет көрсетуді дамытудағы келесі логикалық қадам болды. Профилактикалық қызмет көрсету – жабдықтың ағымдағы жағдайына қарамастан, техникалық іс-шаралар алдын ала белгіленген кесте бойынша орындалатын жабдыққа техникалық қызмет көрсету стратегиясы. Көбінесе жиілік жұмыс уақытымен (мотоциклдер, жұмыс циклдары) немесе күнтізбелік уақытпен (ай сайын, тоқсан сайын, әр 6 ай сайын және т.б.) анықталады. Бұл тәсіл өнеркәсіпте өзінің болжамдылығына, технологиялық қарапайымдылығына және жабдықтың нормативтік құжаттамасына сәйкестігіне байланысты кең таралған.

Профилактикалық техникалық қызмет көрсету контекстінде профилактикалық шығындар мен жабдықтың істен шығу қаупін теңестіруге

көмектесетін оңтайлы қызмет аралығын бағалау формуласы жиі қолданылады (1).

$$C_{\text{жалпы}} = \frac{C_{\text{ТҚ}}}{T} + \lambda * C_{\text{істен шығу}} \quad (1.1)$$

мұндағы: $C_{\text{жалпы}}$ - уақыт бірлігінің орташа құны (мысалы, бір ай);

C_{TK} - бір профилактикалық қызмет көрсету құны;

T - қызмет көрсету аралығы (уақыт кезеңі);

λ - істен шығу қарқындылығы (уақыт бірлігінде істен шығу ықтималдығы);

$C_{\text{істен шығу}}$ - жабдықтың апаттық істен шығу құны. Егер T аралығы тым қысқа болса, онда алдын-алу шығындарының үлесі артады ($\frac{C_{\text{ТК}}}{T}$). Егер тым ұзақ болса - сәтсіздікке ұшырау қаупі және онымен байланысты шығындар артады ($\lambda * C_{\text{істен шығу}}$). Оңтайлы T жалпы шығындарды азайтады.

Төмендегі 1.3-суретте (диаграмма) уақыт бірлігіне шаққандағы орташа құнның профилактикалық қызметтер арасындағы аралыққа тәуелділігін көрсетеді. Көріп отырғаныңыздай, тым жиі техникалық қызмет көрсету кезінде (төмен T мәндері) шығындар техникалық шаралардың жоғары жиілігіне байланысты артады. Тым сирек техникалық қызмет көрсету кезінде (үлкен T) апат қаупі артады, бұл шығындардың өсуіне әкеледі. Тым сирек техникалық қызмет көрсету кезінде (үлкен T) апат қаупі артады, бұл шығындардың өсуіне әкеледі. Қисықтың минимумы - бұл оңтайлы аралық алдын-алу құны мен жабдықтың істен шығу ықтималдығы арасындағы тепе-теңдікке қол жеткізіледі.



1.3-сурет – Уақыт бірлігіне шаққандағы орташа құнның профилактикалық қызметтер арасындағы аралыққа тәуелділігі

Техникалық қызмет көрсетудің профилактикалық тәсілі бірқатар артықшылықтарға ие, соның ішінде жұмыстың жоспарлануы, қосалқы бөлшектердің жеңілдетілген логистикасы және өндірушілердің нұсқауларына сәйкес келеді, бұл оны жабдықты үнемі пайдалануға ыңғайлы етеді. Алайда, мұндай стратегияның тиімділігі жұмыс істейтін түйіндерді ауыстыру ресурстарды ұтымсыз пайдалануға әкелетін операциялардың артықтығына байланысты төмендейді. Сонымен қатар, бұл тәсіл қызмет көрсету аралықтары арасындағы кенеттен істен шығуды болжай алмайды, ал белгіленген кесте нақты жұмыс жағдайларын ескермейді. Бұл қосалқы бөлшектердің құнын арттырады және жүйенің икемділігін төмендетеді. Тек профилактикалық тәсілді қолдану кезінде ең осал болып маңызды машиналар болып табылады, мұнда тоқтау технологиялық тізбектің толық тоқтауына әкелуі мүмкін. Төменде ПЭТ бөтелкесін үрлеу машинасының профилактикалық қызмет көрсету жоспарының мысалы келтірілген.

Кесте 1.1. ПЭТ бөтелкесін үрлеу машинасының профилактикалық қызмет көрсету жоспарының мысалы.

№	Операция кезеңділігі	Жиілігі	Жұмыс сипаттамасы
1	Преформаларды беру жүйесін тексеру және тазалау	1 ай	Шаңды кетіру, рельстерді майлау
2	Сервомоторлардың жұмысын тексеру	6 ай	Шуды, қызып кетуді диагностикалау
3	Ауа жүйесінің сүзгілерін ауыстыру	3 ай	Жаңа ауа сүзгілерін орнату
4	Қыздыру және жылыту жүйелерін диагностикалау	6 ай	Жылу мен тұтынылатын тоқтың біркелкілігін тексеру
5	Гидравликалық жүйені тексеру (бар болса)	1 жыл	Май деңгейін, қосылыстардың тығыздығын тексеру
6	Пішінді ашу/жабу түйіндерін майлау	3 ай	Жоғары температуралы майлауды қолдану
7	Белдіктердің керілуін және жетектің күйін тексеру	6 ай	Көрнекі тексеру және динамикалық баптау
8	Пневматикалық жүйені бақылау	6 ай	Герметикалықты, қысымды тексеру, тозған шлангтарды ауыстыру
9	Температура мен қысым датчиктерін калибрлеу	1 жыл	Контроллерлерді анықтамалық мәндер бойынша орнату
10	Өнімділік сынағы (жыртылған және көлемді бөтелке)	3 ай	Дайын өнімнің шығу сипаттамаларын бақылау

Болжалды техникалық қызмет көрсету бүгінде өндірісті цифрлық түрлендірудің негізгі элементі ретінде қарастырылады: ол түйін істен шыққанға дейін ақаулардың пайда болуын анықтау үшін сенсорлық және визуалды деректердің үздіксіз ағынына сүйенеді. Классикалық анықтамада

PdM жағдайды бақылау технологиясы мен аналитикалық әдістерді біріктіреді, бұл араласуды күнтізбеге емес, жабдықтың деградациясының нақты деңгейіне жоспарлауға мүмкіндік береді. Бұл тәсіл реактивті қызмет көрсетуден күрт айырмашылығы бар, онда жөндеу тек бұзылғаннан кейін басталады және профилактикалық, белгіленген аралықтарға байланған, бұл әлі де жұмыс істейтін бөліктерді мерзімінен бұрын ауыстыруға әкеледі. PdM-ге көшу индустрия 4.0 арқасында мүмкін болды - IoT сенсорларының конвергенциясы, бұлтты және перифериялық есептеу және машиналық оқыту құралдары, бұл тәулік бойы телеметрия мен жедел аналитикалық кері байланысты қамтамасыз етеді.

Болжамды жүйелердің басты артықшылығы-бұзылудың көрінетін белгілері болмаған кезде ерте кезеңдерде деградацияны уақтылы анықтау арқылы механизмдердің сенімділігін арттыру. Мұның негізінде діріл, температура, қысым және дыбыс сенсорларының сигналдарын және қажет болған жағдайда компьютерлік көру жүйесінің кескіндерін өңдейтін Машиналық оқыту алгоритмдері жатыр. Вариациялық автоэнкодер негізінде реконструкциялық қатені қалыптастыру құрылғының қалыпты жұмысынан ауытқуларды автоматты түрде тіркеуге және нақты істен шыққанға дейін дабыл сигналын жасауға мүмкіндік береді. Бұл функционалдылық классикалық шартты-профилактикалық тәсілде жоқ, мұнда қызмет көрсету жұмыстары статистика алдын-ала белгіленген аралыққа жеткенде немесе ақаудың визуалды белгісін анықтаған кезде ғана басталады.

Болжамдық модельдерді қолдану сәтсіздіктер арасындағы орташа уақытты көбейтуге және жөндеу бригадаларының жүктемесін оңтайландыруға мүмкіндік береді. Жабдықтың тиімділік коэффициентінің формуласын келесідей көрсетуге болады (2).

$$K_{\text{тиімділік}} = \frac{T_{\text{жұмыс}}}{T_{\text{жұмыс}} + T_{\text{тоқтау}}} \times 100\% \quad (1.2)$$

мұндағы: $T_{\text{жұмыс}}$ - қалыпты пайдаланудың жалпы уақыты;

$T_{\text{тоқтау}}$ - жабдықтың төтенше жағдайларға байланысты тоқтау уақыты. Мұндай есептеу болжамды тәсілдің өнімділікті арттыруға қосқан нақты үлесін көрсетеді және әртүрлі қызмет стратегияларын нақты салыстыруға мүмкіндік береді.

Қосымша артықшылығы-жабдыққа иелік ету құнын төмендету. Болжалды техникалық қызмет көрсету жоспарлы ауыстыру қажеттілігін азайтады және бөлшектерді нақты дайындық шегіне дейін пайдалануға мүмкіндік береді. Бөлшектер мен еңбек шығындары профилактикалық тәсілмен салыстырғанда 15-25% - ға төмендейді, бұл халықаралық зерттеулер деректерімен расталады [14]. Сонымен қатар, болжамды жүйелер жұмыс жағдайының өзгеруіне бейімделеді және Байес теоремасы бойынша кіріс деректерінен үйренеді, бұл дабылдың шекті шектерін автоматты түрде реттеуге және жалған позитивтердің санын азайтуға мүмкіндік береді.

Өндіріс қауіпсіздігі ықтимал бас тарту туралы ерте хабарлау тәуекелдерді басқаруға және апаттық процедураларды дайындауға уақыт беретіндіктен артады. Бұл әсіресе бұзылу салдары апатты болуы мүмкін ескірген механизмдері бар өндірістік алаңдар үшін өте маңызды. Болжамды жүйелер шеңберінде жасалған Машиналық оқыту модельдері мен цифрлық егіздер нақты уақыт режимінде жабдықтың виртуалды көшірмелерін жасайды, бұл мамандарға физикалық араласусыз түйіндердің әрекетін талдауға және тіпті ең қиын жағдайларда да апаттардың алдын алуға мүмкіндік береді [8].

Жұмыс уақытының ұлғаюы өндіріс экономикасына тікелей әсер етеді, бірақ экономикалық бөлігі жеке бөлімде қарастырылады. Болжалды қызмет көрсетуді енгізу кезінде инженерлік персоналдың қатысуы артып, жас мамандардың жұмысына кедергілер азаятынын атап өту маңызды, өйткені визуалды бақылау тақталары мен автоматты ескертулері бар бағдарламалық платформалар жабдықтың жай-күйін бақылауды жеңілдетеді және күнделікті жүктемені азайтады.


Жақсартуларды бағалау үшін сәтсіздіктер арасындағы орташа уақыт формуласын қолдануға болады (3).

$$MTBF = \frac{\sum_{i=1}^N t_i}{N} \quad (1.3)$$

мұндағы: t_i - кезекті сәтсіздіктер арасындағы жұмыс ұзақтығы;

N - тіркелген істен шығу саны. Бұл көрсеткіш реактивті және профилактикалық қызмет көрсетуден болжамды тәсілге көшу кезінде жабдықтың сенімділігінің өсуін айқын көрсетеді [14]. Сонымен қатар, болжамды жүйелер жұмыс жағдайының өзгеруіне бейімделеді және Байес теоремасы бойынша кіріс деректерінен үйренеді, бұл дабылдың шеткі шектерін автоматты түрде реттеуге және жалған позитивтердің санын азайтуға мүмкіндік береді.

Төмендегі 1.4-суретте техникалық қызмет көрсету шығындарының жабдықтың істен шығу санына тәуелділігі графигі көрсетілген. Диаграмма техникалық қызмет көрсетудің үш негізгі тәсілін көрсетеді: профилактикалық, болжамды (болжамды) және реактивті (апаттық) техникалық қызмет көрсету [2].



1.4-сурет – Техникалық қызмет көрсету шығындары, бұл сәтсіздіктер санына байланысты алдын алу және жөндеу шығындарының сомасы

График болжамды қызмет көрсетудің шығындарды азайту тұрғысынан ең тиімді екенін анық көрсетеді. Профилактикалық қызмет көрсету бұзылу қаупін азайтса да, бұл үлкен жабдық паркінде үнемді емес. Реактивті тәсіл айтарлықтай шығындарға әкеледі және ең аз оңтайлы болып табылады. Қызмет көрсету стратегиясын таңдау нақты пайдалану жағдайларына және кәсіпорынның цифрландыруға дайындық деңгейіне байланысты.

Жиынтықта аталған артықшылықтар - дайындықтың жоғары коэффициенті, оңтайлы сәтте сервистік жұмыстарды орындау, қауіпсіздікті арттыру, шығындарды азайту және өзгермелі жағдайларға бейімделу — қазіргі заманғы өнеркәсіп салаларында болжамды техникалық қызмет көрсетуді кеңінен енгізу қажеттілігін негіздейді және Индустрия 4.0 қағидаттарына және одан әрі инновациялық стандарттарға қатаң сәйкес келетін шын мәнінде ақылды өндірістік экожүйелерге жол ашады.

1.2 Машиналық оқытудың индустрия 4.0 және индустрия 5.0 дегі рөлі

Қазіргі таңда деректер кәсіпорынның стратегиялық активіне айналады. Оларды жинау, сақтау, өңдеу және нақты уақыттағы талдау ақылды өндірістің маңызды элементтері болып табылады. Болжалды қызмет көрсету жүйелерінде деректер әртүрлі дерек көздерінен келеді: діріл, температура, ток, қысым, акустикалық және т.б. сенсорлардан, сонымен қатар өнім сапасын бақылау жүйелері және компьютерлік көру [9]. Индустрия 4.0 және индустрия 5.0 тұжырымдамаларына көшетін заманауи өнеркәсіп сенсорлық және визуалды деректердің үлкен ағындарына сүйенеді, бұл машиналық оқыту алгоритмдері (ML) істен шыққанға дейін түйіндердің деградациясын анықтайтын болжамды қызмет көрсету пайдасына реактивті жөндеу мен

реттеуші профилактикадан бас тартады. Дәстүрлі сараптамалық немесе физикалық модельдерден айырмашылығы, ML әдістері өзгермелі жұмыс режимдеріне автоматты түрде бейімделе алады және жабдықтың тозуын өтей алады, бұл ескірген қорлары бар және білікті инженерлердің тапшылығы бар кәсіпорындар үшін өте маңызды [17].

Классикалық оқыту схемалары бақыланатын, бақыланбайтын және жартылай бақыланатын болып бөлінеді. Келесі 1.2-кесте PdM негізделген ML деректерінің тәсілдері.

Кесте 1.2. ML деректеріне негізделген PdM тәсілдері [2].

Оқыту тәсілдер	Машиналық оқыту әдісі
Бақыланатын оқыту (мұғаліммен оқыту, ағылш. supervised)	Шешім ағаштары (Decision Trees)
	Тірек векторлық машиналар (Support Vector Machines)
	Нейрондық желілер (Neural Networks)
	Сызықтық/логистикалық регрессия (Linear/Logistic Regression)
Бақыланбайтын оқыту (мұғалімсіз оқыту, ағылш. unsupervised) және Жартылай бақыланатын (semi-supervised)	К-жақын көршілер (K-Nearest Neighbors)
	Бөлек кластерлеу (Partitional clustering)
	Иерархиялық және тығыздыққа негізделген кластерлеу (Hierarchical and Density-based Clustering)
	Терең оқыту (Deep Learning)

Бақыланатын оқыту белгілердің әрбір векторына күй белгісі (қалыпты жағдайдағы жұмыс режимі, мойынтіректің тозуы, қызып кету және т.б.) сәйкес келетін белгіленген үлгілерді пайдаланады. Іс жүзінде мұндай деректер сынақ стендтерінде немесе ұзақ мерзімді өнеркәсіптік мониторинг барысында жиналады, бұл нақты істен шығу сәтін белгілеуді талап етеді. Мұндай стратегия қалдық ресурстарды жіктеу және болжау дәлдігінің жоғары көрсеткіштерін көрсетеді, бірақ нақты бұзылулардың мысалдарының жетіспеушілігінен зардап шегеді. PdM контекстіндегі заманауи бақыланатын алгоритмдерге (шешім ағаштары, тірек векторлары, регрессиялар, терең нейрондық желілер) 1 - ML деректеріне негізделген PdM тәсілдері [4].

Мұғаліммен бірге оқыған кезде модель деректерді "белгі – таңба" жұптары түрінде алады және тапсырманың сипаты белгілердің қалай ұсынылатынына байланысты. Жабдықтың күйі жекелеген санаттармен ("қалыпты жұмыс", "тозу", "істен шығу") берілген кезде біз жіктеу міндеті туралы айтамыз. Егер белгі санмен көрсетілсе, мысалы, қалған ресурс (RUL) түрінде, тапсырма регрессияға жатады. Демек, оқыту міндеті келесі қателік функциясын азайтуға дейін азаяды [11] (4).

$$\mathcal{L}(\theta) = \frac{1}{N} \ell(y_i, f_\theta(x_i)) \quad (1.4)$$

мұндағы: x_i - өлшеу векторы;

y_i - анықтамалық күй;

f_θ – үлгі;

ℓ - қате функциясы (мысалы, жіктеу үшін кросс-энтропия немесе регрессия үшін квадрат);

θ - градиент әдістерімен реттелген мән. Орналастырылған үлгілердің жеткілікті санымен бұл тәсіл жоғары дәлдікті қамтамасыз етеді, бірақ өнеркәсіпте ақаулардың бай тарихы сирек кездеседі, бұл барлық ақаулық сценарийлерін қамтуды шектейді.

Бақыланбайтын оқыту (мұғалімсіз оқыту, ағылш. unsupervised) нақты белгілерсіз жасырын деректер құрылымын анықтауға бағытталған. Өнеркәсіпте бұл, ең алдымен, модель "қалыпты" мінез-құлықтың портретін салатын және айтарлықтай ауытқуды білдіретін аномалияларды кластерлеу және оқшаулау міндеттері. Мысал ретінде мойынтіректің температурасы тек "сау" бақылауларда оқытылған көп қабатты перцептронмен бағаланатын автомобиль зауытының конвейерін келтіруге болады, температураның сирек көтерілуін анықтау ықтимал ақаулық ретінде түсіндіріледі. Мұндай әдістер іске асыруды жеңілдетеді, өйткені олар сәтсіздіктердің көптеген мысалдарын жинауды қажет етпейді, бірақ олар жұмыс жағдайларының өзгеруіне және белгілердің таралу дрейфіне сезімтал [4].

Мұғалімсіз оқыту әдістері бақылаулардың негізгі бөлігі жүйенің қалыпты жұмыс режиміне сәйкес келетіндігінен туындайды, бұл режимнен тыс кез келген нәрсе аномалия ретінде түсіндіріледі [48]. Жоғары өлшемді деректер ағындары үшін вариациялық автоэнкодерлер (VAE) әсіресе тиімді, олар вариациялық төменгі ықтималдық шекарасы (ELBO) деп аталатын нәрсені оңтайландырады (5).

$$F(\phi, \theta) = E_{q_\phi(z|x)} [\ln p_\theta(x|z)] - D_{KL}(q_\phi(z|x) || p(z)) \quad (1.5)$$

мұндағы: $q_\phi(z|x)$ – жасырын факторлардың артқы таралуын жуықтайды z ;

$p(z)$ – априорлық $N(0, I)$;

ℓ – Кульбак–Лейблер дивергенциясы. Оқудан кейін автоэнкодер реконструкциялық қатенің шамасын есептейді. Ол төмендегі (6) формуламен есептелінеді.

$$\varepsilon_t = ||x_t - \hat{x}_t||_2 \quad (1.6)$$

мұндағы: x_t - уақыт бойынша бақылаулардың бастапқы векторы;

$\hat{x}_t$ - Қалпына келтірілген вектор, оны автоэнкодер кіре берісте көргендерін "қайталауға" тырысады. ε_t шегінен асып кету ықтимал ақаулықты көрсетеді.

Жартылай бақыланатын (semi-supervised) оқыту белгіленген мысалдардың аз санын жартылай үйретілген деректер массивімен біріктіру арқылы аралық болып табылады. PdM үшін бұл, әсіресе, нақты сәтсіздіктер жеткіліксіз болған кезде және сенсорлар терабайт телеметриясын үздіксіз жасаған кезде дұрыс. Жоғарыда аталған Pagano мақаласы анықтамалық кезеңде ақаусыз оқытылған LSTM желісі артқы Байес жаңартуымен бірге қолмен белгіленген ақауларға аз сүйене отырып, жаңа деректер ағыны кезінде компоненттің жарамды күйінің ықтималдығын бағалауға мүмкіндік беретінін көрсетеді [2].

Жартылай оқыту белгіленген және белгіленбеген үлгілерді біріктіреді: алдымен шектеулі негізгі сұраныс бойынша базалық модель құрылады, содан кейін ол жалпылау қабілетін арттыра отырып, өңделмеген деректер телеметриялардың үлкен массасында оқытылады. Мұндай гибрид сыну сирек кездесетін салаларда сұранысқа ие және олардың белгілерін жазу көп уақытты қажет етеді. Ерте болжаудың кілті - уақыт қатарларын дұрыс модельдеу. ARIMA (p, d, q) классикалық авторегрессиялық модельдері рекурсиямен сипатталады (7).

$$\Phi_p(B) = (1 - B)^d x_t = \theta_q(B) \varepsilon_t \quad (1.7)$$

мұндағы: B - ауысым операторы;

Φ_p және θ_q - p және q тәртіп көпмүшелері. ARIMA біркелкі таңдалған сигналдар үшін пайдалы (мысалы, қысым), бірақ сызықтық емес, әсерлі ауытқуларда күшін жоғалтады [5]. Сондықтан, өнеркәсіптік жағдайда ол қайталанатын желілермен толықтырылады - LSTM және GRU - олар тапсырысты қолмен таңдамай, алыс тәуелділіктерді алады [2]. Іс жүзінде "жылжымалы терезе" әдісі жиі қолданылады (8).

$$x_t = [x_{t-\omega+1}, x_{t-\omega+2}, \dots, x_t] \quad (1.8)$$

мұндағы: t - деректер ағынындағы ағымдағы дискретті уақыт моменті (соңғы алынған үлгі);

ω - жылжымалы терезенің ені - біз модельге бір уақытта қанша өлшем береміз; көбінесе дірілдің бір-екі кезеңін немесе машинаның жұмыс циклін түсіру үшін таңдалады;

$x_t - t - \omega + 1$ - ден t - ға дейінгі барлық бақылауларды қамтитын көп өлшем, болжамды фактімен салыстыра отырып, желіні келесі қадамды болжауға үйретеді [9].

Аномалияны анықтау теориясы статистикалық қашықтыққа сүйенеді. Көпөлшемді сигналдар үшін T^2 Хотеллинг статистикасы және қалдық дисперсия Q қолданылады (9), (10).

$$T_t^2 = (x_t - \bar{x})^T S^{-1} (x_t - \bar{x}), \quad (1.9)$$

$$Q_t = ||x_t - Px_t||_2^2 \quad (1.10)$$

мұндағы: $\bar{x}$ - орташа вектор;

S - ковариациялық матрица;

P - негізгі компоненттер матрицасы. Шекті мәндер χ^2 және Γ үлестірімдерінен алынады, олардың жиынтық асып кетуі стандартты емес режим туралы сигнал береді [8].

Осылайша, мұғаліммен оқыту сирек кездесетін, бірақ белгілі сәтсіздіктерді дәл болжауды қамтамасыз етеді, мұғалімсіз оқыту және вариациялық автоэнкодерлер белгісіз деградация сценарийлерін сүзеді, жартылай оқыту және онлайн Байес теоремасын алынған мәндерді жаңартуы статикалық модельді өзгермелі жұмыс жағдайларына төзімді тірі бейімделу механизміне айналдырады. Осы принциптерді біріктіру PdM-дің ғылыми негізделген негізін құрайды, ол күтпеген тоқтап қалуды азайтады және тіпті ескірген жерлерде де техникалық қызмет көрсету шығындарын оңтайландырады, өнеркәсіпті индустрия 4.0 тұжырымдамаларын толық форматта жүзеге асыруға жақындатады. Жиынтықта көрсетілген қағидаттар реактивті және профилактикалық қызмет көрсетуден индустрия 4.0 және индустрия 5.0 инфрақұрылымында масштабтауға дайын шын мәнінде болжамды стратегияға көшуге мүмкіндік беретін іргетасты қалыптастырады.


Болашақта индустрия 5.0 технологияларының дамуы физикалық және эмпирикалық модельдерді біріктіретін гибриді AI модельдерін қолданатын одан да икемді және бейімделгіш жүйелерге әкеледі [5].

1.3 Төртінші өнеркәсіптік революция жағдайындағы Қазақстан өнеркәсібін дамытудың заманауи сын-тегеуріндері мен перспективалары

Қазақстан Республикасының (ҚР) өнеркәсіп секторы әртүрлі салаларды қамтиды, олардың алдыңғы қатардағылары машина жасау, тамақ өнеркәсібі, тау-кен металлургия кешені (ТМК) және энергетика болып табылады. Бұл салар даму деңгейіне, техникалық негізге және халыққа қызмет көрсетудің заманауи әдістерін енгізу әлеуетіне қарай әр түрлі.

Қазақстанның машина жасау саласы оның дамуы тарихи тұрғыдан шикізат секторларынан төмен болғанымен, өсу әлеуетін көрсетіп отыр. 2010 жылдардың басында өнім шығарудың айтарлықтай өсуі байқалды - 26,4% – ға, шамамен 209 млрд теңге көлеміне жетті [13]. Негізгі проблема кеңес заманынан бері мұраға қалған жабдықтардың техникалық артта қалуы және жоғары тозуы болып қала береді. Көптеген кәсіпорындар бірнеше онжылдықтар бұрын жасалған машиналар мен желілерді басқарады, бұл өнімділікті тежейді және модернизацияға қомақты инвестицияны қажет етеді. Бұл жағдайда болжамды техникалық қызмет көрсетуді (PdM) енгізу

әсіресе өзекті болып көрінеді. Мысалы, локомотив және вагон жөндеу кәсіпорындары сияқты ірі машина жасау зауыттарында болжамды жүйелерді пайдалану станоктардың дірілін, кесу құралдарының тозуын және мойынтіректердің температурасын бақылауға мүмкіндік береді. Бұл кенеттен бұзылуды азайтуға, өнімнің істен шығуын азайтуға және құбырлардың тоқтап қалуын азайтуға көмектеседі. Бір қызығы, машина жасау саласы цифрландыру деңгейі бойынша көшбасшылар қатарында, бұл PdM енгізу үшін қолайлы жағдайлар жасайды. Қазақстанның тамақ өнеркәсібі ішкі нарыққа және ауыл шаруашылығы шикізатын қайта өңдеуге бағдарланған, бұл жылына 9% деңгейінде тұрақты өсімді көрсетеді [13]. Көптеген кәсіпорындар үздіксіз жұмыс істейді және жабдықтың кез келген тоқтауы өнім өндірісіне тікелей әсер етеді. Болжалды техникалық қызмет көрсету компьютерлік көру арқылы құбырдағы сапаны бақылауға және қозғалтқыштар мен сорғылардың күйін нақты уақыт режимінде бақылауға мүмкіндік береді. Бұл әсіресе сүт және ет өңдеу зауыттары үшін өте маңызды. Тау-кен металлургия кешені (ТМК) бюджеттің едәуір үлесін қамтамасыз ете отырып, Қазақстан экономикасында шешуші рөл атқарады. Инфрақұрылымның тозуына қарамастан, соңғы жылдары ТМК шетелдік инвестициялардың арқасында жаңғыртылуда. Мысалы, кеніштерде техниканы бақылауды автоматтандыру үшін цифрлық мониторинг жүйелері енгізілуде. Бұл бос уақытты қысқартуға және жұмыс қауіпсіздігін арттыруға мүмкіндік береді. Инфрақұрылымның көп бөлігі ескірген энергетикалық секторда PdM енгізу апаттық өшірулердің алдын алуға және жабдық ресурсын ұзартуға қабілетті. Атап айтқанда, Экебастуздағы жылу электр станциясында болжамды қызмет көрсетуді қолданбау ауқымды апатқа және - 30 °C - тан төмен ауа температурасында қаланы жылумен және электрмен жабдықтаудың істен шығуына әкелді [10]. Келесі 1.5-суретте Қазақстан өнеркәсібінің алдыңғы қатарлы өндіріс орынының басқару бөліктері. Мұндай жағдай жабдықты жаңарту ұзақ уақыт бойы жүргізілмеген және реактивті техникалық қызмет көрсету негізі техникалық қызмет ретінде саналатын ескі өндірістерде жиі кездеседі.



1.5-сурет – Реактивті қызмет көрсетудің салдары

ҚР-дағы салаларды цифрландыру деңгейі (консалтингтік зерттеу деректері бойынша Қазақстанның өңдеу өндірістерінің цифрлық жетілуін бағалау). Ординат осі бойынша цифрлық дамудың интегралдық деңгейі, абсцисс осі бойынша – уақыт кейінге қалдырылды, түспен динамика белгіленді, көк – консервативті өсу, жасыл – өсудің баяулауы, қызғылт сары – цифрландырудың жеделдетілген өсуі. Машина жасау, құрылыс, тамақ өнеркәсібі және металлургия жеделдетілген цифрлық өсу аймағында тұрғанын көруге болады, ал кейбір салалар (ағаш өңдеу, тоқыма, жиһаз өндірісі және т.б.) баяу дамып келеді [15]. Бұл графикті 1.6 - суреттен көре аласыз.



1.6-сурет – ҚР-дағы салаларды цифрландыру деңгейі

ҚР өнеркәсібі үшін аса маңызды сын-тегеуріндердің бірі-кеңестік индустриялық өткенмен сабақтастықтың алшақтығымен шиеленіскен білікті инженерлік кадрлардың жетіспеушілігі. Инженерлер мен техникалық мамандар – кез келген дамыған өнеркәсіптің іргетасы, алайда Қазақстанда олардың тапшылығы қатты сезіле бастады. КСРО ыдырағаннан кейінгі үш онжылдықта елде көптеген ірі өнеркәсіптік кәсіпорындар, әсіресе машина жасау және онымен байланысты салаларда таратылды. Мысалы, Алматыда АХБК (Мақта комбинаты), АДК (үй құрылысы комбинаты) және т. б. зауыттар жоғалып кетті. [16]. нәтижесінде мыңдаған инженерлер істерде қалмады, техникалық мамандықтардың беделі төмендеді, ал жаңа инженерлерді даярлау жүйесі қысқарды. Кеңес мектебінің егде жастағы мамандары біртіндеп зейнетке шығады, ал жас буын инженерлері жеткіліксіз – "кәсіби инженерлер жоқ", - дейді сарапшылар [16]. Бұл проблеманың сандық көрінісі бар: еңбек министрлігінің мәліметі бойынша, қазір елде 900 мыңға жуық техник (оның ішінде инженерлер) жетіспейді және

тапшылықтың 2030 жылға қарай 1,6 миллион білікті жұмысшыға дейін өсуі болжануда өнеркәсіпте, құрылыста, ауыл шаруашылығында және көлікте ерекше кемшілік сезіледі [17]. Яғни, дәл Күрделі жабдықтарды пайдалану және оларға қызмет көрсету дағдылары талап етілетін нақты сектор салаларында [17].

Қазақстанда болжамды техникалық қызмет көрсету (PdM) көптеген салаларда енгізудің жоғары әлеуетіне ие. Өңдеу өнеркәсібінде мұндай шешімдер жабдықтың жоспарланбаған тоқтап қалуын едәуір төмендетіп, оның қызмет ету мерзімін 20-40% - ға ұзартуы мүмкін [17]. Мысалы, машина жасау мен металлургияда кескіш құралдардың дірілі мен тозуын бақылау жүйелерін пайдалану апаттық тоқтаулардың алдын алу арқылы проблемаларды алдын ала анықтауға мүмкіндік береді. Тамақ өнеркәсібі сонымен қатар сорғылардың, қозғалтқыштардың және тоңазытқыш жабдықтарының күйін бақылау арқылы PdM-ден пайда көреді, бұл өндірістің сапасы мен тұрақтылығын арттырады. Тау-кен өнеркәсібінде PdM әсіресе карьерлер мен шахталардың қашықтығына байланысты маңызды. Энергетикада болжамды техникалық қызмет көрсету турбиналар мен трансформаторлардың дірілін бақылауға мүмкіндік береді, бұл апаттық өшірулердің алдын алады. Машиналық оқыту мен цифрлық егіздерді пайдалану жабдықтың күйін жоғары дәлдікпен болжауға мүмкіндік береді, бұл PdM-ді 4.0 индустриясына көшудің ажырамас бөлігі етеді .

Қорытындылай келе, болжамды техникалық қызмет көрсету Қазақстан өнеркәсібі үшін жаңа көкжиектер ашады. Оны енгізу бірден бірнеше стратегиялық міндеттерді шешуге ықпал етеді: тиімділікті арттыру және өнім шығару әлеуетін көтеру, апаттылық пен тоқтап қалуды азайту, технологиялық құзыреттер мен кадрлық әлеуетті дамыту. Әрине, бұл жолда жабдықтар паркін жаңартудан бастап жүздеген инженерлерді жаңа жұмыс әдістеріне үйретуге дейінгі көптеген қиындықтарды жеңу керек. Дегенмен, алғашқы қадамдар жасалуда: цифрландырудың пилоттық жобалары іске асырылуда, Мемлекет индустрия 4.0 бағытын қолдайды, кәсіпорындар деректердің актив ретіндегі құндылығын түсінеді. Ғылыми зерттеулердің нәтижелері мен практикалық тәжірибе болжамды қызмет көрсетудің ҚР өнеркәсіп секторын дамудың сапалы жаңа деңгейіне ауыстыратын инновациялардың векторы бола алатындығын көрсетеді [10]. Жоғары бәсекелестік және жаһандық технологиялық өзгерістер жағдайында қазақстандық кәсіпорындардың артта қалмауы маңызды: реактивті парадигмадан техникалық қызмет көрсетудегі болжамды парадигмаға көшу елдің заманауи, өнімді және тұрақты өнеркәсіптік кешенін құру жолындағы елеулі қадам болады.

1.4 Болжалды техникалық қызмет көрсетуді іске асырылған жобалар мен шешімдерге шолу

Болжалды техникалық қызмет көрсету тұжырымдамасы бірнеше ондаған жылдар бойы кеңінен зерттелді. Scopus дерекқорында индекстелген ғылыми әдебиеттердің библиометриялық талдауы болжамды техникалық қызмет көрсетуге бағытталған 20 187-ден астам ғылыми құжаттарды анықтады, бұл осы салаға ғылыми қызығушылықтың үздіксіз өсуін көрсетеді. Атап айтқанда, бұл басылымдардың шамамен 25% - ы инженерлік салаға жатады, бұл оның техникалық қызмет көрсету стратегияларын дамытудағы маңызды рөлін көрсетеді. Сонымен қатар, информатика мен медицина жарияланған әдебиеттердің шамамен 15% құрайды, бұл пәнаралық сипатқа және болжамды қызмет көрсету әдістерінің кең қолданылуына баса назар аударады [10]. 1.7-сурет біздің тақырыпта жазылған ғылыми жұмыстардың библиометриялық талдау



1.7-сурет – Библиометриялық талдау

PdM-ге жасанды интеллект интеграциясы ML тәжірибесіне, физикалық заңдарына және әдістеріне негізделген істен шығу уақытын болжауға баса назар аударатын "болжамды қызмет көрсетуге арналған машиналық оқыту моделі" зерттеуінде толығырақ қарастырылады. Бұл тәсіл ақаулы компоненттерді уақтылы ауыстыруға ықпал етеді, осылайша жүйенің сенімділігін арттырады [23].

PdM-де жасанды интеллект (AI) және деректерді талдау интеграциясы кеңінен зерттелуде. 4.0 индустриясында AI негізіндегі техникалық қызмет көрсетуді болжау техникалық қызмет көрсету стратегияларын жетілдіру үшін деректер аналитикасын, терең оқытуды және киберфизикалық жүйелерді пайдалануды қамтиды. Шолуда Саманта және басқалар. (2024) логистикалық регрессияны, тірек векторларының регрессиясын және нейрондық желілерді

қоса алғанда, AI негізіндегі PdM әдістері жабдықтың ұзақ өмір сүруіне және жұмыс тиімділігін арттыруға ықпал ететінін атап өтті [6]. Сол сияқты, Гао және басқалар. (2023) ақауларды интеллектуалды диагностикалау үшін automl негізіндегі терең оқыту жүйесін ұсынды, бұл CNN негізіндегі модельдер сенсорлық деректерді кескінге ұқсас көріністерге түрлендіру арқылы болжау дәлдігін арттыратынын көрсетті [37].

PdM - дегі негізгі мәселелердің бірі-үздіксіз оқыту қажеттілігі, өйткені статикалық ML модельдері көбінесе өзгертін өндірістік жағдайларға бейімделе алмайды. Хуртадо және басқалар (2023) дәстүрлі ML модельдерінің стационарлық емес ортамен жұмыс жасаудағы шектеулерін талқылады және адаптивті PdM модельдерінің шешімі ретінде үздіксіз оқытуды ұсынды [7].

Заманауи өнеркәсіптік тәжірибе деректерді талдау мен машиналық оқытуға негізделген болжамды техникалық қызмет көрсету жүйелерін біріктірудің тұрақты тенденциясын көрсетеді. Қарастырылып отырған тәсілдің қолданбалы маңыздылығын растау үшін осы тарауда халықаралық және жергілікті іске асырылған алты жобаға талдау жасалады. Шешімдердің әрқайсысы көлік пен медицинадан бастап тау – кен және өңдеу өнеркәсібіне дейінгі әртүрлі салаларды қамтиды және болжамды аналитикалық технологиялардың әмбебаптығы мен ауқымдылығын көрсетеді. Шешімдердің архитектурасына, қолданылатын деректер түрлеріне, іске асыру ерекшеліктеріне және алынған әсерлерге назар аударылады.

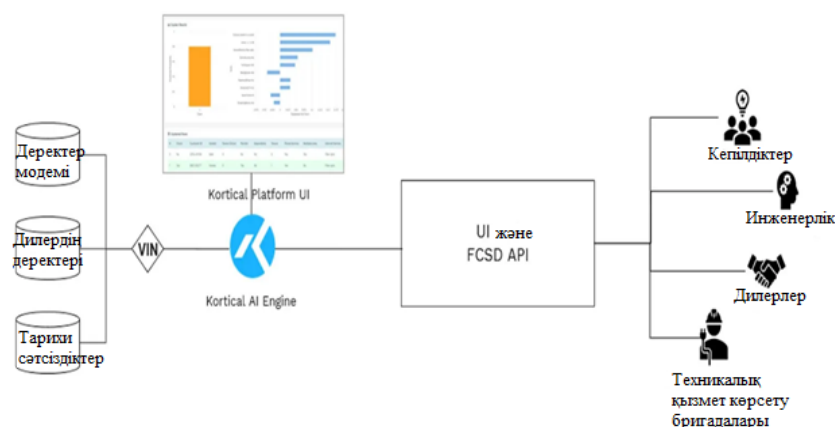
Болжалды қызметті табысты халықаралық қолданудың бір мысалы- Deutsche Bahn инфрақұрылымында іске асырылған Konux (Германия) компаниясы жүйесі. Жүйе компоненттердің тозуын анықтау және болжау үшін машиналық оқыту алгоритмдерін қолдана отырып, теміржол көрсеткілерінен діріл деректерін жинайды және талдайды [18]. Осы шешімді енгізу нәтижесінде күтпеген жөндеулер санын қысқартуға, теміржол көлігі жұмысының сенімділігін арттыруға және пайдалану шығындарын азайтуға мүмкіндік туды. Бұл тәсілдің артықшылығы-қызмет көрсетуді белгіленген кесте бойынша емес, объектінің жай-күйі бойынша болжау мүмкіндігі. Келесі 1.8-суретте болжамды қызмет үшін теміржолға орнатылған сенсорлар [18].



1.8-сурет – Инфрақұрылымды болжамды бақылау үшін теміржолға орнатылған KONUS сенсоры


Автокөлік алыбы Форд (АҚШ) болжамды аналитиканы өз көліктеріне техникалық қызмет көрсету процестеріне сәтті біріктірді. Машиналық оқыту клиенттердің көліктеріне орнатылған көптеген сенсорлардан нақты уақыт режимінде жиналған деректерді талдауға мүмкіндік береді, осылайша жеке тораптар мен қондырғылардың (Kortical) істен шығу ықтималдығын болжайды [25]. Осы тәсілдің арқасында компания күтпеген бұзылуларға байланысты қызмет көрсету орталықтарына жүгіну санын едәуір қысқартты, бұл клиенттердің қанағаттануын едәуір арттырды. Бұл мысал үздіксіз мониторингке және техниканың техникалық жағдайын динамикалық болжауға бағытталған тәсілдің артықшылығын көрсетеді. 1.9 - суретте Kortical жасанды интеллектке негізделген болжамды аналитикалық жүйенің тұжырымдамалық архитектурасы көрсетілген. Жүйе VIN нөмірі бойынша анықталатын және Kortical AI қозғалтқышы арқылы өңделетін көлік модемдерінің, дилерлердің және тарихи ақаулардың деректерін біріктіреді [25].

Concept Solution Design



1.9-сурет – Kortical платформасындағы болжамды аналитика архитектурасы

Келесі кезекте Honeywell Forge - ауыр және мұнай-химия өнеркәсібіндегі мониторингке, басқаруға және болжамды талдауға бағытталған заманауи өнеркәсіптік деңгейдегі цифрлық платформа. Бұл жүйе әртүрлі деректер көздерімен, соның ішінде сенсорлық сигналдармен, SCADA жүйелерімен, бейне аналитикамен, сондай-ақ нақты уақыт режимінде сыртқы көздермен интеграциялауға арналған [19]. Осының арқасында жабдықтың жай-күйі туралы деректер талдау, визуализация және шешім қабылдау үшін қолжетімді болатын бірыңғай цифрлық орта қамтамасыз етіледі. Төмендегі 1.10-суретте Honeywell Forge жүйесіндегі бақылау тақтасы әртүрлі критерийлер бойынша объектілердің интегралды өнімділік көрсеткіштерін көрсетеді: қуат тұтыну, киберқауіпсіздік, кеңістікті пайдалану, жабдықтың өнімділігі және жайлылық деңгейі [19].




1.10-сурет – Honeywell Forge жүйесіндегі өндірістік жабдықтардың көрсеткіштерін визуализациялау

Honeywell Forge қолданудың негізгі бағыттарының бірі-мұнай өңдеу саласы. Атап айтқанда, платформа Сауд Арабиясының ірі өнеркәсіптік нысандарында белсенді қолданылады, онда ол жоғары жүктеме және процестердің маңызды маңыздылығы жағдайында өзінің тиімділігін дәлелдеді [19]. Жүйе ректификациялық бағандар, сорғылар, компрессорлар және жылу алмастырғыштар сияқты элементтердің күйін бақылауды қамтамасыз етеді. Әрбір түйін үшін параметрлердің уақыт қатарлары жиналады (температура, қысым, ағын, діріл), олар терең оқыту алгоритмдерін қолдану арқылы талданады. Бұл алгоритмдер сәтсіздікке дейін қалыпты жағдайдан ауытқуларды анықтай алады.

Қазақстандық жобалар да болжамды қызмет көрсетуді табысты енгізуді көрсетуде. Мысалы, QAZ Neurotech компаниясы мұнай-газ және тау-кен салаларындағы өнеркәсіптік жабдықтар тораптарының жай-күйін бақылауға мүмкіндік беретін діріл-акустикалық датчиктер негізінде жүйе құрды. Машиналық оқыту алгоритмдері мойынтіректердің ерте сатысында тозу және қызып кету белгілерін анықтайды. Мұндай тәсіл Қазақстан кәсіпорындарына көптеген апаттардың алдын алуға және оның пайдалану сенімділігін арттыра отырып, техниканың тоқтап қалуын қысқартуға мүмкіндік береді [24].

Тағы бір Қазақстандық мысал - тамақ өндірісінде IoT - шешімдерді іске асырған Faceplate стартапы. Faceplate - бұл өнеркәсіптік нысандардың цифрлық егіздерін құруға және нақты уақыттағы бақылау жүйелерін біріктіруге арналған заманауи бұлттық платформа. Платформа SCADA жүйелеріне, OPC UA, MQTT қосылымдарын қолдайды және интуитивті басқару тақтасында деректерді визуализациялауға мүмкіндік береді [26]. Faceplate аппараттық құралдың күйін икемді көрсетуді, оқиғалар мен дабылдарды талдауды қамтамасыз етеді және кіріктірілген Машиналық оқыту үлгілеріне негізделген болжамды аналитиканы жүзеге асырады. Негізгі артықшылықтардың бірі-конфигурацияның қарапайымдылығы және бағдарламалауды қажет етпестен орналастыру мүмкіндігі. Платформа энергетика, тамақ және өңдеу өнеркәсібінде белсенді қолданылады [26]. Келесі 1.11-суретте SCADA-Қазақстанның энергожүйесінде жиілік графигі және қуаттың бөлінуі бар жүйені визуализациялау.



1.11-сурет – Телеметрия деректері бар электр жүйесінің сандық картасының мысалы


Жоғарыда келтірілген барлық мысалдарды жан-жақты талдау жасанды интеллект, машиналық оқыту (ML), OPC UA және SCADA сияқты заманауи деректер құралдарын пайдалана отырып, болжамды қызмет көрсету жүйелерін біріктіру, жабдықтың сенімділігін арттыру және оны пайдалану шығындарын азайту үшін оңтайлы шешім екенін көрсетеді. Зияткерлік техникалық қызмет көрсетуге көшу Қазақстан кәсіпорындарына өндірістік жүйелердің бәсекеге қабілеттілігін, сенімділігін арттыруға және индустрия 4.0 тұжырымдамасын іске асыру үшін база құруға мүмкіндік береді. PdM енгізу-бұл тиімділікті арттырудың жолы ғана емес, сонымен қатар елдің тұрақты дамуы мен технологиялық тәуелсіздігіне жасалған қадам.

2 Зерттелетін жүйенің әдіснамасы

2.1 Болжалды қызмет үшін машиналық оқыту түрлеріне шолу. Машиналық оқыту түрін таңдау

Болжалды техникалық қызмет көрсетудің негізгі мәселелердің бірі сынып теңгерімсіздігі болып табылады. Көп жағдайда қалыпты жағдайлар тіркеледі және сәтсіздіктердің мысалдары өте аз. Бұл модельдерді оқытуды қиындатады және дәстүрлі дәлдік көрсеткішін пайдалы емес етеді. Неғұрлым барабар көрсеткіштер Precision, Recall және F1-score болып саналады. Бұл зерттеу классикалық алгоритмдерден (SVM, Random Forest) терең (CNN, LSTM) және генеративті тәсілдерге (VAE) дейінгі ML модельдеріне салыстырмалы талдау жасайды. Бас тарту мысалдарын қажет етпейтін, тек қалыпты жұмыс жағдайында үйренуге және Байес жаңартуы арқылы жаңа деректерге бейімделуге қабілетті вариациялық автоэнкодерге ерекше назар аударылады.

2.1-суретте қарастырылып отырған модельдерді негізгі критерийлер бойынша жалпыланған салыстыру келтірілген. Модельдер түрі бойынша топтастырылған (бақыланатын – сәтсіздік белгілерін қажет етеді, ал қадағаланбайтын – онсыз жұмыс істейді), сондай-ақ болжамды қызмет көрсету контекстінде олардың салыстырмалы күшті және әлсіз жақтары көрсетілген.



2.1-сурет – Болжалды техникалық қызмет көрсету тапсырмаларында машиналық және терең оқыту модельдерінің дәлдігін (ассигасу) салыстыру

SVM (анықтамалық векторлық әдіс) - бақыланатын модель. Белгіленген

деректерді қажет етеді (оқу үшін "бас тарту" сыныбы болуы керек). Өнеркәсіптік деректерде қол жетімді жіктеу дәлдігі шамамен 0.78 құрайды [27].

- Артықшылықтары: шағын үлгілерде жақсы жұмыс істейді, сыныптарды нақты бөлуде тиімді, ядро функциялары сызықтық емес тәуелділіктерді ескеруге мүмкіндік береді;

- Кемшіліктері: ядро таңдауына және регуляризация параметрлеріне сезімтал, үлкен белгілер жиынтығына шектеулі масштабталады, деректердегі уақытша тәуелділіктерді есепке алмайды.

Random Forest (кездейсоқ орман) - бақыланатын модель. Сәтсіздік белгілерін қажет етеді. PdM тапсырмаларындағы тән дәлдік 0.75–0.85 диапазонында [27].

- Артықшылықтары: ағаштарды ансамбльдеу арқылы қайта оқытуға төзімді, белгілердің маңыздылығын анықтауға мүмкіндік береді, әртүрлі кіріс түрлерімен жұмыс істейді;

- Кемшіліктері: есептеу шығындарын арттыра отырып, көптеген ағаштарды қажет етуі мүмкін, деректердің уақыт сипаттамаларын ескермейді, сыныптардың қатты теңгерімсіздігіне сезімтал.

CNN (конволюциялық нейрон желісі) - бақыланатын терең модель. Белгіленген деректерді қажет етеді, бірақ синтетикалық үлгілерде де оқытылуы мүмкін. Діріл сигналдарын диагностикалау кезінде қол жетімді жіктеу дәлдігі 80-85% құрайды [28].

- Артықшылықтары: жергілікті белгілерді автоматты түрде шығарады (жиіліктер, құрылымдық ауытқулар), шуға төзімді, жақсы масштабталады;

- Кемшіліктері: оқу деректерінің үлкен көлемін қажет етеді, аз түсіндіріледі ("қара жәшік"), қосымша қайталанатын қабаттарсыз уақытша тәуелділіктерді есепке алмайды.

LSTM (Long Short-Term Memory) – бақыланатын қайталанатын модель. Белгіленген уақыт реттілігінде (істен шығу жай-күйін көрсете отырып, сенсорлық айғақтар тарихы) оқытылады. Техникалық ақауларды болжау кезінде қол жеткізілген жіктеу дәлдігі - 0.85-0.90 [27].

- Артықшылықтары: уақытша тәуелділіктер мен деградациялық тенденцияларды тиімді қарастырады, уақытша тапсырмаларда тұрақты нәтижелерді көрсетеді [28];

- Кемшіліктері: белгіленген деректердің көп мөлшерін қажет етеді, оқыту көп уақыт пен ресурстарды алады, тым ұзақ немесе әртүрлі тізбектерде қайта оқытылуы мүмкін.

Variational Autoencoder (VAE) – бақылаусыз (unsupervised) модель. Ол жабдықтың қалыпты жұмысына сәйкес келетін мәліметтерден ғана үйренеді. Ауытқуларды анықтаудағы әдеттегі жіктеу дәлдігі жағдайларға байланысты 0.90-тен 0.94-ға дейін өзгереді [30].

- Артықшылықтары: сәтсіздік мысалдарын қажет етпейді, бұл әсіресе сирек кездесетін жағдайларда маңызды, бұрын белгісіз ақаулардың


түрлерін анықтай алады, аномалия дәрежесін сандық бағалауды қамтамасыз етеді. Байес жаңартуы арқылы модельді бейімдеуді қолдай отырып, жаңа деректерден оңай үйренеді [30];

- Кемшіліктері: ауытқу шегін таңдауға сезімтал (Recall және Precision арасындағы тепе-теңдік), егер олар "нормаға" енгізілген болса, тұрақты қайталанатын ауытқуларды танымауы мүмкін, оқыту деректерін мұқият дайындауды қажет етеді (барлық деректер шынымен қалыпты деп есептеледі).

Жалпы тенденциялар: терең модельдер (CNN, LSTM және олардың комбинациясы) көп өлшемді сенсорлық деректердің үлкен көлемімен және күрделі сәтсіздік үлгілерімен ең жоғары дәлдікті көрсетеді [27]. алайда, шектеулі үлгілерде классикалық әдістер салыстырмалы нәтижелерді көрсете алады. Мысалы, компрессорды диагностикалау кезінде Random Forest жіктеу дәлдігі бойынша LSTM-ден сәл ғана озып кетті, ал LSTM жөндеуден кейін тұрақты мінез-құлықты қамтамасыз етті [28].

Бақыланбайтын модельдер белгіленген сәтсіздіктер болмаған кезде әсіресе өзекті болады. Олар кез-келген ауытқуларды анықтауға негізделген болжамды қызметті ұйымдастыруға мүмкіндік береді, тіпті ақаулардың жаңа түрлері болған жағдайда да. VAE әсіресе ықтималдық сипатымен, жоғары бейімделуімен және үздіксіз қайта даярлау қабілетімен ерекшеленеді. Зерттеулер гибриді тәсілдердің тиімділігін қолдайды, мұнда ауытқулар VAE арқылы анықталады, содан кейін мамандандырылған жіктеу моделімен нақтыланады [29].

Құрылымдық жағынан VAE екі негізгі компоненттен тұратын классикалық автоэнкодер негізінде құрылады: энкодер және декодер. Энкодер бастапқы деректерді кіріске қабылдайды және оны жасырын кеңістіктегі қабаттардағы айналдырады. Декодер өз кезегінде алынған жасырын вектор негізінде бастапқы деректерді қалпына келтіруге тырысады. Төмендегі 2.2-суретте VAE құрылымдық сұлбасы көрсетілген.



2.2-сурет – VAE - дің құрылымы

VAE-дің басты ерекшелігі-кодтау процесіне стохастиканы енгізу, бұл модельге бақыланатын мәліметтерге қатысты жасырын айнымалылардың шынайы артқы таралуын жуықтауға үйретуге мүмкіндік береді. Бұл деректерді дәлірек қалпына келтіруге ғана емес, сонымен қатар бастапқы деректерге ұқсас жаңа үлгілерді жасауға мүмкіндік береді, бұл өндірістік жабдықтың қалыпты мінез-құлқын модельдеу міндеттері үшін өте маңызды.

VAE тренингі вариацияның төменгі шегін максимизациялауға негізделген (Evidence Lower Bound, ELBO) деректердің сенімділік логарифмі. Ресми түрде оқыту тапсырмасы келесідей жазылуы мүмкін (11) [29].

$$\log p(x) \geq E_{q(z|x)}[\log p(x|z)] - D_{KL}(q(z|x)||p(z)) \quad (2.1)$$

мұндағы x - бақыланатын деректер;

z - жасырын айнымалылар;

$p(x)$ - деректердің шынайы таралуы;

$p(z)$ - жасырын айнымалылардың априорлық таралуы, әдетте стандартты қалыпты үлестіру;

$q(z|x)$ - энкодер параметрімен параметрленген жасырын айнымалылардың артқы таралуына жуықтау;

$p(x|z)$ - жасырын кеңістіктен деректерді қалпына келтірудің ықтималдық моделі, рендеринг арқылы рендеринг;

$D_{KL}(\cdot || \cdot)$ - жуықталған және априорлық үлестіру арасындағы Кульбака–Лейблера дивергенциясы. Өрнектің бірінші бөлігі $E_{q(z|x)}[\log p(x|z)]$ жасырын айнымалыларға негізделген деректерді қалпына келтірудің сенімділік логарифмінің күтілетін мәнін білдіреді. Ол қалпына келтіру сапасына жауап береді: декодер бастапқы деректерді қаншалықты жақсы қалпына келтіре алады. Екінші $D_{KL}(q(z|x)||p(z))$, жуықталған жасырын үлестіру мен таңдалған априорлық үлестіру арасындағы айырмашылықтың өлшемі. Бұл компонент реттегіш ретінде әрекет етеді, бұл модельді жасырын кеңістікті ұйымдастыруға және қайта оқытудан аулақ болуға мәжбүр етеді.

Интуитивті түрде VAE жаттығулары қалпына келтіру дәлдігі мен жасырын кеңістіктің құрылымдылығы арасындағы компаға келеді. Егер модель тек деректерді қалпына келтіруге бағытталған болса, жасырын кеңістік тым күрделі және ретсіз болуы мүмкін, бұл жаңа деректерді шығаруды және ауытқуларды анықтауды қиындатады. Екінші жағынан, шамадан тыс регуляризация кіріс туралы ақпараттың жоғалуына әкелуі мүмкін. Осы екі аспект арасындағы тепе-теңдікке ELBO оңтайландыру арқылы қол жеткізіледі [36].

VAE-дің аномалияларды анықтау міндеттері үшін ерекше маңыздылығы олардың қалыпты (ақаусыз) деректерден сабақ алу және жабдықтың қалыпты жұмыс істеу заңдылықтарын көрсететін тығыз жасырын

кеңістік құру қабілетімен түсіндіріледі. Ықтимал ауытқулары бар жаңа деректерді өңдеу кезінде модель оларды жеткілікті түрде қалпына келтіре алмайды, өйткені олар бұрын зерттелген үлестірімге сәйкес келмейді. Бұл ақаулықтың көрсеткіші ретінде пайдалануға болатын қалпына келтіру қатесінің жоғарылауына әкеледі.

Осылайша, болжамды техникалық қызмет көрсету үшін VAE қолданудың негізгі гипотезасы мынада: қалыпты деректер қалпына келтірудің төмен қателігіне әкеледі, ал ақауларға немесе жабдықтың ықтимал ақауларына байланысты қалыптан тыс деректер бұл қатенің айтарлықтай өсуіне әкеледі. Сондықтан қалпына келтіру қателерінің таралуын талдау маңызды ақаулар басталғанға дейін жабдық күйіндегі ауытқуларды тиімді анықтауға мүмкіндік береді.

Математикалық тұрғыдан белгілі бір бақылау үшін қалпына келтіру қатесі x ретінде анықталуы мүмкін (12).

$$Loss(x) = ||x - \hat{x}||^2 \quad (2.2)$$

мұндағы x - бақыланатын деректер;

$\hat{x}$ - деректер энкодер мен декодер арқылы өткеннен кейін алынған реконструкцияланған деректер;

$|| \cdot ||$ - Евклид нормасы. Практикалық сценарийлерде VAE негізінде болжамды жүйені құру үшін қалпына келтіру қатесінің шегі қалыптасады, оның асып кетуі аномалияның болуы ретінде түсіндіріледі. Шекті таңдау Оқу жинағындағы қателерді бөлуді талдау негізінде немесе percentile thresholding немесе ROC талдауы сияқты тәсілдерді қолдану арқылы жүзеге асырылады.

Сонымен қатар, Вариациялық автоэнкодерлер ықтималдық генеративті модельдердің кең класының маңызды бөлігі болып табылатындығын атап өткен жөн. Олардың белгіленген нүктелермен емес, үлестірулермен жұмыс істеу қабілеті оларға белгісіздік көрінісінде икемділік береді, бұл өлшеу дәлдігі шектеулі және деректер шулы болуы мүмкін өнеркәсіптік қосымшаларда өте маңызды [38].

Құрылымдық жағынан, VAE-дегі кодтаушы белгілер векторын қабылдайтын және қалыпты таралу параметрлерін шығаратын нейрондық желі ретінде жүзеге асырылады: орташа μ векторы және $\log \sigma^2$ дисперсиялық логарифм векторы. Стохастикалық іріктеу операциясы арқылы қатенің кері таралу мүмкіндігін қамтамасыз ету үшін "репараметризация трюкі" (reparameterization trick) деп аталады. Бұл әдіске сәйкес жасырын айнымалыны іріктеу формула бойынша жүзеге асырылады (13).

$$z = \mu + \sigma \phi \epsilon, \epsilon \sim N(0, I) \quad (2.3)$$

мұндағы ϕ - элементтік көбейтуді білдіреді;

ϵ - стандартты қалыпты үлестірімнен алынған кездейсоқ шама. Бұл тәсіл іріктеудің стохастикалық сипатына қарамастан желі параметрлері

бойынша градиентті түсіруге мүмкіндік береді.

VAE-ді қолданудың артықшылығы-олардың әмбебаптығы: бірдей архитектураны физикалық Сенсорлардан (мысалы, діріл, температура) деректерді талдау үшін де, машиналық көру жүйелерінен алынған визуалды ақпаратты өңдеу үшін де қолдануға болады. Соңғы жағдайда өндіріс процесінің суреттері немесе бейне фрагменттері кіріс ретінде қызмет етеді, ал модельді оқыту кескіннің қалыпты құрылымын қалпына келтірудің ұқсас принциптері бойынша жүреді.

Вариациялық автоэнкодерлерді болжамды техникалық қызмет көрсету жүйесіне интеграциялау реактивті және жоспарлы-алдын алу парадигмасынан неғұрлым прогрессивті тұжырымдамаға — деректер негізінде жабдықтың жай-күйін Белсенді бақылау тұжырымдамасына көшуді жүзеге асыруға мүмкіндік береді. Бұл өз кезегінде жоспардан тыс тоқтап қалу санын азайтуға, жабдықтың жалпы тиімділігін арттыруға (Overall Equipment Effectiveness, OEE) және техникалық қызмет көрсету шығындарын оңтайландыруға ықпал етеді.


Осылайша, вариациялық автоэнкодерлер өнеркәсіптік деректердегі ауытқуларды анықтауға арналған қуатты құрал ғана емес, сонымен қатар 4.0 және 5.0 индустриясына көшу дәуірінде өзгермелі өндіріс жағдайларына бейімделуге және өнеркәсіптік кәсіпорындардың сенімділігі мен тұрақтылығының жоғары деңгейін қамтамасыз етуге қабілетті интеллектуалды болжамды жүйелерді құруға негіз жасайды.

2.2 Сенсорлардан деректерді жинау және эксперименттік хаттама

Деректерді жинау деңгейінің негізі далалық құрылғылар мен аналитикалық жүйелер арасында үздіксіз ақпарат алмасуды қамтамасыз ететін сенімді және масштабталатын архитектураға негізделген. Siemens S7-1200 бағдарламаланатын логикалық контроллерлер желісінің конфигурациясы PROFINET протоколы арқылы TIA Portal ортасында орындалады [34]. Әрбір контроллер үшін құрылғының бірегей IP-мекен-жайы мен желілік атауы беріледі, содан кейін ортаның визуалды дизайн құралдарын қолдана отырып, "сызық" немесе "жұлдыз" бойынша топология құрылады [34]. Мұндай архитектура қызмет көрсету сапасына кепілдік беретін детерминирленген деректерді беруді қамтамасыз етеді және жаңа түйіндер қосылған кезде жүйені масштабтауды жеңілдетеді.

OPC UA стандартының ақпараттық модельдеуі тікелей S7-1200 ядросына енгізілген және "Activate OPC UA Server" опциясы арқылы CPU қасиеттерінде іске қосылады. Сыртқы қол жетімділікке арналған тегтер "Accessible from OPC UA" деп белгіленеді, содан кейін олар түйіндер мен нысандар түрінде түсінікті атаулар мен типтермен ұсынылған семантикалық деректер моделінің элементтеріне айналады [35]. Келесі 2.3-суретте өндірістік деректерді жинаудың интеграциялық жүйесінің

архитектурасы көрсетілген. Жүйенің негізі өндірістік жабдықтар мен орталықтандырылған мәліметтер базасы арасында деректерді беру үшін OPC UA протоколын пайдалану болып табылады [35].



2.3-сурет – Деректерді жинау жүйесінің интеграциялық архитектурасы

Желі шекарасында ақпарат алмасуды жүзеге асыру үшін Azure Industrial IoT құрамындағы IPC Publisher модулі жиі қолданылады [40]. Бұл компонент хабарламалардың буферленуін қамтамасыз етеді және телеметрияның қысқа мерзімді байланыс арнасының ақауларында да жеткізілуіне кепілдік береді. Буферлеу жергілікті түрде шлюз жадында немесе құрылғының кіріктірілген дискісінде ұйымдастырылады, бұл деректер пакеттерін сақтауға және орталық серверге қосылуды қалпына келтіргеннен кейін оларды бөліктерге бөлуге мүмкіндік береді.

Деректерді алдын ала өңдеу желінің "шеті" деңгейінде жүзеге асырылады және сенсорлар мен компьютерлік көру жүйелерінің әртүрлі түрлерінің көрсеткіштерін біріктіруді қамтиды [40]. Бұл жағдайда ең маңызды міндет-уақыт белгілерін туралау. $x(t)$ сигналының мәнін іргелес t_i және $t_i + 1$ санақтары арасында жатқан t - ның ерікті сәтінде есептеу үшін сызықтық интерполяция қолданылады (14).

$$x(t) = x_i + \frac{t - t_i}{t_{i+1} - t_i} (x_{i+1} - x_i) \quad (2.4)$$

мұндағы: x_i және x_{i+1} – t_i және t_{i+1} сәттеріндегі өлшемдер. Бұл әдіс уақыт қатарларының дәйектілігін қамтамасыз етеді және діріл арналарының деректерін температура мен қысымның дискретті көрсеткіштерімен синхрондауға мүмкіндік береді.

Шлюздегі деректерді ағынмен бағыттау MQTT протоколын қолдайтын хабарлама брокері арқылы жүзеге асырылады. Хабарламалар тақырыптық топтарға құрылады және тұрақсыз байланыс жағдайында да деректерді

сенімді сақтау мен жеткізуді қамтамасыз ететін реттелген кезекке қойылады [39]. Кепілдендірілген жеткізуді іске асыру қажет болған жағдайда, клиент пен брокер сессиялары арасындағы жазылымды және жеткізілмеген хабарламалардың жай-күйін сақтауға мүмкіндік беретін басқарылатын сеанстар тетігі пайдаланылады.

Сенсорлар желісі мен камералар құрған мәліметтер минутына жүздеген мегабайтқа жетуі мүмкін. Жиектер элементтеріндегі желіге және есептеу ресурстарына жүктемені азайту үшін шуды сүзу, мәндерді біріктіру және машиналық оқыту әдістеріне негізделген маңызды белгілерді бөлектеу жүзеге асырылады. Edge компоненттері ауытқуларды анықтау және бастапқы жіктеу модельдерін іске қосуға қабілетті, бұл орталыққа тек ауытқу белгілері бар оқиғаларды жіберуге мүмкіндік береді.

Жинау арнасының дұрыстығын бақылаудың негізгі элементі - кезектегі L хабарламаларының орташа санын, кірістің орташа қарқындылығын λ және W пакетінің жүйелердегі орташа уақытын байланыстыратын Литтл теңдеуі (15).

$$L = \lambda W \quad (2.5)$$

бұл сізге қажетті буфер көлемін есептеуге және шлюз мен сервер арасындағы күту уақытының параметрлерін оңтайландыруға мүмкіндік береді [39].

Кідірістерді азайту және деректердің жиек түйіндерінде қатып қалуын болдырмау үшін кезек өлшемі, өңдеу уақыты және өткізу қабілеттілігі көрсеткіштерін қамтитын өнімділікті бақылау жүйесі енгізіледі. Осы көрсеткіштердің динамикасын талдау кептелістерді тез анықтауға және шлюз ресурстарын масштабтауға немесе маршруттау стратегиясын өзгертуге мүмкіндік береді.

Тұтастай алғанда, деректерді жинау деңгейі визуалды редактор арқылы контроллер желісінің конфигурациясынан бастап, деректер семантикасын құруға және телеметрияны буферлеуді ұйымдастыруға дейін, хабарламаларды алдын ала өңдеуге және кепілдендірілген жеткізуге дейінгі үйлесімді процесс болып табылады [35]. Мұндай көп деңгейлі архитектура болжамды қызмет көрсетудің сенімді модельдерін құру үшін қажетті ақпараттың тұтастығын, консистенциясын және уақтылығын қамтамасыз етеді

2.3 Талдау үшін деректерді өңдеу және жинақтау

Қазіргі заманғы өндірістік процестер деректерді қарқынды пайдаланумен сипатталады, әсіресе болжамды қызмет көрсету және сапаны бақылау контекстінде. Машиналық оқытуға негізделген тиімді жүйелерді құру үшін деректерді өңдеу және ерекшеліктерді жобалау процесін мұқият

жобалау қажет. Негізгі қадамдарға шуды жою, деректерді синхрондау және жетіспейтін мәндерді қалпына келтіру, сондай-ақ ақауларды анықтау үшін статистикалық әдістерді, спектрлік талдауды және кескінді күшейтуді қолдана отырып белгілерді алу кіреді.

Деректер инженериясы - бұл бастапқы деректерді машиналық оқыту алгоритмдерінде қолдануға болатын ақпараттық белгілерге түрлендіру процесі. Бұл кезең болжамды аналитиканы өнеркәсіпте сәтті қолдану үшін өте маңызды, өйткені болжау дәлдігі бастапқы деректердің сапасына тікелей байланысты.

Деректер инженериясының негізгі қадамдарының бірі - жабдықтың қалыптан тыс күйін анықтауға мүмкіндік беретін белгілерді алу. Мысалы, сенсорлық көрсеткіштердің уақыт қатарларына (температура, қысым, діріл, дыбыс) сүйене отырып, орташа, дисперсия, стандартты ауытқу, асимметрия және шектен шығу коэффициенті сияқты статистикалық дескрипторларды есептеуге болады [20]. Орташа мәнді есептеу формуласы (16).

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.6)$$

мұндағы: μ – орташа мән;

x_i - өлшенген мән;

n - бақылаулар саны. Мысалы ретінде өнеркәсіптік қозғалтқыш (сорғы) бақылау кезінде дірілдің орташа мәні жабдықтың тұрақтылығын бағалауға көмектеседі. Орташадан айтарлықтай ауытқу мойынтірек ақауының пайда болуын көрсетуі мүмкін.

Деректерді біріктіргеннен кейін стандарттау жүргізіледі (нөлдік орташа және бірлік дисперсияға әкеледі), бұл әсіресе кіріс масштабына сезімтал модельдерді (мысалы, логистикалық регрессия немесе SVM) пайдалану кезінде маңызды. Өткізілген мәндер сызықтық интерполяция арқылы қалпына келтіріледі, бұл белгілердің бұрмалануын азайтады [20].

Белгілерді дұрыс құру үшін сигналдарды алдын-ала өңдеу қажет. Шу мен деректерді жіберіп алу болжамдарды айтарлықтай бұрмалайды [21]. Шуды сүзу үшін тегістеу әдістері жиі қолданылады. Мысалы, Калман сүзгісі немесе экспоненциалды жылжымалы орташа мән (17).

$$S_t = \alpha \times x_t + (1 - \alpha) \times S_{t-1} \quad (2.7)$$

мұндағы S_t - тегістелген мән;

α - тегістеу коэффициенті;

x_t - ағымдағы өлшем;

S_{t-1} - алдыңғы тегістелген мән. Өткізілген мәндерді қалпына келтіру үшін жақын көрші интерполяция немесе сызықтық интерполяция жиі қолданылады. Мысалы, егер температура сенсоры қысқа уақыт ішінде деректерді жібермесе, мәндерді сызықтық жуықтау арқылы қалпына

келтіруге болады (18).

$$x(t) = x(t_1) + \frac{x(t_2) - x(t_1)}{t_2 - t_1} \times (t_2 - t_1) \quad (2.8)$$

Дыбыстық сигналдарды талдау үшін Бор-спектрлік коэффициенттер (MFCC) қолданылады, бұл жабдықтың жұмысындағы құрылымдық өзгерістерді, мысалы, қозғалтқыш дыбысының өзгеруін анықтауға мүмкіндік береді [21]. MFCC дискретті косинустық түрлендіру (DCT) негізінде есептеледі (19).

$$MFCC(n) = \sum_{m=1}^M \log(X_m) \cos \left[\frac{\pi n(2m-1)}{2M} \right] \quad (2.9)$$

мұндағы X_m - m – інші сүзгі арнасындағы қуат;


M - сүзгілер саны. Компрессордың акустикалық сигналын талдау кезінде төмен жиіліктегі MFCC мәндерінің жоғарылауы мойынтіректерде үйкелістің пайда болуын көрсетуі мүмкін [20]. Спектрлік белгілер Фурье түрлендіру арқылы алынады (20).

$$F(\omega) = \int_{-\infty}^{\infty} x(t) \times e^{-j\omega t} dt \quad (2.10)$$

мұндағы $x(t)$ - біз талдайтын уақыт сигналы;

ω - бұрыштық жиілік (рад / с);

$e^{-j\omega t}$ - сигнал синусоидтарға ыдыраған кезде негізгі функция ретінде қызмет ететін күрделі экспонент. Өндірістегі өнімдерді визуалды бақылау компьютерлік көрудің тұрақты модельдерін құруды талап етеді. Суреттерді үлкейту, оқу үлгісінің көлемін ұлғайтуға және жарық жағдайлары мен көру бұрыштары өзгерген кезде модельдің сенімділігін арттыруға мүмкіндік береді. Төмендегі 2.4-суретте нейрондық желіні оқытпас бұрын деректерді өңдеу және дайындау үшін қолданылатын Roboflow платформасының интерфейсі көрсетілген.



2.4 -суретте – Roboflow платформасының интерфейсі және кескінді

түрлендірудегі мүмкіндіктері

Кескінді күшейту модельдің жарықтандыруды өзгерту, нысанды айналдыру немесе шудың болуы сияқты әртүрлі жағдайларға төзімділігін арттыру үшін қажет [38]. Бұл жаңа кескіндерді жинамай-ақ жаттығу деректер жиынтығының әртүрлілігін арттыруға мүмкіндік береді, осылайша модельдің жалпылау қабілетін жақсартады.

Іс жүзінде келесі күшейту әдістері қолданылады:

- Кескіндерді бұру және шағылыстыру.
- Жарықтық пен Контрасттың өзгеруі.
- Шу қосу (Гаусс немесе импульс).

Компьютерлік көрудің сенімді моделін құру үшін әр түрлі ядролары бар конволюцияларды қолдану ұсынылады (мысалы, 3x3 немесе 5x5). Гаусс ядросының мысалы төмендегі формуламен беруге болады (21).

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.11)$$

мұндағы σ - бұлыңғырлық дәрежесін сипаттайтын үлестірімнің стандартты ауытқуы;

x, y - сүзгі центріне қатысты суреттегі нүктенің координаттары;

$e^{-\frac{x^2+y^2}{2\sigma^2}}$ - ядро центріне дейінгі қашықтығына байланысты вестибулаларды анықтайтын экспоненциалды мультипликатор (орталықтан неғұрлым алыс болса, салмағы соғұрлым аз болады);

$\frac{1}{2\pi\sigma^2}$ - ядроның барлық салмақтарының қосындысы бірлікке тең болатындығын қамтамасыз ететін нормалау коэффициенті (кескіннің жарықтығын сақтау).

Деректерді жобалау және белгілерді құру өнеркәсіптік кәсіпорындарда болжамды қызмет көрсетуді жүзеге асырудың маңызды кезеңдері болып табылады. Сигналдарды сапалы өңдеу, жетіспейтін деректерді қалпына келтіру және кескінді күшейтудің заманауи әдістерін қолдану болжамды аналитиканың сенімді модельдерін жасауға мүмкіндік береді. Модельдердің жоғары дәлдігіне қол жеткізу сүзу әдістерін, спектрлік талдауды және визуалды ақпаратты мұқият өңдеуді қажет етеді. Дәстүрлі әдістер мен терең оқытуды біріктіру мүмкін болатын ақауларды мүмкіндігінше дәл болжауға және жабдықтың сенімділігін арттыруға мүмкіндік береді.

2.4 Сенсорлық деректер мен компьютерлік көруді біріктіру

Заманауи болжамды техникалық қызмет көрсету жүйелері жабдықтың нашарлау белгілерін уақтылы анықтау және ықтимал ақауларды болжау үшін деректерді жинауға, өңдеуге және талдауға кешенді тәсілді қажет етеді. Физикалық сенсорлардың көрсеткіштері мен компьютерлік көру жүйелерінің деректерін қоса алғанда, әртүрлі деректер көздерін біріктіру сенімді және тиімді интеллектуалды бақылау жүйелерін құрудың маңызды шарттарының бірі болып табылады.

Электр тоғын өлшеу электр қозғалтқыштарына, генераторларға және басқа электр құрылғыларына жүктеме дәрежесін бағалауға мүмкіндік береді. Тұтынылатын тоқтың ауытқуы механикалық ақаулардың пайда болуын (мысалы, мойынтіректердің жабысуы), жүйенің электрлік тұтастығының бұзылуын немесе оқшаулағыш материалдардың деградациясын көрсетуі мүмкін. Тоқ сигналын талдау үшін уақыт қатарларын өңдеудің статистикалық әдістері жиі қолданылады, соның ішінде орташа мәнді, стандартты ауытқуды, асимметрия коэффициентін және шектен шығуды есептеу.

Діріл сенсорлары электр қозғалтқыштары, сорғылар, редукторлар және желдеткіштер сияқты айналмалы механизмдерді диагностикалаудағы ең ақпараттылардың бірі болып табылады. Дірілді талдау роторлардың теңгерімсіздігін, мойынтіректердің тозуын, бекітпелердің әлсіреуін және басқа ақауларды анықтауға мүмкіндік береді. Діріл деректерін өңдеу Фурье түрлендіру, толқындық түрлендіру және амплитудалық-жиілік сипаттамаларының спектрлерін талдау әдістерін қолдану арқылы жүзеге асырылады.

Акустикалық сенсорлар жабдық жұмыс істеп тұрған кезде пайда болатын дыбыстық сигналдарды тіркейді. Дыбыс спектріндегі өзгерістер жарықтар, үйкеліс, соққылар немесе кавитацияны көрсетуі мүмкін. Акустикалық деректерді өңдеу әдістеріне сүзгілеу, қуат спектрін талдау және акустикалық үлгілерді жіктеу үшін машиналық оқыту кіреді.

Ресми түрде сенсорлық деректерді жинау процесін келесідей ұсынуға болады. Болсын $x(t)$ - сенсор уақыт бойынша жазылатын бақыланатын шама. Содан кейін болжамды талдаудың міндеті болжам функциясын құру болып табылады (22).

$$x(t + \Delta t) = f(x(t)), \dot{x}(t - 1), \dots, x(t - n)) \quad (2.12)$$

мұндағы $x(t + \Delta t)$ - уақыт аралығы арқылы шаманың болжамды мәні Δt ;

$f(\cdot)$ - тарихи деректерге негізделген болжау моделі;

n - уақыт терезесінің тереңдігі.

Өнеркәсіптік процестердің күрделілігі сенсорлық деректерді компьютерлік көру жүйелері арқылы алынған визуалды ақпаратпен

толықтыруды талап етеді [31]. Машиналық көру жүйелері бұйымдардың, процестердің немесе Жабдықтардың сыртқы сипаттамаларын түсіретін кескіндерді немесе бейне ағындарын автоматты түрде тіркеуге және талдауға арналған. Олар ақауларды, технологиялық процестердегі ауытқуларды, жабдықтың тозуын немесе ластануын анықтауға мүмкіндік беретін тәуелсіз деректер көзін қамтамасыз етеді.

Компьютерлік көрудің ең тиімді құралдарының бірі-суреттерден белгілерді алуға және оларды кейіннен жіктеуге маманданған конволюциялық нейрондық желілер (Convolutional Neural Networks, CNN) [31]. CNN-дің негізгі идеясы-шеттер, бұрыштар және текстуралар сияқты жергілікті заңдылықтарды анықтай отырып, кескіннен өтетін оқытылатын конволюцияларды (сүзгілерді) қолдану.

Құрылымдық конволюциялық нейрондық желі ауыспалы конволюция қабаттарынан (convolutional layers), қосалқы үлгіден (pooling layers) және толық байланысқан қабаттардан (fully connected layers) тұрады [32]. Кескінді белгілер жиынтығына түрлендіру процесі келесідей рәсімделеді (23).

$$h_{i,j}^{(k)} = \sigma(\sum_{m,n} W_{m,n}^{(k)} * x_{i+m,j+n} + b^{(k)}) \quad (2.13)$$

мұндағы $h_{i,j}^{(k)}$ - белгілердің k - ыншы арнасындағы (i,j) позициядағы нейронның шығыс мәні;

$W_{m,n}^{(k)}$ - оқытылатын сүзгі салмағы;

$x_{i+m,j+n}$ - кіріс кескінінің пиксел мәні;

$b^{(k)}$ - орын ауыстыру (bias);

$\sigma(\cdot)$ - сызықтық емес белсендіру функциясы (мысалы, ReLU).

Компьютерлік көру модельдерінің ішінде нақты уақыттағы суреттердегі объектілерді анықтау тапсырмасына арналған YOLO (you Only Look Once) отбасының архитектуралары ерекше орын алады. YOLO-ның негізгі идеясы-объектілердің координаттары мен олардың сыныптарын бір реттік болжау, қызығушылық аймақтарын алдын-ала бөлудің нақты кезеңінсіз (region proposals), бұл жоғары өңдеу жылдамдығы мен өнеркәсіптік өндіріс жағдайында қолданылуын қамтамасыз етеді.

YOLO моделі кіріс кескінін $S \times S$ торына бөледі және әрбір тор ұяшығы үшін сәйкес сынып белгілерімен шектейтін тіктөртбұрыштардың (bounding boxes) белгіленген санын болжайды [32]. Модельдің жоғалуы үш компонентті қамтитын біріктірілген шығын функциясын қолдану арқылы оңтайландырылады:

1. Шектеу тіктөртбұрыштарының координаттарын болжау қатесі;
2. Объектілерді жіктеу қатесі;
3. Ұяшықта объектінің бар екеніне сенімділік қатесі.

Yolo жоғалту функциясы келесідей ұсынылуы мүмкін (24).

$$\begin{aligned}
\tau = & \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] + \\
& + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[(\sqrt{\omega_i} - \hat{\omega}_i)^2 + \left(\sqrt{h_i} - \hat{h}_i \right)^2 \right] + \\
& \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} (C_i - \hat{C}_i)^2 + \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{noobj} (C_i - \hat{C}_i)^2 + \\
& + \sum_{i=0}^{S^2} 1_i^{obj} \sum_{c \in classes} (p_i(c) - \hat{p}_i(c))^2
\end{aligned} \tag{2.14}$$

мұндағы 1_{ij}^{obj} - ұяшықтың j - ыншы шектейтін тіктөртбұрышында объектінің болу индикаторы i ;

λ_{coord} λ_{noobj} - оқытылатын сүзгі салмағы;

$x_{(i+m,j+n)}$ - координаттар мен жалған позитивтер үшін айыппұл салмақтары;

$(x_i, y_i, \omega_i, h_i)$ - орталық координаттары және шектеу тіктөртбұрышының өлшемдері;

C_i - ұяшықта объектінің болу ықтималдығы;

$p_i(c)$ - объект класының ықтималдығы. Yolo модельдерін өнеркәсіпте қолдану нақты уақыт режимінде өнімнің ақауларын (мысалы, жарықтар, чиптер, ластанулар) анықтауға, құрастыру процестерін бақылауға, қаптаманың дұрыстығын бақылауға, сондай-ақ өндірістегі қауіпсіздікті бақылауға мүмкіндік береді [33].

Сенсорлық деректер мен компьютерлік көруді біріктіру болжамдардың дәлдігін едәуір жақсартады, өйткені ол екі қосымша ақпарат көзін біріктіреді: жабдықтың ішкі параметрлері және оның сыртқы визуалды белгілері [32]. Интеграцияның тиімді стратегиясы-сандық сенсорлық деректерді де, кескіндерді де қабылдайтын мультимодальды модельдерді құру [33]. Бұл жағдайда конволюциялық қабаттар кескіндерді өңдейді, ал толық байланысқан қабаттар белгілердің сандық векторларын өңдейді, содан кейін олардың көріністері бірлескен талдау үшін біріктіріледі.

Математикалық тұрғыдан ерекшеліктердің бірігуі екі ерекшелік векторының бірігуі ретінде жазылуы мүмкін (25).

$$h = \text{concat}(h_{\text{sensor}}, h_{\text{vision}}) \tag{2.15}$$

мұндағы h_{sensor} - сенсорлық деректерден алынған белгілер векторы;

h_{vision} - CNN кескінін өңдеуден кейін алынған белгілер векторы;

$\text{concat}(\cdot)$ - белгілерді біріктіру (біріктіру) операциясы. Біріктірілген h көрінісі бұдан әрі қалған жабдық ресурсын (remaining Useful Life, RUL) немесе істен шығу ықтималдығын болжау тапсырмасын орындау үшін классификаторға немесе регрессиялық модельге енгізуге беріледі [33].

Сенсорлық деректер мен компьютерлік көру жүйелерінің интеграциясы нақты өндірістік ортаның күрделі және динамикалық жағдайларына

бейімделе алатын неғұрлым тұрақты және сенімді техникалық қызмет көрсету модельдерін құруды қамтамасыз етеді. Бұл тәсіл ақылды өндіріс тұжырымдамасына көшу және технологиялық процестердің сенімділігін, тиімділігі мен қауіпсіздігін үздіксіз арттыруды қамтамасыз ету үшін деректер негізгі активке айналатын Индустрия 4.0 және 5.0 қағидаттарын іске асыру үшін негіз қалайды.

2.5 Тұрақты оқыту механизмдері және Байес теоремасы

Өнеркәсіптегі болжамды техникалық қызмет көрсетудің заманауи жүйелері динамикалық өзгеретін деректердің үлкен көлемін өңдеу қажеттілігіне тап болады. Өндірістік процестер әр түрлі өзгергіштік көздеріне ұшырайды: жабдықтың қартаюы, жұмыс режимдерінің өзгеруі, компоненттердің модернизациясы, қоршаған ортаның маусымдық ауытқуы. Мұндай жағдайларда шектеулі деректер жиынтығында бір рет оқытылған машиналық оқытудың статикалық модельдерін қолдану жеткіліксіз болып шығады. Болжалды қызмет көрсетудің жоғары тиімділігін қамтамасыз ету үшін модельдерге бұрын жинақталған білімді жоғалтпай нақты уақыттағы өзгерістерге бейімделуге мүмкіндік беретін тұрақты оқыту (үздіксіз оқыту) тетіктерін енгізу қажет [45].

Тұрақты оқыту, кең мағынада, жаңа кіріс деректері негізінде модель параметрлерін жаңарту процесі болып табылады, бұл бүкіл деректер жиынтығында толық қайта оқытуды қажет етпейді. Мұндай жүйелердің негізгі міндеті-жаңа ақпарат модельдің бұрын зерттелген тапсырмаларды шешу қабілетінің нашарлауына әкелетін апатты ұмыту құбылысын (catastrophic forgetting) болдырмау. Болжалды қызмет көрсету контекстінде үздіксіз оқытудың мақсаты модельдер белгілі ақау түрлерін тану қабілетін сақтай отырып және сонымен бірге деградацияның жаңа түрлері туралы білім ала отырып, жабдықты пайдаланудың жаңа жағдайларына уақтылы бейімделе алуы болып табылады.

Тұрақты оқыту мәселесін шешудің іргелі тәсілдерінің бірі ықтималдық ойлауды қолдануға, атап айтқанда Байес теоремасын қолдануға негізделген. Байес теоремасы жаңа ақпарат келген кезде білімді жаңарту процесін формальды түрде сипаттауға мүмкіндік береді, бұл оны адаптивті болжамды жүйелерді құрудың тамаша математикалық құралына айналдырады [46].

Байес теоремасы гипотезаның априорлық ықтималдығы, жаңа деректерді алғаннан кейінгі артқы ықтималдық және сол деректердің ықтималдық функциясы арасындағы байланысты орнатады. Ресми түрде Байес теоремасы келесідей жазылады (26).

$$P(A|B) = \frac{P(B|A)*P(A)}{P(B)} \quad (2.16)$$

мұндағы $P(A|B)$ - гипотезаның артқы ықтималдығы А кейін В;

$P(B|A)$ - А гипотезасының ақиқаты жағдайында В деректерін байқау ықтималдығы (ықтималдық функциясы);

$P(A)$ - В деректерін алғанға дейін Н гипотезасының априорлық ықтималдығы;

$P(B)$ - барлық ықтимал гипотезалар бойынша ықтималдықтардың қосындысы ретінде есептелетін D деректерін бақылаудың толық ықтималдығы.


Мысалыға 2.2 - кетеді біздің зерттеуге 17 станокты таңдап алдық делік. Олардың әрқайсысы үшін біз сәтсіздік фактісін (А оқиғасы) және қалыптан тыс сигналдың болуын (В оқиғасы) тіркедік. Бақылау жабдық саны маңызды статистика үшін аз болғанымен, бұл принциптерді көрсету үшін жеткілікті.

Кесте 2.2. Байес теоремасы гипотезаның априорлық ықтималдығы

№	A	B	B A	!B A	B !A	!B !A
1	0	0			0	1
2	1	1	1	0		
3	1	1	1	0		
4	0	0			0	1
5	1	1	1	0		
6	0	0			0	1
7	1	1	1	0		
8	0	0			0	1
9	0	0			0	1
10	0	1			1	0
11	1	0	0	1		
12	0	1			1	0
13	0	0			0	1
14	1	1	1	0		
15	1	1	1	0		
16	0	0			0	1
17	0	1			1	0
N	17	17	7	7	10	10
+	7	9	6	1	3	7
P	41.18%	52.94%	85.71%	14.29%	30.00%	70.00%

Деректер кестелік түрде берілген, мұнда 1 ақаулық немесе аномалия, ал 0 жабдықтың дұрыс жұмысын немесе аномалия жоқ дегенді білдіреді. Сол кестеде келесі есептеулер келтірілген: бақылаулардың жалпы саны N, сәтсіздіктер саны (+), сәтсіздіктің эмпирикалық ықтималдығы P, сәтсіздік кезінде аномальды сигналды анықтаудың шартты ықтималдығы $P(B|A)$, сәтсіздік болмаған кезде аномалияның шартты ықтималдығы $P(B|!A)$, және

$P(!B|A)$ - сәтсіздік аномалиясының болмауы және $P (!B|!A)$ - қалыпты жұмыс кезінде аномалияның болмауы. Мұнда белгісі "!" жоқ дегенді білдіреді, яғни "!A" - ақаусыз жабдық. $(B|A)$ бағанында біз $(A)=1$ болатын (B) мәндерін ғана ескереміз. Бағанда $(B|!A)$ қайда $(A)=0$ және т. б. Осы мәліметтер негізінде жиілік диаграммасын жасауға болады. Бұл бір немесе басқа нәтиженің ықтималдығын көрсететін ағаш жиектің салмағы (санмен көрсеткі). Сондай-ақ, симптомның (кері ағаш) болуының тамыры бар ағашты жасауға болады. Оның мысалын 2.5 – суреттен көре аламыз.



2.5-сурет – Жабдықтың күйін бағалауға арналған шешім қабылдау ағашы.

Интуитивті түрде Байес теоремасы жаңа бақылауларға негізделген гипотезаның ықтималдығы туралы бастапқы идеямызды қалай жаңарту керектігін көрсетеді [45]. Болжалды техникалық қызмет көрсету мәселелерінде гипотеза жабдықтың қалыпты немесе ақаулы күйі болуы мүмкін, ал деректер сенсорлардың көрсеткіштері немесе кескінді талдау нәтижелері болуы мүмкін.

Дәйекті бақылаулар арқылы ықтималдықтарды толық жаңарту формуласын рекурсивті түрде жазуға болады (27).

$$P(H|D_1, D_2, \dots, D_n) \propto P(D_n|H)P(H|D_1, D_2, \dots, D_{n-1}) \quad (2.17)$$

мұнда әрбір жаңа D_n бақылауы алдыңғы бақылаулардан кейін алынған артқы үлестірімді жаңартады. Осылайша, білім моделі динамикалық болады және бүкіл деректер тарихын сақтамай-ақ ақпаратты жинақтайды.

Байес тәсілін болжамды қызмет көрсету модельдерін үздіксіз оқытуда қолдану бірнеше негізгі кезеңдерді қамтиды:

1. Жабдықтың қалыпты жұмыс істеуі туралы тарихи мәліметтер негізінде модель параметрлерінің априорлық таралуын инициализациялау.

2. Жаңа деректер келген кезде ауытқулардың пайда болу ықтималдығын бағалауға мүмкіндік беретін бақыланатын сипаттамалар үшін ықтималдық функциясын есептеу.

3. Келесі қайталанулар үшін жаңа априорлық үлестірімге айналатын артқы үлестіруді қайта есептеу арқылы модель параметрлерін жаңарту.

Үлкен нейрондық желілер үшін практикалық қолдануда артқы үлестірімдерді тікелей есептеу есептеу қиын міндет болып табылады. Сондықтан Вариациялық байесиандық алып тастау (variational Bayesian Inference) немесе Монте-Карлоның Марков тізбегі әдістері қолданылады [46]. Вариациялық тәсілде $q(\theta)$ артқы үлестірімінің жуықтауы оңтайландырылады, бұл шынайы артқы үлестіру мен оның жуықтауы арасындағы Кульбак–Жапсырма дивергенциясын азайтады (28).

$$KL(q(\theta)||p(\theta|D)) = \int q(\theta) \log \frac{q(\theta)}{p(\theta|D)} d\theta \quad (2.18)$$

мұндағы θ - модель параметрлері;

$P(\theta|D)$ - модель параметрлерінің шынайы артқы таралуы;

$q(\theta)$ - вариациялық жуықтау. Бұл дивергенцияны азайту осындай $q(\theta)$ алуға әкеледі, ол шынайы постериорлық үлестіруді мүмкіндігінше жақын түрде қайталайды, сондықтан жаңа деректер келген сайын модель параметрлерін тиімді жаңартуға мүмкіндік береді.

Байес жаңартуы белгісіздіктерді ескеретін жүйелерді құруда маңызды рөл атқарады. Классикалық машиналық оқыту жүйелерінде модель параметрлері оқу процесінде жазылады және одан әрі өзгерістер тек қайта оқыту арқылы мүмкін болады. Байес модельдерінде әр параметрде ықтималдық үлестірімі бар, бұл модельдің өз болжамдарына деген сенімділік дәрежесін ескеруге мүмкіндік береді. Бұл әсіресе болжамды техникалық қызмет көрсету мәселелерінде өте маңызды, мұнда қателер қымбатқа түсуі мүмкін және қалыптан тыс оқиғалардың саны өте шектеулі.

Болжамдардың ықтималды интерпретациясының болуы жабдықтың ең ықтимал күйін анықтап қана қоймай, сонымен қатар модельдің жасалған қорытындыға деген сенімділігін бағалауға мүмкіндік береді. Төмен сенімділікпен жүйе жалған дабылдарды да, нақты ақауларды жіберіп алмауды да болдырмай, қосымша диагностика сұрауын бастауы мүмкін.

Машиналық оқыту негізінде болжамды жүйенің тұрақты оқыту архитектурасы тұрғысынан келесі жұмыс схемасы мүмкін:

- Модель параметрлердің бастапқы априорлық таралуын ала отырып, тарихи мәліметтерден үйренеді;
- Жұмыс барысында жабдық жаңа сенсорлық деректер мен визуалды бақылаулар жасайды;
- Модель толық қайта оқытусыз артқы бөлуді қайта есептеу арқылы мезгіл-мезгіл жаңартылып отырады;
- Аномалиялардың жаңа кластары пайда болған кезде, модель бұрын белгілі аномалияларды тану қабілетін жоғалтпай, оларға бейімделеді.

Ресми түрде өнеркәсіптік жүйеде үздіксіз оқыту процесін келесі қайталанатын параметрлерді жаңарту схемасымен сипаттауға болады (29).

$$\theta_n = \operatorname{argmax}_{\theta} (\log p(D_n|\theta) + \log p(\theta|\theta_{n-1})) \quad (2.19)$$

мұндағы θ_{n-1} – $n-1$ деректер пакетін өңдегеннен кейінгі модель параметрлері;

θ_n – n -ші деректер пакетіндегі жаңартудан кейінгі опциялар;

$\log p(D_n|\theta)$ – жаңа деректердің сенімділік логарифмі;

$\log p(\theta|\theta_{n-1})$ – модельдің алдыңғы күйімен анықталған параметрлердің априорлық ықтималдығының логарифмі. Мұндай схема модельдің уақыт өте келе біртіндеп дамуына мүмкіндік береді, бұл жабдықтың, технологиялық процестердің және сыртқы ортаның сипаттамаларының өзгеруін көрсетеді.

Үздіксіз оқыту тетіктерін қолдану өнеркәсіптік қолдану үшін бірқатар қосымша артықшылықтарға ие. Біріншіден, пайдалану жағдайлары өзгерген кезде модельдерді қолмен қайта өңдеу және жүйелерді қайта калибрлеу қажеттілігі айтарлықтай азаяды. Екіншіден, деректерді сақтау көлемі азаяды, өйткені қайта оқыту үшін барлық тарихи үлгілерді сақтаудың қажеті жоқ. Үшіншіден, үздіксіз оқыту жүйелердің сирек кездесетін, бірақ маңызды ақауларға төзімділігін арттыруға көмектеседі, өйткені модель жабдықтың мінез-құлқындағы тіпті шағын өзгерістерді анықтай алады.

Алайда үздіксіз оқытуды тиімді қолдану бірқатар әдістемелік мәселелерді шешуді талап етеді:

- Модельді жаңарту сәтін анықтау (мысалы, жаңа деректердің белгілі бір көлемін жинақтау немесе белгілердің таралуын өзгерту);
- Параметрлерді жаңартуға сенімділік интервалдарын реттеу немесе енгізу арқылы шулы деректерде қайта оқытудан қорғау;
- Модельдің тұрақтылығы мен оның бейімделу қабілеті арасындағы тепе-теңдік ("икемділік-тұрақтылық" дилеммасы деп аталады).

Бұл принциптерді қолдану қатаң бағдарламаланған диагностикалық жүйелер тұжырымдамасынан өздігінен дамып, қоршаған ортаға бейімделе алатын өзін-өзі оқытатын интеллектуалды агенттер тұжырымдамасына көшуге мүмкіндік береді. Бұл өз кезегінде 5.0 индустриясын одан әрі дамытуға жол ашады, мұнда Машиналық оқыту өндірістік жүйелердің ажырамас бөлігіне айналады, олардың жоғары сенімділігін, тиімділігін және өзін-өзі оңтайландыру қабілетін қамтамасыз етеді.

3 Жүйені жасау және енгізу

3.1 Өнеркәсіпте компьютерлік көруді қолдану

Деректер бастапқыда өндіріс процесін бейнеге жазу арқылы жиналды. Нақты уақыттағы өнім ағынын бекіту үшін өндіріс желісіне жоғары ажыратымдылықтағы камера орнатылды. Бұл тәсіл жабдықтың табиғи жұмыс жағдайында кескіндерді алуға мүмкіндік береді, бұл модельді дұрыс оқыту үшін өте маңызды.


Roboflow платформасы деректерді белгілеу мен күшейтудің негізгі құралы ретінде таңдалды. Бұл компьютерлік көру үшін деректерді дайындауға арналған ыңғайлы онлайн қызмет. Roboflow мәліметтер жиынтығын құруға және басқаруға, кескінді белгілеуге және әр түрлі күшейтуге мүмкіндік береді. Roboflow негізгі артықшылықтарына мыналар жатады:

- Көптеген деректер форматтарын қолдау (YOLO, COCO, Pascal VOC және т.б.);
- Деректерді күшейтуді автоматтандыру мүмкіндігі;
- Терең оқыту модельдерімен интеграцияның қарапайымдылығы;
- Интуитивті интерфейс және кіріктірілген деректер сапасын талдау құралдары.

Деректерді Roboflow платформасына жүктегеннен кейін ақауларды қолмен белгілеу жүргізілді. Ақаулар кластары өнімді визуалды талдау негізінде анықталды. Roboflow құралдарының арқасында белгілеу жоғары дәлдікпен және тиімділікпен орындалады. Әр белгі үшін объектінің координаттары және оның класы берілді. Бұл процесс кейінірек модельді оқыту үшін қолданылатын құрылымдық және аннотацияланған мәліметтер базасын құруды қамтамасыз етті.


Модельдің жалпылау қабілетін арттыру үшін Roboflow платформасында деректерді күшейту жүргізілді. Келесі әдістер қолданылды:

- шуды қосу (6,63%): модельге камераның шуы мен артефактілеріне төзімді болуға мүмкіндік береді. Төмендегі 3.1-суретте шуды қосудың мысалы көрсетілген.



3.1-сурет – Roboflow платформасындағы суреттерге шуды қосу

- контрастты түзету (адаптивті гистограмма): айнымалы жарық жағдайында кескін сапасын жақсартады. Келесі 3.2-суретте контрастты түзетудің мысалы көрсетілген.




3.2-сурет – Roboflow платформасындағы суреттің контрастын бейімдеу.

Бұл әдістер қайта оқытудың алдын алу және нақты түсіру жағдайларына төзімділікті арттыру арқылы модельді жалпылауды жақсартуға көмектеседі.

Белгілеу кезеңі аяқталғаннан кейін дайындалған деректер yolo11 форматында экспортталды және терең нейрондық модельдерді оқыту үшін графикалық үдеткіштерге (GPU) қол жеткізуді қамтамасыз ететін бұлтты платформа - Google Colab-қа жіберілді.

Келесі 3.3-суретте техникалық көру моделін дайындау кезінде Google Colab-қа жүктелген және өңделген аннотацияларды таратудың визуализациясы көрсетілген. Жоғарғы сол жақ диаграмма барлық нысандардың Banka класына жататынын көрсетеді, даналар саны 2500-ден асады. Оң жақта нысандар негізінен суреттердің орталық аймағында орналасқанын растайтын қабаттасқан bounding box көрсетілген.



3.3-сурет – Датасеттегі объектісінің аннотацияларының кеңістіктік-өлшемдік таралуы


Төменгі диаграммалар координаттардың тығыздығын көрсетеді:

- x/y біркелкі бөлінеді, бұл кадрдағы объектінің позицияларының әртүрлілігін көрсетеді;
- ені/биіктігі ені 0.2–0.3 және биіктігі 0.1–0.4 диапазонында шоғырланған, бұл тұрақты өлшемді көрсетеді.

Аннотацияның бұл құрылымы теңдестірілген оқытуды және модельдің объектілерді жылжытуға немесе масштабтауға төзімділігін қамтамасыз етеді [22].

Келесі 3.4-суретте өнімнің сапасын бақылауға арналған нейрондық желіні оқыту және валидациялау процесінің негізгі көрсеткіштерінің динамикасы көрсетілген. Графиктердің жоғарғы қатарында локализация

(train/box_loss), жіктеу (train/cls_loss) және таратылған локализация (train/dfl_loss) қателері, сондай-ақ дәлдік және толықтық (recall) көрсеткіштері көрсетілген. Төменгі қатар тексеру жиынтығында ұқсас көрсеткіштерді көрсетеді, соның ішінде әр түрлі объектілерді қабаттастыру шектерінде орташа дәлдік (mAP) [50]. Оқыту мен валидациядағы қателіктердің біртіндеп төмендеуі, сондай-ақ mAP-тің өсуі өнімнің сапасын анықтау міндетіндегі модельдің сәтті дамуын көрсетеді.



3.4-сурет – Сапаны бақылау үшін нейрондық желіні оқыту процесінің көрсеткіштері

Оқу аяқталғаннан кейін сынақ кескініндегі YOLO моделінің жұмыс нәтижесінің мысалы. Кадрдағы барлық банктер дұрыс анықталғанын және сынып белгілері бар түрлі-түсті жақтаулармен белгіленгенін көруге болады. Әрбір анықталған объект үшін модельдің сенімділік деңгейі (confidence) жоғары (0.90-нан астам), бұл танудың сенімділігін растайды. Модель дұрыс орналастырылған объектілерді де сенімді түрде анықтайды және күтілетін жерде банктің жоқтығын анықтайды. 3.5-суретте жұмыс нәтижелері көрсетілген.




3.5-сурет – Жұмыс нәтижелері

AutoML және конволюциялық нейрондық желі архитектураларына (CNN) негізделген болжамды техникалық қызмет көрсету үлгілерін қолдану диагностикалық процестердің тиімділігінің айтарлықтай жақсарғанын көрсетті. Атап айтқанда, инженерлік персоналдың еңбек шығындарының 35% - ға дейін қысқаруы, сондай-ақ дәстүрлі визуалды бақылау және қолмен диагностика әдістерімен салыстырғанда технологиялық ауытқуларды анықтау жылдамдығының 3-5 есе артуы байқалады [22]. Сонымен қатар, компоненттерді мерзімінен бұрын ауыстырудан бас тарту және апаттық жөндеу жиілігінің төмендеуі жылдық техникалық қызмет көрсету шығындарының 30 пайыздан астам төмендеуін қамтамасыз етті [51]. Бірыңғай цифрлық платформа шеңберінде нақты уақыттағы мониторинг, ауытқуларды интеллектуалды анықтау және болжамдық модельдеу тетіктерін интеграциялау өнеркәсіптік цифрландырудың жүйе құраушы құрамдас бөлігі ретінде болжамды қызмет көрсетудің жоғары қолданбалы құндылығын растайды [12].

3.2 Болжалды өнеркәсіптік қызметке арналған машиналық оқыту

Біз ұсынған болжамды техникалық қызмет көрсету жүйесі Қазақстандағы нақты өндірістен тікелей жиналған деректерде әзірленді және сыналды. Бұл өндірістік қондырғылар жабдықтың айтарлықтай тозуымен және білікті инженерлік кадрлардың жетіспеушілігімен ерекшеленеді. Жұмыс аясында OPC UA протоколы бойынша Siemens PLC арқылы алынған сенсорлық деректер, сондай-ақ машиналық көру камераларынан алынған ақпарат пайдаланылды. Осы нақты өндіріс деректері негізінде вариациялық автоэнкодерлер (VAE) негізінде құрылған болжамды қызмет көрсету моделі оқытылды. Оқытылған модель жасырын белгілерді анықтауға және ақаулардың пайда болуын жоғары дәлдікпен болжауға қабілетті.

3.6 - суретте үрлеу және құю желілерінің технологиялық жабдықтарына орнатылған діріл датчиктерінен алынған сигналдардың уақытша қатарлары келтірілген. Графикалық бейнелеу 200 рет қатарынан санау кезінде 21 сенсорлық арнамен (s1–s21) бекітілген нормаланған тербеліс амплитудасын қамтиды. Абсцисса осі бойынша уақыт шартты бірліктерде (өлшеудің уақыт аралықтарында), ординат осі бойынша — 0-ден 1-ге дейінгі диапозондағы дірілдің нормаланған амплитудасы көрсетіледі. Сигнал динамикасын талдауға ыңғайлы болу үшін әр арна бөлек түспен белгіленеді.




3.6-сурет – Жабдықтың қалыпты жұмыс режимінде 21 сенсорлық деректер арнасының көрсеткіштерінің уақыт қатары.

Суретте көптеген арналар (s1, s2, s3, s5, s7–s8, s10–s13, s15, s17, s19–s21) 0,6–0,8 диапазонында ауытқиды, бұл жабдық түйіндерінің штаттық жұмыс режимдеріне сәйкес келеді. S4, s9, s14 және s18 арналары төмен деңгейлерді көрсетеді (0,1–0,3), бұл бақыланатын параметрлердің басқа сипатын көрсетуі мүмкін (мысалы, төмен амплитудалық діріл сипаттамалары немесе фондық шу).

S1, s2 және s12 арналарындағы уақытша шығарындылар (шыңдар) 150 және 180 аралығында байқалады, бұл жүктеменің қысқа мерзімді өсуін немесе жергілікті тозудың басталуын көрсетуі мүмкін. VAE моделінің міндеті - "типтік" сигнал үлгілерін көбейтуді үйрену, содан кейін реконструктивті қателік шамасы бойынша (reconstruction loss) қалыптан тыс шығарындыларды анықтау.

Бақылаудың тағы бір кезеңі - нақты уақыттағы температура және қозғалтқыш тоғының сенсорларынан алынған деректерді талдау. Істен шығуға дейінгі ауытқуларды анықтау мақсатында осы сигналдардың уақыт қатарларын визуализациялау жүргізілді. 3.7-суретте мәндер белгіленген шекті деңгейден асатын сәттер белгіленеді (графиктерде маркерлермен белгіленеді), бұл ықтимал апаттық жағдайларды көрсетеді. Мысалы, жабдықтың температурасы $t = 75$ C шамасында рұқсат етілген мәннен қысқа уақытқа асып түседі, сонымен бірге дірілдің жоғарылауы және қозғалтқыш тоғының жоғарылауы жүреді.



3.7-сурет – Температура және тоқ сенсорларынан алынған деректер

Қалыпты жұмыс тербелістері мен бірнеше күрт шығарындылар айқын көрінетін температура және уақыт бойынша тоқ сенсорларының көрсеткіштерінің графиктері. Бірнеше параметрлердің бір мезгілде ауытқуы, мысалы, механикалық жүктеменің қысқа мерзімді ұлғаюын немесе майлау жүйесіндегі ақаулықты болжайды, бұл түйіндердің қызып кетуіне және дірілдің өсуіне әкелді. Уақыт серияларын талдау осы корреляциялық аномальды ауытқуларды тіркеуге мүмкіндік берді, бұл ақаулықтың дамуының басталуын көрсетеді. Сигналдарды тіркеудің жоғары жиілігі (атап айтқанда, діріл-акустикалық арна үшін шамамен 1 кГц) тіпті қысқа мерзімді шыңдарды түсіруге мүмкіндік бергенін ескеріңіз: $t = 75$ шамасында анықталған аномалия шамамен 1-2 секундқа созылды, бірақ графикте айқын көрінді. Көрсетілген оқиғалардан тыс параметрлер норма шегінде қалып, жабдықтың тұрақты жұмысын сыни ауытқуларсыз растады. Осылайша, осы датчиктерді талдау жабдықтың шамадан тыс жүктемелері мен стандартты емес жұмыс режимдерін уақтылы анықтауға мүмкіндік береді.

Вариациялық автоэнкодердің кодтаушысы 3×3 ядролары бар үш конволюциялық қабатты және кіріс спектрограммаларының өлшемін төмендететін сүзгілердің (16, 32, 64) өсіп келе жатқан санын, содан кейін толық байланысқан қабаттарды қамтиды. Нәтижесінде 16 өлшемді жасырын z айнымалысының таралуын сипаттайтын орташа (μ) және стандартты ауытқу (σ) векторлары пайда болады [30]. Осы компоненттерді таңдай отырып, біз құрылғының жұмысының пайдалы әсер коэффициентінің жоғары

болуына қажетті компоненттерді тағдап аламыз және осы құрылғыны жинақтап оның жұмыс істеу ұзақтығын, батареяның қуатталу уақытына зерттеулер жүргізетін боламыз. Энкодердің программалық құрылымын 3.8-суреттен көре аламыз.

```

# Построение энкодера
input_img = tf.keras.Input(shape=IMG_SIZE + (1,))
x = tf.keras.layers.Conv2D(32, 3, activation='relu', strides=2, padding='same')(input_img)
x = tf.keras.layers.Conv2D(64, 3, activation='relu', strides=2, padding='same')(x)
x = tf.keras.layers.Flatten()(x)
x = tf.keras.layers.Dense(16, activation='relu')(x)
z_mean = tf.keras.layers.Dense(latent_dim, name='z_mean')(x)
z_log_var = tf.keras.layers.Dense(latent_dim, name='z_log_var')(x)
z = tf.keras.layers.Lambda(sampling, output_shape=(latent_dim,), name='z')((z_mean, z_log_var))
encoder = tf.keras.Model(input_img, [z_mean, z_log_var, z], name='encoder')
encoder.summary()

```

Model: "encoder"

Layer (type)	Output Shape	Param #	Connected to
input_layer (InputLayer)	(None, 128, 128, 1)	0	-
conv2d (Conv2D)	(None, 64, 64, 32)	320	input_layer[0][0]
conv2d_1 (Conv2D)	(None, 32, 32, 64)	18,496	conv2d[0][0]
flatten (Flatten)	(None, 65536)	0	conv2d_1[0][0]
dense (Dense)	(None, 16)	1,048,592	flatten[0][0]
z_mean (Dense)	(None, 16)	272	dense[0][0]
z_log_var (Dense)	(None, 16)	272	dense[0][0]
z (Lambda)	(None, 16)	0	z_mean[0][0], z_log_var[0][0]

Total params: 1,067,952 (4.07 MB)
Trainable params: 1,067,952 (4.07 MB)
Non-trainable params: 0 (0.00 B)

3.8-сурет – TensorFlow/Karas негізіндегі вариациялық автоэнкодер (VAE) энкодерінің архитектурасы

VAE декодері энкодердің айнадағы бейнесі бола отырып, жасырын z айнымалысын қабылдайды және бор спектрограммасын транспозицияланған конволюциялық қабаттар сериясы арқылы қалпына келтіреді. Оқытылған автокодер қалыпты дыбысты дәл шығарады, ал ауытқулармен (мысалы, мойынтіректердің дірілдеуі) - қайта құру қателігі күрт артып, ақаулық туралы сигнал береді. Декодердің программалық құрылымын 3.9-суреттен көре аламыз.

```

# Построение декодера
latent_inputs = tf.keras.Input(shape=(latent_dim,))
x = tf.keras.layers.Dense(32 * 32 * 64, activation='relu')(latent_inputs)
x = tf.keras.layers.Reshape((32, 32, 64))(x)
x = tf.keras.layers.Conv2DTranspose(64, 3, activation='relu', strides=2, padding='same')(x)
x = tf.keras.layers.Conv2DTranspose(32, 3, activation='relu', strides=2, padding='same')(x)
output_img = tf.keras.layers.Conv2DTranspose(1, 3, activation='sigmoid', padding='same')(x)
decoder = tf.keras.Model(latent_inputs, output_img, name='decoder')
decoder.summary()

```

Model: "decoder"


Layer (type)	Output Shape	Param #
input_layer_1 (InputLayer)	(None, 16)	0
dense_1 (Dense)	(None, 65536)	1,114,112
reshape (Reshape)	(None, 32, 32, 64)	0
conv2d_transpose (Conv2DTranspose)	(None, 64, 64, 64)	36,928
conv2d_transpose_1 (Conv2DTranspose)	(None, 128, 128, 32)	18,464
conv2d_transpose_2 (Conv2DTranspose)	(None, 128, 128, 1)	289

Total params: 1,169,793 (4.46 MB)
Trainable params: 1,169,793 (4.46 MB)
Non-trainable params: 0 (0.00 B)

3.9-сурет – TensorFlow/Karas негізіндегі вариациялық автоэнкодер (VAE) декодерінің архитектурасы

Келесі 3.10-суретте бор-кепстральды коэффициенттерге (MFCC) негізделген белгілердің корреляциялық матрицасы, жабдықтың діріл

сигналдарының спектрлік және автокорреляциялық сипаттамалары көрсетілген.




3.10-сурет – Дыбыстық сигнал белгілерінің корреляциялық жылу картасы (MFCC және спектрлік сипаттамалар)

Матрица параметрлер арасындағы сызықтық қатынас дәрежесін көрсетеді. Оң корреляция (қызыл) тікелей байланысты, теріс (көк) кері қатынасты көрсетеді. Ең үлкен теріс корреляция MFCC_2 мен Spectral Rolloff (-0.97) арасында, ал ең үлкен оң корреляция MFCC_1 мен Autocorrelation (0.79) арасында анықталды. Бұл талдау артық белгілерді болдырмауға және нейрондық желінің кіріс векторын оңтайландыруға мүмкіндік береді. Бұл болжамды модельдің өнімділігі мен дәлдігін едәуір жақсартады, технологиялық жабдықтың ақауларын ерте анықтау міндетінде оның тиімділігін арттырады.

Көрнекі талдау болжамды және нақты мәндер арасындағы сәйкестіктің жоғары дәрежесін көрсетеді. Модель көптеген ауытқуларды нақты деректермен бірдей аралықта бекіту арқылы дұрыс анықтайды. Жеке нүктелердегі шамалы сәйкессіздіктер оқу үлгісінің ерекшеліктерімен байланысты және практикалық қолдану шеңберінде рұқсат етіледі.

3.11-суретте жаттығу және валидация үлгілерінде оқыту кезінде модельдің жоғалту функциясының (loss) динамикасы көрсетілген. X осі


бойынша оқу дәуірлері, Y осі бойынша — шығын мәні.



3.11-сурет – Оқыту және валидация кезеңдеріндегі модельді жоғалту функциясының динамикасы

График әр дәуірде loss-тің сенімді төмендеуін көрсетеді, бұл модельдің тұрақты конвергенциясын көрсетеді. Валидациялық шығындар бүкіл оқу процесінде жаттығудан төмен немесе оған тең, бұл қайта оқытудың жоқтығын көрсетеді. 10-шы дәуірге қарай шығындар мәні 0.2 — ден аз, ал 24-ші дәуірге қарай тұрақтандыру 0.15 шамасында. Бұл модельдің жоғары жалпылау қабілетін және болжамды қызмет көрсету мәселесінде таңдалған архитектураның тиімділігін растайды.


3.12-сурет оқыту дәуірлері бойынша жаттығу және валидация үлгілеріндегі модельдің дәлдік динамикасы көрсетілген. Бесінші дәуірде 93%-дан жоғары дәлдікке қол жеткізілді, ал 25 — ші дәуірде шамамен 94-95% Дәлдік деңгейі тұрақты болды.



3.12-сурет – Оқыту және валидация үлгілеріндегі модель дәлдігінің динамикасы

Тегіс өсу және күрт ауытқулардың болмауы жақсы таңдалған модель архитектурасын және теңдестірілген гиперпараметрлерді көрсетеді. Оқыту мен валидация қисықтары арасында айтарлықтай алшақтықтың болмауы модельдің қайта оқытуға төзімділігін көрсетеді. Бұл нәтиже модельдің жалпылаудың жоғары қабілетін және нақты өндіріс жағдайында болжамды техникалық қызмет көрсету міндеттеріне жарамдылығын растайды.

Келесі 3.13-суретте модельдің болжамдарын (көк сызық) 90 бақылау бойынша жабдықтың істен шығуының нақты белгілерімен (жасыл сызық) салыстыру көрсетілген. X осі бойынша уақыт терезесінің индексі (row), Y осі бойынша - екілік күй: "0" - қалыпты, "1" - аномалия анықталды. График болжамды техникалық қызмет көрсету тапсырмалары үшін қолданылатын Вариациялық автоэнкодер көмегімен қалыпты деректерде оқытылған модельдің жұмысын көрсетеді.




3.13-сурет – Сынақ үлгісіндегі болжамды және нақты аномалия белгілерін салыстыру

Көрнекі талдау болжамды және нақты мәндер арасындағы сәйкестіктің жоғары дәрежесін көрсетеді. Модель көптеген ауытқуларды нақты деректермен бірдей аралықта бекіту арқылы дұрыс анықтайды. Жеке нүктелердегі шамалы сәйкессіздіктер оқу үлгісінің ерекшеліктерімен байланысты және практикалық қолдану шеңберінде рұқсат етіледі.

Жабдықтың күй классификаторының қате матрицасы "қалыпты" немесе "ақаулық" сыныптарын анықтаудың жоғары дәлдігін көрсетеді. Модель объектілердің болмау жағдайларын олардың айқын визуалды ауырлығына байланысты ең тиімді түрде таниды. Қызып кетудің дифференциациясы және олардың ұқсас сипаттамаларына байланысты діріл

ауытқулары кезінде шамалы қателіктер байқалады. Болжамдардың көпшілігі матрицаның диагоналіне бағытталған, бұл жіктеудің жоғары дұрыстығын көрсетеді. Жалған позитивтердің саны аз, ал нақты ақаулар іс жүзінде танылмайды. Жіктеудің жалпы дәлдігі 95% - дан асады, бұл жүйенің өнеркәсіптік пайдалану және ақаулықтарды ерте анықтау жағдайында қолдану сенімділігін растайды. Келесі 3.14-суретте біздің моделдің қателерінің матрицасы көрсетілген.



3.14-сурет – Нейрондық желі қателерінің матрицасы


Машиналық оқытуды қолдана отырып, болжамды қызмет көрсету перспективасына қарамастан, оны жүзеге асыру бірқатар негізгі міндеттерді шешуді талап етеді. Модельдердің тиімділігі көбінесе өндірісте жеткіліксіз болатын белгіленген деректердің сапасы мен қол жетімділігіне тікелей байланысты [11]. Деректердегі шу мен жіберіп алу оларды алдын ала өңдеудің тиімді әдістерін қолдануды талап етеді [12]. Сонымен қатар, PdM масштабтау қажетті сенсорлар мен қосылымдармен жабдықталмаған ескірген жабдықты жаңарту қажеттілігімен қиындайды. Бұл айтарлықтай шығындарды талап етеді, әсіресе шағын және орта бизнес үшін. IoT және бұлтты технологияларды енгізу киберқауіптердің қаупін арттырады, сондықтан қауіпсіз деректерді беруді қамтамасыз ету өте маңызды [13].

PdM тиімділігін арттыру үшін болжамдардың дәлдігін жақсартатырып, нақты жұмыс жағдайларын имитациялауға қабілетті цифрлық егіздерді біріктіру керек. Ұзақ мерзімді болжау сапасын жақсартуға қабілетті трансформаторлар сияқты терең оқытудың жаңа архитектуралары да перспективалы [1]. Қуаты аз чиптері бар шекаралық AI пайдалану деректерді нақты уақыт режимінде өңдеуге мүмкіндік береді, кідірістерді азайтады және болжамды техникалық қызмет көрсету жүйелерінің сенімділігін арттырады.

3.3 Болжалды қызмет көрсету жүйесін әзірлеу және енгізу. Болашақ даму бағыттары.

Өнеркәсіптік автоматтандыру жағдайында болжамды қызмет көрсетудің зияткерлік жүйесін жобалау және енгізу процестерін стандарттау үшін егжей-тегжейлі жол картасы әзірленді. Ол шешімнің өмірлік циклінің барлық негізгі кезеңдерін қамтиды-бастапқы деректерді жинаудан бастап толық интеграция мен өнеркәсіптік пайдалануға дейін. Әрбір кезең цифрлық трансформация принциптерін ескере отырып, модельдерді үздіксіз оқытуды қамтамасыз ету және OPC UA протоколын өнеркәсіптік деректермен алмасудың әмбебап платформасы ретінде пайдалану арқылы қалыптасады [23].

Төмендегі 3.15 - суретте деректерді жинаудан бастап модельді пайдалануға және жаңартуға дейінгі процестің негізгі кезеңдерін қамтитын болжамды қызмет көрсетуді енгізу схемасы берілген. Бұл схема іс-шаралар кешенін және іс-әрекеттердің логикалық реттілігін көрнекі түрде көрсетуге мүмкіндік береді.



3.15-сурет – Өнеркәсіпте болжамды қызмет көрсетуді енгізудің негізгі кезеңдері

Бірінші кезеңде жобаның басымдықтары, міндеттері мен мақсаттары тұжырымдалады. Маңызды мәселе-сәтсіздіктер туындаған кезде айтарлықтай

шығындарға әкелуі мүмкін маңызды өндірістік нысандарды таңдау. Мысалы, үрлемелі құю машиналарында сорғы қондырғылары мен температураны реттеу модульдері ең осал компоненттер болып табылады.

Негізгі қадамдардың бірі-бар деректерді тексеру. Бұл болжамды модель құру үшін қандай параметрлер маңызды екенін түсінуге мүмкіндік береді. Датчиктерден алынған мәліметтер температура, қысым, діріл күші, жылдамдық және қуат сияқты параметрлерді қамтиды. Сондай-ақ техникалық қызмет көрсету және жөндеу жүйесінен алынған сәтсіздіктер туралы тарихи деректер ескеріледі.

Деректерді жинақтау-бұл ең ұзақ процесс (жоба уақытының шамамен 80%), өйткені ұзақ уақыт бойы нақты уақыт режимінде деректерді жинау қажет. Негізгі міндет-жабдықтың қалыпты күйінің деректерін де, ақаулар туындаған кезде деректерді де қамтитын сапалы үлгіні құру.

Деректер қорын сандық бағалау үшін келесі формула қолданылады (30).

$$D = \sum_{i=1}^n x_i \times t_i \quad (3.1)$$

мұндағы D - жинақталған деректердің жалпы көлемі;

x_i - уақыт бірлігінде алынған мәліметтер саны;

t_i - i интервалда деректерді жинау ұзақтығы;

n - уақыт аралықтарының жалпы саны. Осылайша, деректерді жинау кезеңі мен тығыздығы неғұрлым көп болса, соғұрлым дәлірек оқытылған модель болады.

Шешімнің нәтижесі мен тиімділігін бағалау кезеңінде болжамды қызмет көрсетуді енгізу нәтижелерін бағалау жүргізіледі. Негізгі мақсат - жоспардан тыс тоқтап қалу мен жөндеу шығындарын азайтудың экономикалық әсерін анықтау [49].

Экономикалық әсерді есептеу үшін рентабельділік индексі есептеу (PI) формуласын қолдануға болады (31).

$$PI = \frac{\sum_{t=1}^T \frac{R_t}{(1+r)^t}}{\sum_{t=1}^T \frac{C_t}{(1+r)^t}} \quad (3.2)$$

мұндағы R_t - t уақыт кезеңіндегі PdM арқылы табыс немесе үнемдеу;

C_t - уақыт бірлігінде алынған мәліметтер саны;

r - дисконттау ставкасы (дисконттау ставкасы немесе мүмкіндік ставкасы);

T - жобаның жалпы мерзімі жылдарда немесе басқа уақыт аралықтарында. Егер PI 1-ден үлкен болса, бұл жобаның тиімді екенін білдіреді, болжамды қызметті жүзеге асырудан түскен пайда оны жүзеге асыру шығындарынан көп.

Экономикалық бағалау негізінде келесі шешімдердің бірі қабылданады:

- Іске асыру-егер бағалау айтарлықтай экономикалық пайда көрсеткен болса;
- Деректерді жинақтауды тоқтата тұру-Егер деректер көлемі дәл болжау үшін жеткіліксіз болса;
- Ұшқышты ұзарту - егер оң динамика болса, бірақ растау үшін көп уақыт қажет болса;
- Жобадан бас тарту-егер іске асыру аз әсер етсе немесе теріс әсер етсе.

Болжалды қызмет пайдалануға берілгеннен кейін жүйенің жұмысына тұрақты мониторинг жүргізіледі. Бұл кезеңде сәтті болжамдар да, модель қателері де талданады. Жалған оң және жалған теріс позитивтерді талдауға ерекше назар аударылады.

Болжамдардың дәлдігін талдау үшін F1-score метрикасы қолданылады (32), (33), (34).

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}, \quad (3.3)$$

$$Precision = \frac{TP}{TP + FP}, \quad (3.4)$$

$$Recall = \frac{TP}{TP + FN} \quad (3.5)$$

мұндағы TP - шынайы оң позитивтердің саны;

FP - жалған оң позитивтердің саны;

FN - жалған теріс позитивтердің саны. F1-score жоғары мәні болжамды жүйенің сапалы жұмысын көрсетеді. Әрі қарай, кестеде болжамды қызмет көрсетуді енгізудің негізгі кезеңдері және әр кезеңде жүзеге асырылатын іс-шаралардың қысқаша сипаттамасы келтірілген. Толықтыруда келтірілген график жобаны іске асырудың логикасын және қадамдар арасындағы байланысты айқын көрсетеді. жоғары мәні болжамды жүйенің сапалы жұмысын көрсетеді

Кесте 3.1 - ML және OPC UA негізіндегі болжамды қызмет көрсетуді енгізу жобасының жол картасы [10].

№	Кезең	Мазмұны
1	Деректерді жинау және шоғырландыру	Технологиялық жабдыққа техникалық құжаттаманы, сенсорлардың тарихи деректерін (тоқ, температура, діріл, қысым, дыбыс), авариялар мен тоқтап қалулар журналдарын, машиналық көру жүйелерінен бейне ағындарды жинау. Сақтық көшірме жасау.
2	Деректерді дайындау және тазарту	Деректердің тұтастығын тексеру. Өткізіп жіберулер мен ауытқуларды жою. Тазалау және қалыпқа келтіру. Сенсорлар мен кескіндердің уақыт белгілерін синхрондау. Параметрлер арасындағы корреляциялық матрицаны

		есептеу.
3	Бастапқы талдау және диагностика	Жабдықтың тұрақты жұмыс кезеңдерін анықтау. Автоэнкодерді оқыту үшін қалыпты мінез-құлық учаскелерін анықтау. Техникалық маңызды белгілерді анықтау.
4	Модельдеу және оқыту	Автоэнкодерді "сау" деректерге үйрету. RUL тарихи деректерінде сызықтық регрессия моделін оқыту. Байес жаңартуы үшін көрсеткіштерді біріктіру. Модельдерді тексеру.
5	Интеграция және визуализация	Жүйені OPC UA және SCADA-мен біріктіру. Power BI-де нәтижелерді визуализациялау. Инженерлер үшін ескертулер мен дабылдарды орнату. Менеджмент үшін аналитикалық есептерді дайындау.
6	Орналастыру және пайдалану	Өндірісте жүйені енгізу. Болжамдардың сапасын бақылау. Үздіксіз модельдік оқытуды қолдау.
7	Қызмет көрсету және жаңарту	Модельді жаңа деректерге жаңарту. Қауіпсіздік жүйелерін қолдау, сенсорларды жаңарту, камераларды калибрлеу. Модель нұсқаларын қолдау және деректер сапасын бақылау.

Болжалды қызмет көрсетуді енгізу өнеркәсіптік кәсіпорындар үшін экономикалық негізделген шешім болып табылады. Іске асыру кезеңдері нақты тапсырмаларды қоюды, деректерді жинақтауды, экономикалық бағалауды және нәтижелерді бақылауды қамтиды. Машиналық оқытудың заманауи әдістерін қолдану жабдықтың істен шығуын жоғары дәлдікпен болжауға және техникалық қызмет көрсету шығындарын азайтуға мүмкіндік береді. Іске асырудағы негізгі қиындықтар деректерді жинақтаудың ұзақ процесімен және жаңа мәліметтер негізінде модельді үнемі жаңартып отыру қажеттілігімен байланысты.

Deloitte зерттеуінің нәтижелеріне сәйкес, болжамды аналитиканы енгізу кәсіпорындарға техникалық қызмет көрсету және жабдықты жөндеу шығындарын 5% - дан 10% - ға дейін төмендетуге мүмкіндік береді [41]. Сарапшылардың болжамы бойынша, 2024 жылға қарай болжамды қызмет көрсетудің әлемдік нарығы 10,7 млрд АҚШ долларына жетеді, орташа жылдық өсу қарқыны 28,8% [41]. Бұл өсу екі негізгі факторға байланысты: деректерді талдаудың озық технологияларын қолдану қажеттілігінің артуы, сондай-ақ операциялық шығындарды азайтуға және жабдықтың тоқтап қалу уақытын азайтуға ұмтылу.

Grandview Research мәліметтері бойынша, 2022 жылы болжамды қызмет көрсетудің жаһандық нарығы 7,85 миллиард АҚШ долларына бағаланды [43]. 2023-2030 жылдар аралығында орташа жылдық өсу қарқыны CAGR 29,5% болса, бұл көрсеткіш 2030 жылға қарай 60,13 миллиард АҚШ долларына жетеді деп күтілуде [43].

Сонымен қатар, Markets and Markets мәліметтері бойынша, жаһандық болжамды қызмет көрсету нарығы 2024 жылы 10,6 миллиард доллардан 2029 жылға қарай 47,8 миллиард долларға дейін өседі деп болжануда, бұл кезеңде CAGR 35,1% құрайды. [42].

Орташа алғанда, техникалық қызмет көрсету шығындары дайын өнімді өндіру құнының 15% - дан 60% - на дейін, ауыр өнеркәсіпте бұл көрсеткіштер жалпы құнның 50% - на дейін жетуі мүмкін [3]. Бұл деректер өндіріс желілерінде қолданылатын машиналар мен олардың компоненттеріне уақтылы қызмет көрсетудің маңызды маңыздылығын көрсетеді. Жабдықтардың сенімділігі мен қауіпсіздігін арттырумен қатар, техникалық қызмет көрсету шығындарын тиімді оңтайландыру қазіргі заманғы өнеркәсіптік кәсіпорындарды дамытудың негізгі бағыты болып табылады.

ҚОРЫТЫНДЫ

Бұл зерттеу өнеркәсіптік автоматтандырудағы болжамды қызметке негізделген машиналық оқытудың трансформациялық әсерін көрсетеді. Реактивті және профилактикалық тәсілдер сияқты дәстүрлі техникалық қызмет көрсету стратегиялары жоғары шығындар мен жоспарланбаған үзілістерге байланысты тиімсіз болып шықты. ML, IoT және аналитиканың нақты уақыттағы интеграциясы болжамды қызметке ақауларды белсенді түрде анықтауға, техникалық қызмет көрсету кестелерін оңтайландыруға және операциялық шығындарды азайтуға мүмкіндік береді [23].

Практикалық маңыздылығы - пайдалану шығындарын азайту, жабдықтың сенімділігін арттыру үшін ұсынылған жүйені пайдалану мүмкіндігі, сонымен қатар диагностика мен техникалық қызмет көрсетуді жоспарлау процестерін автоматтандыру арқылы инженерлік персоналдың еңбек шығындарын азайту. Теориялық маңыздылығы AUTOENCODER модельдері мен OPC UA-ны қартайған жабдыққа және тұрақсыз ортаға бейімделу мүмкіндігі бар өндірістік жүйелерге біріктіруге архитектуралық көзқарасты негіздеуде көрінеді.

Қазақстан Республикасының контекстінде бұл жобаның ғылыми және техникалық қана емес, стратегиялық маңызы да бар. Өз елімнің азаматы ретінде мен Қазақстанның өнеркәсіптік кәсіпорындарының басым көпшілігі кеңестік кезеңде құрылғанын және бүгінде жаңғырту мен цифрлық технологияларға көшуді аса қажет ететінін түсінемін. Білікті инженерлік кадрлардың тапшылығы жағдайында, әсіресе жастар арасында, жабдықтың жай-күйін техникалық диагностикалау мен болжауды автоматтандыруға қабілетті зияткерлік жүйелерді енгізу өте маңызды. Машиналық оқыту негізінде болжамды қызмет көрсету жүйелерін әзірлеу және іске асыру Қазақстанның өнеркәсіптік секторын цифрлық жаңғырту жолындағы маңызды қадам болады. Бұл шешім отандық кәсіпорындардың тұрақтылығы мен бәсекеге қабілеттілігін арттырып қана қоймай, елдің технологиялық егемендігі үшін берік негіз қалауға мүмкіндік береді. Бұл әсіресе машина жасау, тау-кен және тамақ өнеркәсібі сияқты негізгі салаларға қатысты. Сонымен қатар, мұндай жобалар жоғары технологиялардың заманауи мәдениетін қалыптастырып, инженерлік мамандықтардың беделін қалпына келтіре отырып, қазақстандық инженерлер мен IT-мамандардың жаңа буынын шабыттандыра алады. Отанымыздың зияткерлік және өнеркәсіптік әлеуетін дамытуға қосқан үлесі - бұл менің кәсіби мақсатым ғана емес, сонымен қатар азаматтық миссиям.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

- [1] Yan Gao, Chengzhang Chai, Haijiang Li and Weiqi Fu. A deep learning framework for intelligent fault diagnosis using AutoML-CNN and image-like data fusion.
- [2] Davide Pagano. A predictive maintenance model using Long Short-Term Memory Neural Networks and Bayesian inference.
- [3] Deloitte. Predictive Maintenance. Taking pro-active measures based on advanced data analytics to predict and avoid machine failure.
- [4] Aysegul Ucar, Mehmet Karakose and Necim Kırımça. Artificial intelligence for predictive maintenance applications: Key components, trustworthiness, and future trends.
- [5] MD Raisul Islam, MD Zakir Hossain Zamil, MD Eshmam Rayed, MD Moshin Kabir, M. F. Mridha, Satoshi Nishimura, and Jungpil Shin. Deep learning and computer vision techniques for enhanced quality control in manufacturing processes.
- [6] International Journal of Engineering Research & Technology (IJERT). ISSN: 2278-0181. AI Based PdM in Manufacturing Industry 4.0: A Bibliographic Review.
- [7] P. Nunes, J. Santos, E. Rocha. Challenges in predictive maintenance – A review.
- [8] Oluwatobi Dayo-Olupona, Bekir Genc, Turgay Celik, Samson Bada. Adoptable approaches to predictive maintenance in mining industry: An overview.
- [9] Modelling of predictive maintenance for a periodically inspected system
- [10] Bissembayev A.S., Amangeldy I.S. Enhancing operational efficiency in industry 4.0: a predictive maintenance approach.
- [11] Julio Hurtado, Dario Salvati, Rudy Semola, Mattia Bosio, Vincenzo Lomonaco. Continual learning for predictive maintenance: Overview and challenges.
- [12] Sherien Elkateb, Ahmed M’etwalli, Abdelrahman Shendy, Ahmed E.B. Abu-Elanien. Machine learning and IoT – Based predictive maintenance approach for industrial applications.
- [13] Г.Н. Сансызбаева, А. Кузенбаева. Проблемы и перспективы обрабатывающей промышленности РК.
- [14] Chong Chen, Huibin Fu, Yu Zheng, Fei Tao, Ying Liu. The advance of digital twin for predictive maintenance: The role and function of machine learning.
- [15] Analytic Company «Алгоритм». Цифровая зрелость промышленности: текущий уровень цифровизации обрабатывающих отраслей, 2024. URL: <https://algarytm.kz/tpost/x1szmmp8y1-tsifrovaya-zrelost-promishlennosti-tekus>.
- [16] Кейкин Дулат. Интервью: нехватка инженеров в Казахстане и проблемы индустрии. URL: [Press.kz](https://press.kz).
- [17] LS.kz. Дефицит кадров в Казахстане превысит 1,5 млн человек. URL: lsm.kz.

- [18] KONUX. Железнодорожная инфраструктура. URL: https://www.deutschebahn.com/de/Digitalisierung/startups/db_startups/weichen-6898954.
- [19] Honeywell - the future is what we make it. URL: <https://www.honeywell.com/us/en/solutions/honeywell-forge>.
- [20] А.В. Чернухин, Е.А. Богданов, Т.В. Савицкая. Построение модели предиктивной аналитики неисправностей промышленного оборудования.
- [21] Amir Rafati, Hamid Reza Shaker. Predictive maintenance of district heating networks: A comprehensive review of methods and challenges.
- [22] Aitzaz Ahmed Murtaza, Amina Saher, Muhammad Hamza Zafar, Syed Kumayl Raza Moosavi, Muhammad Faisal Aftab, Filippo Sanfilippo. Paradigm shift for predictive maintenance and condition monitoring from Industry 4.0 to Industry 5.0: A systematic review, challenges and case study.
- [23] Panagiotis Mallioris, Eirini Aivazidou, Dimitrios Bechtsis. Predictive maintenance in Industry 4.0: A systematic multi-sector mapping.
- [24] QAZ Neurotech. URL: <https://astanahub.com/account/company/5733/>.
- [25] Kortical. Автомобильная промышленность. URL: <https://kortical.com/case-studies/ford-predicting-failures-ai-example>.
- [26] Казахстанский стартап Faceplate внедрил инструменты IIoT. URL: <https://faceplate.io/kazakhstanskij-startap-faceplate-vnedril-instrumenty-iiot-v-pishhevoj-promyshlennosti-56>.
- [27] Predicting machine failures from multivariate time series: an industrial case study. URL: <https://arxiv.org/html/2402.17804v1#:~:text=Predictive%20maintenance%20is%20a%20strategy,25%3B%20ShaominWu2010>.
- [28] Predictive Maintenance of Urban Metro Vehicles: Classification of Air Production Unit Failures Using Machine Learning. URL: https://www.researchgate.net/publication/371035904_Predictive_Maintenance_of_Urban_Metro_Vehicles_Classification_of_Air_Production_Unit_Failures_Using_Machine_Learning#:~:text=businesses,predictive%20maintenance%20is%20increased%20uptime.
- [29] A systematic review of rolling bearing fault diagnoses based on deep learning and transfer learning: Taxonomy, overview, application, open challenges, weaknesses and recommendations. URL: <https://www.sciencedirect.com/science/article/pii/S2090447922002568#:~:text=The%20results%20of%20the%20classification,it%20comes%20to%20detecting>.
- [30] Condition Monitoring Using a Latent Space of Variational Autoencoder Trained Only on a Healthy Machine. <https://www.mdpi.com/1424-8220/24/21/6825#:~:text=A%20common%20problem%20in%20machine,data%20from%20the%20faulted%20object>.
- [31] Lin Zhang and Nicholas Konz. Computer vision techniques in manufacturing.
- [32] Longfei Zhou, Andrzej Sioma. Vision system in product quality control systems.

[33] Бучка К. А. Обзор диапазона задач машинного зрения на современном этапе развития.

[34] Siemens. URL: [PROFIBUS/PROFINET communication between two projects in TIA Portal](#).

[35] Siemens. URL: [OPC UA Access to S7-1200 PLC via modeled OPC UA Server Interface](#).

[36] Barbara Martini, Denise Bellisario, and Paola Coletti. Human-Centered and sustainable artificial intelligence in industry 5.0: Challenges and Perspectives.

[37] MD Raisul Islam, MD Zakir Hossain Zamil, MD Eshmam Rayed, MD Moshin Kabir, M. F. Mridha, Satoshi Nishimura, and Jungpil Shin. Deep learning and computer vision techniques for enhanced quality control in manufacturing processes.

[38] И. В.Девятов, Д. В.Туев. Реализация сервис-ориентированного подхода для повышения конкурентоспособности производителя специальных транспортных средств.

[39] OPC UA + MQTT = A Popular Combination for Iot. URL: <https://opcconnect.opcfoundation.org/2019/09/opc-ua-mqtt-a-popular-combination-for-iot-expansion/?utm>.

[40] Troubleshooting OPC Publisher. URL: azure.github.io/Industrial-IoT/opc-publisher/troubleshooting.

[41] Deloitte. Predictive maintenance and the smart factory. Predictive maintenance connects machines to reliability professionals through the power of the smart factory.

[42] Predictive Maintenance Market Size, Share & Trends Analysis Report By Component, By Solution, By Service, By Deployment, By Enterprise Size, By Monitoring Technique, By End-use, By Region, And Segment Forecasts, 2023 – 2030. URL: <https://www.grandviewresearch.com/industry-analysis/predictive-maintenance-market>

[43] Predictive Maintenance Market. URL: <https://www.marketsandmarkets.com/Market-Reports/operational-predictive-maintenance-market-8656856.html>

[44] П.Ю. Гусев. Анализ возможностей предиктивной аналитики при прогнозировании состояния оборудования АЭС.

[45] Ida Hector and Rukmani Panjanathan. Predictive maintenance in Industry 4.0: a survey of planning models and machine learning techniques

[46] А. А. Рыжова, Д. А. Рыжов. Применение концепций индустрия 4.0 для решения ключевых задач современных предприятий.

[47] Ahmed Raza, Vladimir Ulanskyb. Modelling of predictive maintenance for a periodically inspected system.

[48] Nur Haninie Abd Wahab, Khairunnisa Hasikin, Khin Wee Lai, Kaijian Xia, Lulu Bei, Kai Huang and Xiang Wu. Systematic review of predictive maintenance and digital twin technologies challenges, opportunities, and best practices.

[49] Petr Blaha, Matus Kozovsky, Zdenek Havranek, Martin Dosedel, Franz Wotawa, David Kaufmann, Adil Amukhtar, Iulia Nica, Florian Klück and Hermann Felbinger. Real-Time predictive maintenance – artificial neural network based diagnosis.

[50] Muhammad Hussain. Sustainable machine vision for industry 4.0: A comprehensive review of convolutional neural networks and hardware accelerators in computer vision.

[51] André Rino Amorim, Boris Bret and José M. González-Méijome. Opto-Mechanical eye models, a review on human vision applications and perspectives for use in industry.

Қосымша А

```
# Проверяем наличие GPU
!nvidia-smi

# Установка зависимостей
!pip install -q librosa tensorflow ffmpeg-python

# Устанавливаем нужные библиотеки
!pip install -q librosa tensorflow ffmpeg-python moviepy

import os, glob
import numpy as np
import librosa
import tensorflow as tf
from moviepy.editor import VideoFileClip
import matplotlib.pyplot as plt

# Монтируем диск
from google.colab import drive
drive.mount('/content/drive')

import os
print(os.listdir("/content/drive/MyDrive/DataSet/1/normal"))
print(os.listdir("/content/drive/MyDrive/DataSet/1/abnormal"))

# Пути к папкам с аудиоданными
normal_pump_path = "/content/drive/MyDrive/DataSet/1/normal"
abnormal_pump_path = "/content/drive/MyDrive/DataSet/1/abnormal"

normal_files = glob.glob(os.path.join(normal_pump_path, "*.wav"))
abnormal_files = glob.glob(os.path.join(abnormal_pump_path, "*.wav"))
print(f"Найдено {len(normal_files)} нормальных и {len(abnormal_files)} аномальных файлов")

# Общие параметры
SR = 22050
DURATION = 10.0
N_MELS = 128
MAX_DB = 80.0
LATENT_DIM = 16
BATCH_SIZE = 32
EPOCHS_VAE = 30
EPOCHS_RUL = 50
```


А қосымшасының жалғасы

```
# функция конвертации wav→128×128 мел
def load_audio_to_mel(path,
                      sr=SR,
                      duration=DURATION,
                      n_mels=N_MELS,
                      max_db=MAX_DB):
    y, sr = librosa.load(path, sr=sr)
    desired_len = int(sr * duration)
    if len(y) < desired_len:
        y = np.pad(y, (0, desired_len-len(y)))
    else:
        y = y[:desired_len]
    mel = librosa.feature.melspectrogram(y=y, sr=sr, n_mels=n_mels)
    mel_db = librosa.power_to_db(mel, ref=np.max, top_db=max_db)
    mel_norm = (mel_db + max_db) / max_db
    # pad или trim по time-axis
    if mel_norm.shape[1] < n_mels:
        pad = n_mels - mel_norm.shape[1]
        mel_norm = np.pad(mel_norm, ((0,0),(0,pad)), mode='constant')
    return mel_norm[:, :n_mels]

# Собираем заполненные массивы
def build_dataset(file_list):
    specs = [load_audio_to_mel(p) for p in file_list]
    X = np.stack(specs,0)[...,np.newaxis].astype(np.float32) # (N,128,128,1)
    return X

X_norm = build_dataset(normal_files)
X_abnorm = build_dataset(abnormal_files)
print("X_norm:", X_norm.shape)
print("X_abnorm:", X_abnorm.shape)

# --- Строим VAE -----
from tensorflow.keras import layers, Model

# Encoder
inp = layers.Input((N_MELS,N_MELS,1))
x = layers.Conv2D(16,3,2,'same', activation='relu')(inp) # 64x64x16
x = layers.Conv2D(32,3,2,'same', activation='relu')(x) # 32x32x32
x = layers.Conv2D(64,3,2,'same', activation='relu')(x) # 16x16x64
```

А қосымшасының жалғасы

```
x = layers.Conv2D(128,3,2,'same',activation='relu')(x) # 8x8x128
flat = layers.Flatten()(x)
z_mean = layers.Dense(LATENT_DIM, name='z_mean')(flat)
z_log_var = layers.Dense(LATENT_DIM, name='z_log_var')(flat)

def sampler(args):
    mu, logvar = args
    eps = tf.random.normal(tf.shape(mu))
    return mu + tf.exp(0.5*logvar)*eps

z = layers.Lambda(sampler, name='z')([z_mean,z_log_var])

encoder = Model(inp, [z_mean,z_log_var,z], name='encoder')
encoder.summary()

# Decoder
latent_inp = layers.Input((LATENT_DIM,))
x = layers.Dense(8*8*128, activation='relu')(latent_inp)
x = layers.Reshape((8,8,128))(x)
x = layers.Conv2DTranspose(64,3,2,'same',activation='relu')(x) #16x16x64
x = layers.Conv2DTranspose(32,3,2,'same',activation='relu')(x) #32x32x32
x = layers.Conv2DTranspose(16,3,2,'same',activation='relu')(x) #64x64x16
out = layers.Conv2DTranspose(1,3,2,'same',activation='sigmoid')(x) #128x128x1

decoder = Model(latent_inp,out, name='decoder')
decoder.summary()

# VAE custom train loop
optimizer = tf.keras.optimizers.Adam(1e-3)
dataset =
tf.data.Dataset.from_tensor_slices(X_norm).shuffle(1000).batch(BATCH_SIZE)

history_loss = []
for ep in range(EPOCHS_VAE):
    tot=0; rec=0; kl=0; cnt=0
    for batch in dataset:
        with tf.GradientTape() as tape:
            m, v, z_ = encoder(batch, training=True)
            recon = decoder(z_,training=True)
            rloss = tf.reduce_mean(tf.reduce_sum(tf.square(batch-recon),[-3,-2,-1]))
            kloss = tf.reduce_mean(-0.5*tf.reduce_sum(1+v-m*m-tf.exp(v),axis=1))
```

А қосымшасының жалғасы

```
    loss = rloss+kloss
    vars = encoder.trainable_variables+decoder.trainable_variables
    grads = tape.gradient(loss, vars)
    optimizer.apply_gradients(zip(grads,vars))
    tot+=loss; rec+=rloss; kl+=kloss; cnt+=1
    history_loss.append([tot/cnt, rec/cnt, kl/cnt])
    if ep%5==0:
        print(f"ep {ep:3d}: tot={tot/cnt:.4f} rec={rec/cnt:.4f} kl={kl/cnt:.4f}")

# рисуем loss
hist = np.array(history_loss)
plt.plot(hist[:,0],label='total')
plt.plot(hist[:,1],label='recon')
plt.plot(hist[:,2],label='kl')
plt.legend(); plt.show()

# --- Строим RUL-регрессию -----
# из нормальных латенты RUL=100, из аномальных RUL=10
mu_norm = encoder.predict(X_norm)[0]
mu_abnorm = encoder.predict(X_abnorm)[0]
rul_norm = np.full(len(mu_norm), 100.,dtype=np.float32)
rul_abnorm = np.full(len(mu_abnorm), 10.,dtype=np.float32)

Xr = np.vstack([mu_norm, mu_abnorm])
yr = np.concatenate([rul_norm, rul_abnorm])

print("RUL:", Xr.shape, yr.shape)

# При компиляции явно укажем метрику MSE
rul_model.compile(optimizer='adam',
loss='mse',
metrics=['mse'])

# Обучаем
h = rul_model.fit(Xr, yr, epochs=EPOCHS_RUL, batch_size=16, verbose=0)

# Посмотрим, какие ключи есть
print(h.history.keys())
```

А қосымшасының жалғасы

```
# Отобразим график по правильному ключу:
# - если в history есть 'mse' — используем его
# - иначе — используем 'mean_squared_error' или 'loss'
if 'mse' in h.history:
    plt.plot(h.history['mse'], label='mse')
elif 'mean_squared_error' in h.history:
    plt.plot(h.history['mean_squared_error'], label='mse')
else:
    plt.plot(h.history['loss'], label='loss (MSE)')

plt.title("RUL Model MSE over epochs")
plt.xlabel("Epoch")
plt.ylabel("MSE")
plt.legend()
plt.show()

# И финальное значение
final_mse = (h.history.get('mse') or
             h.history.get('mean_squared_error') or
             h.history['loss'])
print("Final MSE:", final_mse[-1])

# --- Анализ видео -----
video = VideoFileClip("/content/drive/MyDrive/DataSet/Грузия Кока Кола.mp4")
audio = video.audio
audio.write_audiofile("temp.wav", fps=SR, verbose=False, logger=None)
video.close()

import matplotlib.pyplot as plt

plt.figure(figsize=(6,4))
plt.plot(hist[:,0], label='total')
plt.plot(hist[:,1], label='recon')
plt.plot(hist[:,2], label='kl')
plt.legend()
plt.xlabel('Epoch')
plt.ylabel('Loss')
plt.title('VAE Training Losses')
plt.show()
# Объединяем данные для обучения регрессии
```

А қосымшасының жалғасы

```
X_train = np.vstack([mu_norm, mu_abnorm]) # признаковое пространство
(число образцов x latent_dim)
y_train = np.concatenate([rul_norm, rul_abnorm])

print("Размерность матрицы признаков X_train:", X_train.shape)
print("Примеры меток RUL в y_train:", y_train[:5], "...", y_train[-5:])

# Определяем линейную модель регрессии RUL
rul_model = tf.keras.Sequential([
    tf.keras.layers.Input(shape=(LATENT_DIM,)), # <— тут исправлено
    tf.keras.layers.Dense(1, activation='linear')
])

rul_model.compile(
    optimizer=tf.keras.optimizers.Adam(learning_rate=1e-2),
    loss='mse',
    metrics=['mse']
)

# Обучение модели регрессии
history_rul = rul_model.fit(X_train, y_train, epochs=50, batch_size=16, verbose=0)

# выводим финальный результат обучения
print("Обучение RUL модели завершено. Финальное MSE:",
      history_rul.history['mse'][-1])

import matplotlib.pyplot as plt

# График потерь VAE
plt.figure(figsize=(8,5))
plt.plot(history_total, label="Total Loss")
plt.plot(history_recon_loss, label="Reconstruction Loss")
plt.plot(history_kl_loss, label="KL Divergence")
plt.title("VAE Training Loss")
plt.xlabel("Epoch")
```

А қосымшасының жалғасы

```
plt.ylabel("Loss")
plt.legend()
plt.show()
```

```
# График MSE для модели RUL
plt.figure(figsize=(6,4))
plt.plot(history_rul.history['mse'], label="Training MSE", color='orange')
plt.title("Linear Regression RUL Model MSE")
plt.xlabel("Epoch")
plt.ylabel("Mean Squared Error")
plt.legend()
plt.show()
```

```
from moviepy.editor import VideoFileClip
```

```
# Задайте путь к видеофайлу, который хотите проанализировать
video_path = "/content/drive/MyDrive/DataSet/1/example_video.mp4" # !!!
измените на реальный путь
```

```
# Извлечение аудио из видео
clip = VideoFileClip(video_path)
audio = clip.audio
audio.write_audiofile("temp_audio.wav", fps=target_sr, verbose=False,
logger=None)
clip.close()
```

```
# Загрузка полученного аудио и преобразование в мел-спектрограмму (точно
как в обучении)
```

```
new_y, new_sr = librosa.load("temp_audio.wav", sr=target_sr)
```

```
# Приведение к 10 сек
```

```
desired_length = int(new_sr * target_duration)
```

```
if len(new_y) < desired_length:
```

```
    new_y = np.pad(new_y, (0, desired_length - len(new_y)))
```

```
else:
```

```
    new_y = new_y[:desired_length]
```

```
# Мел-спектрограмма
```

```
new_mel = librosa.feature.melspectrogram(new_y, sr=new_sr, n_mels=n_mels)
```

```
new_mel_db = librosa.power_to_db(new_mel, ref=np.max, top_db=max_db)
```

```
new_mel_norm = (new_mel_db + max_db) / max_db
```

```
# Подгоняем размер 128x128
```

```
if new_mel_norm.shape[1] < n_mels:
```

А қосымшасының жалғасы

```
new_mel_norm = np.pad(new_mel_norm, ((0,0),(0, n_mels -
new_mel_norm.shape[1])), constant_values=0.0)
new_mel_norm = new_mel_norm[:, :n_mels]
# Добавляем размерность батча и канала для подачи в модель
new_mel_norm = new_mel_norm[np.newaxis, ..., np.newaxis].astype(np.float32)

# Прогон через VAE
z_mean_pred, z_log_var_pred, z_pred = encoder.predict(new_mel_norm)
recon_pred = decoder.predict(z_pred)
# Вычисление ошибки реконструкции для этого образца
recon_error = np.mean((new_mel_norm - recon_pred) ** 2)

# Прогноз RUL
rul_pred = rul_model.predict(z_mean_pred)

print(f'Предсказанный RUL для звука из видео: {rul_pred[0][0]:.2f}')
print(f'Ошибка реконструкции VAE для звука из видео: {recon_error:.6f}')
```


Қосымша Б

```
!nvidia-smi
!pip install ultralytics lcd.setCursor(0, 1);

from ultralytics import YOLO
import os
from IPython.display import display, Image
from IPython import display
display.clear_output()
!yolo checks

!pip install roboflow

from roboflow import Roboflow
rf = Roboflow(api_key="***** ")
project = rf.workspace("meirzhan-koibagarov-*****").project("*****")
version = project.version(5)
dataset = version.download("yolov11")

!yolo task=detect mode=train model=/content/yolo11l.pt
data={dataset.location}/data.yaml epochs=70 imgsz = 640

Image(filename=f'/content/runs/detect/train/results.png', width=600)

!yolo task=detect model=val model=/content/runs/detect/train/weights/best.pt
data={dataset.location}/data.yaml

!yolo task=detect mode=predict model=/content/runs/detect/train2/weights/best.pt
conf=0.5 source={dataset.location}/test/images save_txt = true save_conf

import glob
from IPython.display import Image, display

for image_path in glob.glob(f'/content/runs/detect/predict/*.jpg'):
    display(Image(filename=image_path, height=600))
    print("\n")
```

Б қосымшасының жалғасы

```
!pip install --upgrade ultralytics
```

```
!pip install --no-cache-dir onnx onnxruntime onnx2tf protobuf tflite_support onnx-slim onnx-graphsurgeon
```

```
!python -c "import onnx; print(onnx.__version__)"
```

```
pip install onnx --upgrade
```

```
!yolo export model=/content/runs/detect/train2/weights/best.pt format=tflite
```

«Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті» коммерциялық емес акционерлік қоғамы

7M07107 – «Робототехника және мехатроника» мамандығының магистранты
Қойбағаров Мейіржан Қойбағарұлының

Магистрлік диссертациясы

Тақырыбы: «Машиналық оқыту негізінде өнеркәсіптегі техникалық қызмет көрсетуді болжау жүйесін жобалау»

Әзірленген:

а) графикалық бөлімі _____ парак

б) түсіндірме жазбасы _____ бетте

ЖҰМЫСҚА ЕСКЕРТУ ЖАСАУ

Қойбағаров Мейіржанның дипломдық жұмысы «Машиналық оқыту негізінде өнеркәсіптегі техникалық қызмет көрсетуді болжау жүйесін жобалау» тақырыбына арналған.

Жұмыстың мақсаты – сенсорлық мәліметтер мен техникалық көру жүйесі негізінде өнеркәсіптік жабдықтың істен шығуын алдын ала болжауға мүмкіндік беретін интеллектуалды жүйе әзірлеу.

Зерттеу барысында келесі міндеттер шешілген: вариациялық автоэнкодер (VAE) арқылы ақауларды анықтау әдісі ұсынылды. PLC арқылы OPC UA протоколымен деректерді алу жүзеге асырылды. YOLOv11 нейрондық желісі арқылы компьютерлік көру модулі жасалып, Roboflow және Google Colab платформаларында дайындалған бейнелер негізінде оқытылды.

Бірінші бөлімде PdM стратегиясының теориялық негіздері мен машиналық оқыту әдістері сипатталған.

Екінші бөлімде интеллектуалды жүйенің архитектурасы мен бағдарламалық бөлігі баяндалған.

Үшінші бөлімде жүйенің нақты өнеркәсіптік жағдайда сынақтан өткізілуі және алынған нәтижелердің талдауы ұсынылған.

Дипломдық жоба мәтіндік және графикалық материалдарды ресімдеудің талаптарына толық сәйкес келеді.

ЖҰМЫС БАҒАСЫ

Магистрант Қойбағаров Мейіржанның дипломдық жобасы жоғары деңгейде орындалған деп есептеймін. Жұмыс құрылымы жүйелі, мазмұны өзекті және тәжірибелік маңызы зор. Жоба "өте жақсы" деген бағаға лайық және автор бакалавр академиялық дәрежесіне толық сәйкес келеді деп санаймын.

Магистрлік диссертацияны 95 балға бағалап, магистр академиялық дәрежесіне лайық деп есептеймін.

Сын пікір беруші

Азаматтық авиация академиясының
техника ғылымдарының кандидаты,
қауымдастырылған профессор

« _____ » _____ 2025 ж



Сейдидаева А. К.

ҒЫЛЫМИ ЖЕТЕКШІНІҢ ПІКІРІ

бойынша магистрлік диссертация

Қойбағаров Мейіржан Қойбағарұлы

7M07107 – Робототехника және Мехатроника

Тақырып: «Машиналық оқыту негізінде өнеркәсіптегі техникалық қызмет көрсетуді
болжау жүйесін жобалау»

Қойбағаров Мейіржанның дипломдық жұмысы «Машиналық оқыту негізінде өнеркәсіптегі техникалық қызмет көрсетуді болжау жүйесін жобалау» тақырыбына арналған. Зерттеудің басты мақсаты – сенсорлардан және техникалық көру жүйелерінен алынған мәліметтер негізінде жабдықтың істен шығуын алдын ала болжай алатын интеллектуалды жүйені құру.

Жұмыс аясында келесі маңызды міндеттер шешімін тапты: вариациялық автоэнкодерлер (VAE) көмегімен ақауларды анықтау тәсілі ұсынылып, Siemens PLC құрылғылары арқылы OPC UA протоколы негізінде деректерді жинау жүзеге асырылды. Сонымен қатар, компьютерлік көру модулі YOLOv11 нейрондық желісі арқылы жасалып, Roboflow және Google Colab платформаларында бейнелерді оқыту арқылы жетілдірілді.

Бірінші тарауда Predictive Maintenance (PdM) стратегиясының теориялық негіздері мен машиналық оқыту әдістеріне шолу жасалған. Екінші тарауда әзірленген жүйенің архитектуралық құрылымы мен бағдарламалық қамтылуы баяндалған. Ал үшінші тарауда – жүйенің нақты өндірістік жағдайда сыналып, нәтижелері талданған.

Дипломдық жұмыс мазмұны жағынан да, көрнекі материалдармен рәсімделуі тұрғысынан да қойылған талаптарға толық сәйкес келеді. Жұмыс ғылыми негізделген, құрылымы қисынды және нәтижелері тәжірибелік қолданысқа бейімделген.

Осыған орай, Қойбағаров Мейіржанның дипломдық жұмысын жоғары деңгейде орындалған деп есептеймін. Жобаны «өте жақсы» деген бағаға және авторды магистр академиялық дәрежесіне лайық деп санаймын.

Ғылыми жетекші

Физика-математика ғылымдарының кандидаты, қауымдастырылған профессор



Алдияров Н.У.

2025 ж.

«GALANZ bottlers» акционерлік қоғамы
Қазақстан Республикасы, 050000, Әуезов ауданы
Алматы қаласы, Жазылбек көшесі, 20 үй, т.е.6.216
Тел.: +7 (727) 346 91 18, 346 93 67
E-mail: info@galanz.kz, www.galanz.kz
БСН: 060740001737



Акционерное общество «GALANZ bottlers»
Республика Казахстан, 050000, Ауезовский район
город Алматы, улица Жазылбека, дом 20, н.п.216
Тел.: +7 (727) 346 91 18, 346 93 67
E-mail: info@galanz.kz, www.galanz.kz
БИН: 060740001737

Нақты мекенжай: Қазақстан Республикасы, 050054, Алматы қ., Сүйінбай даң., 239 «Б»

Фактический адрес: Республика Казахстан, 050054, г. Алматы, пр.Суюнбая, 239 «Б»

Шығ./Исх. № _____
от « _____ » _____ 2025ж./г

Отзыв на диссертационный проект

отечественного консультанта диссертационной работы на соискание степени магистра технических наук по специальности «7М07107 – Робототехника и Мехатроника» Койбагаров Мейиржан Койбагарулы
тему «Интеллектуальная система предиктивного обслуживания на основе машинного обучения».

Общая оценка:

Работа представляет собой высокотехнологичный и актуальный проект, полностью соответствующий современным тенденциям цифровизации промышленности в рамках концепции Индустрии 4.0. Магистрант демонстрирует глубокие знания в областях промышленной автоматизации, анализа данных, компьютерного зрения и архитектур искусственного интеллекта.

От лица технического директора АО «GALANZ Bottlers» особенно хотелось отметить:

- широкий подход (интеграция SCADA, OPC UA, машинного обучения и IoT);
- высокий уровень практической реализации, включая архитектуру системы, обработку сенсорных данных, разработку моделей автоэнкодеров и компьютерного зрения;
- качественный анализ данных и использование VAE (вариационного автоэнкодера) с байесовским обновлением;
- внятную структуру дорожной карты внедрения предиктивного обслуживания в промышленную среду;
- акцент на стратегическую значимость проекта для Казахстана, что подчёркивает зрелость и социальную ответственность автора.

Перспективы проекта

1. Промышленное внедрение и масштабирование

Проект имеет отличные предпосылки для реализации на предприятиях, особенно с устаревшей инфраструктурой (что актуально для СНГ и стран Центральной Азии). Возможность адаптации к оборудованию советского производства делает систему практически уникальной в своём роде.

2. Развитие в рамках Индустрии 5.0

Система может быть расширена за счёт внедрения цифровых двойников, облачных аналитических платформ и пограничных вычислений (edge computing). Это отвечает вызовам перехода от Индустрии 4.0 к 5.0 — ориентированной на устойчивость, киберфизические системы и человекоцентричность.

3. Коммерциализация

Проект может стать основой для стартапа или существующей компании, специализирующейся на разработке интеллектуальных решений под ключ. Особый интерес могут проявить отрасли: энергетика, пищевая промышленность, металлургия, машиностроение.

4. Научно-исследовательский потенциал

Используемые подходы (например, непрерывное обучение и компьютерное зрение в реальном времени) создают хорошую основу для публикаций в международных журналах и участия в грантовых программах в сфере прикладного ИИ.

5. Образовательный вклад

Проект служит отличным примером для учебных заведений в Казахстане и СНГ, демонстрируя, как можно интегрировать машинное обучение в инженерные дисциплины на реальных данных и с учётом специфики национального производства.

Данный дипломный проект отличается продуманной архитектурой, практической значимостью и глубокой научной проработкой. Он может стать не только основой для внедрения предиктивного обслуживания на казахстанских предприятиях, но и вкладом в развитие индустриального ИИ в глобальном масштабе. Студент продемонстрировал высокий уровень подготовки и способность решать реальные производственные задачи, что позволяет рекомендовать работу к защите с высокой оценкой.

Консультант

Ким Н. А.
технического директор
АО «GALANZ bottlers»

подпись

Председатель Правления

Заурбеков И.М



Отчет подобия

Метаданные

Название организации

Satbayev University

Название

Машиналық оқыту негізінде өнеркәсіптегі техникалық қызмет көрсетуді болжау жүйесін жобалау

Автор

Научный руководитель / Эксперт

Қойбағаров Мейіржан ҚойбағарұлыНахипбиек Алдияров

Подразделение

ИАиИТ

Объем найденных подбий

КП-ия определяют, какой процент текста по отношению к общему объему текста был найден в различных источниках. Обратите внимание! Высокие значения коэффициентов не означают плагиат. Отчет должен быть проанализирован экспертом.



КП1

25

Длина фразы для коэффициента подбий 2



КП2

14956

Количество слов



КЦ

127140

Количество символов

Тревога

В этом разделе вы найдете информацию, касающуюся текстовых искажений. Эти искажения в тексте могут говорить о ВОЗМОЖНЫХ манипуляциях в тексте. Искажения в тексте могут носить преднамеренный характер, но чаще, характер технических ошибок при конвертации документа и его сохранении, поэтому мы рекомендуем вам подходить к анализу этого модуля со всей долей ответственности. В случае возникновения вопросов, просим обращаться в нашу службу поддержки.

Замена букв		4
Интервалы		0
Микропробелы		1
Белые знаки		0
Парафразы (SmartMarks)		4

Подобия по списку источников

Ниже представлен список источников. В этом списке представлены источники из различных баз данных. Цвет текста означает в каком источнике он был найден. Эти источники и значения Коэффициента Подобия не отражают прямого плагиата. Необходимо открыть каждый источник и проанализировать содержание и правильность оформления источника.

10 самых длинных фраз

Цвет текста

ПОРЯДКОВЫЙ НОМЕР	НАЗВАНИЕ И АДРЕС ИСТОЧНИКА URL (НАЗВАНИЕ БАЗЫ)	КОЛИЧЕСТВО ИДЕНТИЧНЫХ СЛОВ (ФРАГМЕНТОВ)
1	Күн шағын электр станциясын жобалау 5/25/2023 Satbayev University (ИАиИТ)	30 0.20 %
2	https://dspace.uqwenca.edu.ec/handle/123456789/32850	12 0.08 %
3	https://pastebin.com/aCW34ps0	10 0.07 %

4	https://pastebin.com/aCW34ps0	7 0.05 %
5	https://pastebin.com/aCW34ps0	6 0.04 %
6	https://digilib.uin-suka.ac.id/id/eprint/17618/1/BAB%20I%2C%20%20V%2C%20DAFTAR%20PUSTAKA.pdf	6 0.04 %
7	https://pastebin.com/aCW34ps0	6 0.04 %
8	https://digilib.uin-suka.ac.id/id/eprint/17618/1/BAB%20I%2C%20%20V%2C%20DAFTAR%20PUSTAKA.pdf	6 0.04 %
9	https://pastebin.com/aCW34ps0	5 0.03 %
10	https://pastebin.com/aCW34ps0	5 0.03 %

из базы данных RefBooks (0.00 %)

ПОРЯДКОВЫЙ НОМЕР	НАЗВАНИЕ	КОЛИЧЕСТВО ИДЕНТИЧНЫХ СЛОВ (ФРАГМЕНТОВ)
------------------	----------	---

из домашней базы данных (0.20 %)

ПОРЯДКОВЫЙ НОМЕР	НАЗВАНИЕ	КОЛИЧЕСТВО ИДЕНТИЧНЫХ СЛОВ (ФРАГМЕНТОВ)
1	Күн шағын электр станциясын жобалау 5/25/2023 Satbayev University (ИАИТ)	30 (1) 0.20 %

из программы обмена базами данных (0.00 %)

ПОРЯДКОВЫЙ НОМЕР	НАЗВАНИЕ	КОЛИЧЕСТВО ИДЕНТИЧНЫХ СЛОВ (ФРАГМЕНТОВ)
------------------	----------	---

из интернета (0.45 %)

ПОРЯДКОВЫЙ НОМЕР	ИСТОЧНИК URL	КОЛИЧЕСТВО ИДЕНТИЧНЫХ СЛОВ (ФРАГМЕНТОВ)
1	https://pastebin.com/aCW34ps0	44 (7) 0.29 %
2	https://dspace.ucuenca.edu.ec/handle/123456789/32850	12 (1) 0.08 %
3	https://digilib.uin-suka.ac.id/id/eprint/17618/1/BAB%20I%2C%20%20V%2C%20DAFTAR%20PUSTAKA.pdf	12 (2) 0.08 %

Список принятых фрагментов (нет принятых фрагментов)

ПОРЯДКОВЫЙ НОМЕР	СОДЕРЖАНИЕ	КОЛИЧЕСТВО ИДЕНТИЧНЫХ СЛОВ (ФРАГМЕНТОВ)
------------------	------------	---



Отчет об обнаружении ИИ-контента

Результат поиска отражает вероятность того, был ли текст создан инструментом ИИ с использованием GPT-2, GPT-J, GPT-NEO, GPT-3, GPT-4 или Bard.

Метаданные

Название организации
Satbayev University

Название

Машиналық оқыту негізінде өнеркәсіптегі техникалық қызмет көрсетуді болжау жүйесін жобалау

Автор Научный руководитель / Эксперт
Қойбағаров Мейіржан ҚойбағарұлыНахипбиек Алдияров


Подразделение
ИАИИТ

Коэффициент Вероятности ИИ

4%

Коэффициент Вероятности ИИ — это показатель, отражающий среднюю вероятность использования ИИ для всего документа. Результат 90% следует рассматривать как 90%-ную уверенность того, что контент был создан с использованием инструментов ИИ.

Система группирует текстовые фрагменты в 5 диапазонов. Каждый из диапазонов имеет свой цветовой код, отражающий уровень вероятности присутствия ИИ в тексте. Зеленый цвет означает низкий уровень вероятности того, что текст был сгенерирован ИИ, а красный, наоборот, высокий уровень.



Индикатор Контента ИИ


1%

Этот коэффициент указывает, какая часть текста могла быть создана с использованием искусственного интеллекта в пределах порогового значения, заранее заданного пользователем. 97% означает, что 97% текста имеет коэффициент вероятности ИИ выше 78% (0,78 - заранее заданный коэффициент вероятности ИИ).

Подробности

Ниже представлен список фрагментов, ранжированных по вероятности ИИ, от фрагментов с самой высокой вероятностью до фрагментов с самой низкой вероятностью ИИ.

ПОРЯДКОВЫЙ НОМЕР	ФРАГМЕНТ	ВЕРОЯТНОСТЬ КОНТЕНТА ИИ	ЧИСЛО СЛОВ
1	In the conditions of rapid technological developme...	99%	79
2	ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ [1] Yan Gao, Ch...	92%	116
3	[39] OPC UA + MQTT – A Popular Combination for Io...	68%	41
4	Enhancing operational efficiency in Industry 4.0: ...	45%	51
5	Systematic review of predictive maintenance and di...	34%	66
6	Модель параметрлердің бастапқы априорлық таралуын ...	30%	50
7	АҢДАТПА Бұл жұмыс қазіргі заманғы өнеркәсіп жағда...	6%	281
8	[13] Г.Н. Сансызбаева, А. Кузенбаева. Проблемы и ...	5%	404
9	The proposed approach allows early detection of an...	3%	10052
10	Ресми түрде өнеркәсіптік жүйеде үздіксіз оқыту пр...	2%	3284



СПРАВКА

Дана М.К. Койбагарову, Ж.Н. Исабекову Л.А. Курмангалиевой, В.К. Байтургановой, П.М. Рахметовой в том, что статья на тему «РАЗРАБОТКА СИСТЕМЫ ПРЕДИКТИВНОГО ОБСЛУЖИВАНИЯ НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ» действительно принята в научный журнал «Вестник Университета Шакарима. Серия технические науки» № 2(18) 2025 г. Выход номера запланирован на июнь 2025 года.

Справка дана по месту требования.

Координатор Центра
организации научных
исследований



Е.П. Евлампиева



SATBAYEV
UNIVERSITY



Polych is the best!

СЕРТИФИКАТ

Certificate

«SATBAYEV INTERNATIONAL CONFERENCE - 2025. ARTIFICIAL INTELLIGENCE IN ENGINEERING
AND PRODUCTION SYSTEMS: SOLUTIONS FOR OPTIMIZATION AND AUTOMATION OF PROCESSES»

жоғарғы деңгейлі
on the topic

«Машиналық оқытуды қолданатын болжамады өнеркәсіптік қызмет»

«Predictive industrial service using machine learning»

(М. К. Койбағаров, Н. У. Алдияров, П. М. Рахметова)

атты мазмұнды баяндама ұсынғаны үшін беріледі
for providing a high-level semantic report

2025



M. Бегентаев

СӘТБАЕВ
УНИВЕРСИТЕТІ



SATBAYEV
UNIVERSITY



PolyTech is the best!

ДИПЛОМ

«Satbayev International Conference 2025.

Инженерлік және өндірістік жүйелердегі жасанды интеллект:
процестерді оңтайландыру мен автоматтандыру шешімдері»
халықаралық конференциясына қатысып,

Қойбағаров Мейіржан

II орын

алғаны үшін марапатталады



М. Бегентаев