



DOI 10.51885/1561-4212\_2025\_4\_162  
FTAXP 28.23.25

## ИОТ-СЕНСОРЛАРЫН ПАЙДАЛАНЫП СО КОНЦЕНТРАЦИЯСЫН БАҚЫЛАУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІНІҢ САЛЫСТЫРМАЛЫ ТАЛДАУЫ

## СРАВНИТЕЛЬНЫЙ АНАЛИЗ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ МОНИТОРИНГА КОНЦЕНТРАЦИИ СО С ИСПОЛЬЗОВАНИЕМ ИОТ-СЕНСОРОВ

## COMPARATIVE ANALYSIS OF MACHINE LEARNING ALGORITHMS FOR CO CONCENTRATION MONITORING USING IOT SENSORS

А.Б. Кусаинов <sup>1\*</sup>, Г. Жомартқызы <sup>1</sup>, Rajermani Thinakaran <sup>2</sup>

<sup>1</sup>Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

<sup>2</sup>INTI International University, Лабу қ., Малайзия

\*Жауапты автор: Кусаинов Ануар Бейбутович, e-mail: ak@kab.kz

### Түйінді сөздер:

көміртек оксиді, СО, IoT-сенсорлар, машиналық оқыту, LSTM, газ ортасын бақылау, жерасты кеңістіктері, предиктивті талдау, регрессиялық алгоритмдер, классификациялық алгоритмдер

### ТҮЙІНДЕМЕ

Мақалада IoT-сенсорлары (SENSOR – Mine 4GN моделі) арқылы жерасты өндірістік кеңістіктерде көміртек оксиді (CO) концентрациясын бақылау үшін машиналық оқыту (ML) алгоритмдерінің салыстырмалы талдауы ұсынылған. Сзықтық регрессия әдістері, ансамбльдік модельдер, мысалы, Random Forest және XGBoost, Тірек векторлар әдісі (SVM), сондай-ақ рекурренттік нейрондық желі LSTM әдістері қарастырылды. LSTM болжам жасауда ең жоғары дәлдікке қол жеткізетіндігі және СО-ның аномальды шығарындыларын белгілеуде кідірістерді азайтатыны көрсетілген. Ұсынылған әдістеме бастапқы деректерді сүзу, ескерту сигналдарын тексеру ережелері және ML арқылы болжам жасауды біріктіреді, бұл мониторинг жүйесінің сенімділігін арттырады және жалған сигналдарды азайтады. Зерттеу нәтижелері IoT-сенсорларды интеллектуалды өңдеумен біріктіру арқылы шахталар мен жерасты құрылыстарында қауіпсіздікті қамтамасыз етудің тиімділігін растайды.

### Ключевые слова:

угарный газ, СО, IoT-сенсоры, машинное обучение, LSTM, мониторинг газовой среды, подземные помещения, предиктивная аналитика, алгоритмы регрессии, алгоритмы классификации

### АННОТАЦИЯ

В статье представлен сравнительный анализ алгоритмов машинного обучения (ML) для мониторинга концентрации угарного газа (CO) с использованием IoT-сенсоров модели SENSOR – Mine 4GN в замкнутых промышленных пространствах. Рассмотрены методы линейной регрессии, ансамблевых моделей, таких как Random Forest и XGBoost, метод опорных векторов (SVM), а также рекуррентной нейронной сети LSTM. Показано, что LSTM обеспечивает наибольшую точность предсказания и минимизирует задержки при фиксации аномальных выбросов CO. Предложенная методика сочетает первичную фильтрацию шумов, правила подтверждения тревог и прогнозирование с помощью ML, что повышает надёжность системы мониторинга и снижает количество ложных сигна-



лов. Результаты исследования подтверждают эффективность интеграции IoT-сенсоров и интеллектуальной обработки данных для обеспечения безопасности в шахтах и подземных сооружениях.

#### Keywords:

carbon monoxide, CO, IoT sensors, machine learning, LSTM, gas environment monitoring, underground spaces, predictive analytics, regression algorithms, classification algorithms

#### ABSTRACT

This paper presents a comparative analysis of machine learning (ML) algorithms for monitoring carbon monoxide (CO) concentration using IoT sensors (SENSOR – Mine 4GN) in confined industrial spaces. The study considers linear regression, ensemble models such as Random Forest and XGBoost, support vector machines (SVM) and the recurrent neural network LSTM. It is shown that LSTM provides the highest prediction accuracy and minimizes delays in detecting abnormal CO spikes. The proposed methodology combines initial noise filtering, alarm confirmation rules, and ML-based forecasting, which enhances the reliability of the monitoring system and reduces false alarms. The results confirm the effectiveness of integrating IoT sensors with intelligent data processing for safety management in mines and underground facilities.

#### КІРІСПЕ

Қазіргі заманда өндірістік қауіпсіздік мемлекеттер мен жоғары қауіпті жағдайларда жұмыс істейтін кәсіпорындар үшін негізгі басым бағыттардың бірі болып табылады (International Labour Organization, 2018). Әсіресе, шахталар мен жерасты қазбалары сияқты тұйық кеңістіктерде бұл мәселе ерекше маңызға ие, себебі ауа құрамының қалыпты нормасынан ауытқуы апатты салдарға әкелуі мүмкін. Мұнда іштен жану қозғалтқыштары бар техника үздіксіз жұмыс істеп, жану өнімдері ретінде улы газдар - көміртек тотығы (CO), азот диоксиді (NO<sub>2</sub>), күкірт диоксиді (SO<sub>2</sub>) және жарылыс қаупі бар метан қоспалары бөлінеді (Li J. и др., 2020). Жерасты кеңістігінің тұйықтығы табиғи желдетуді толық көлемде жүргізуге мүмкіндік бермейді, ал желдету жүйесіндегі қысқа мерзімді ақаулардың өзі зиянды газдардың қауіпті деңгейде жиналуына себеп болуы ықтимал.

Шахталардағы ең өзекті мәселелердің бірі – жоғары уыттылығымен ерекшеленетін көміртек тотығының әсері. Ол қандағы гемоглобинмен оттекке қарағанда ондаған есе белсендірек байланысып, төмен концентрацияның өзінде тіндік гипоксия туғызады (Zhang Y. и др., 2019). Халықаралық еңбек ұйымының деректері бойынша, жерасты кәсіпорындарындағы улану оқиғаларының 40%-дан астамы дәл осы CO әсерінен орын алады. Мұндай жағдайлар көбіне кенеттен болып, дер кезінде эвакуация жасауға мүмкіндік бермейді (ILO, 2018).

Ауыр тау-кен техникасын пайдалану жағдайды одан әрі күрделендіреді. Қозғалтқыштардың жетілдірілуі мен экологиялық стандарттарға көшуге қарамастан, бұл техника азот оксидтері мен қатты бөлшектердің негізгі көзі болып қала береді (Qin Y. и др., 2021). Мұндай заттар еңбек жағдайының санитарлық деңгейін төмендетіп қана қоймай, сонымен қатар желдету жүйелеріне қосымша жүктеме түсіреді. Бұл жүйелер бір мезетте таза ауамен қамтамасыз ету, метан мен улы газдарды шығару және шахтадағы микроклиматты тұрақтандыру міндеттерін атқаруы тиіс (Li X. и др., 2022).

Қазіргі зерттеулер көрсетіп отырғандай, ауа сынамаларын мерзімді түрде алу мен стационарлық датчиктерге сүйенетін дәстүрлі қауіпсіздік әдістері енді жеткіліксіз. Біріншіден, шахталардағы жұмыс динамикасы үздіксіз қозғалыстағы техника мен адамдардың орналасуына байланысты, газдардың концентрациясы тез және локалды түрде өзгеруі мүмкін (Kumar S., Singh R., 2020). Екіншіден, интеллектуалды алгоритмдері жоқ мониторинг жүйелері деректерді өңдеуде кешігіп, апаттың алдын алу тиімділігін төмендетеді (Chen L. и др., 2023). Сондықтан газ талдағыштардан алынған мәліметтерді нақты уақытта талдап, қауіпті жағдайларды болжауға қабілетті интеллектуалды



предиктивтік аналитика жүйелерін дамыту – жерасты қауіпсіздігін қамтамасыз етудің стратегиялық бағыты болып табылады (Wang J. и др., 2022).

Қазақстанда да өндірістегі апаттық жағдайлардың алдын алу бағытында бірқатар зерттеулер жүргізілуде. Мысалы, Л.Н. Гумилев атындағы Еуразия ұлттық университетінде газ сенсорларынан алынған деректерді статистикалық өңдеу әдістері зерттеліп, ұшпа органикалық қосылыстарды жіктеудің дәлдігін арттыруға бағытталған. Ақпараттық және есептеуіш технологиялар институты интеллектуалды басқару және болжау жүйелерін дамыту саласында зерттеулер жүргізуде, бұл өндірістік процестердің қауіпсіздігі мен тиімділігін арттыруға септігін тигізеді.

Қазақстандық және шетелдік ғылыми басылымдарда Сатыбалдына Д., Исайнова А., Глазырина Н., Шагабудинов А., Құдайбергенов С.Е. (Satybaldina D. и др., 2024); Shah Mansouri T., Wang H., Mariotti D., Maguire P., Skarysz A., Salman D., Eddleston M., Mojto M., Lubušký K., Fikar M., Paulen R. (Haleem A. и др., 2025; Хасенова З.Т., Рақышева М.А., Глазырина Н.С., Исайнова А.Н., Мукатов А.Т. (Khasenova Z.T. и др., 2024); Тукушова А.Е. \*, Рахметуллина С.Ж., Пененко А.В. (Tukushova A.E. и др., 2024) сынды ғалымдардың еңбектері жарияланған. Бұл еңбектер газдық орта параметрлерін өлшеу және инциденттердің алдын алу мақсатында өлшеу құралдарын қолдану саласындағы өзекті зерттеулерді қамтиды.

Осылайша, шахталардағы газдық ортаны бақылау мәселесі тек техникалық емес, кешенді сипатқа ие. Ол инженерия, еңбек қауіпсіздігі, медицина және ақпараттық технологиялар салаларын біріктіреді. Заманауи цифрлық шешімдерді пайдалану арқылы интеграцияланған қауіпсіздік жүйелерін құруға болады. Мұндай жүйелер улы газдардың шекті концентрациядан асуын анықтап қана қоймай, апатты жағдайлардың дамуын болжауға мүмкіндік береді. Бұл өз кезегінде жұмысшылардың өмірі мен денсаулығын қорғаудың жаңа деңгейін қалыптастырады.

### **ЗЕРТТЕУ МАТЕРИАЛДАРЫ МЕН ӨДІСТЕРІ**

Деректерді жинау үшін негізгі аппараттық платформа ретінде автор және «KAB SYSTEMS» жауапкершілігі шектеулі серіктестігінің директоры әзірлеген SENSOR - Mine 4GN газ талдағышы пайдаланылды. Бұл құрылғы шахталар мен өнеркәсіптік нысандар жағдайында жұмыс істеуге арналған. Зерттеу барысында оның екі түрлендірмесі - Mine 4G1 және Mine 4G2 қолданылды.

Негізгі зерттеу нысаны болып табылатын көміртек тотығы (CO) үшін өлшеу диапазоны тиісінше 0-200 parts per million (ppm немесе мг/м<sup>3</sup>) және 0-1000 ppm аралығында болды. Өлшеу дәлдігі толық шкаланың (F.S.) ±10%-ынан аспады, ал жауап беру уақыты 10 секундтан кем болды. Мұндай сипаттамалар уақыттық қатарларды дәл қалыптастыруға мүмкіндік берді. SENSOR Software бағдарламалық кешені арқылы мониторинг жүйесіне деректерді беру жиілігі 1 Гц (бір секундтық интервал) деңгейінде орнатылды. Бұл параметрлер машиналық оқыту алгоритмдерін үйрету үшін алынатын мәліметтер жиынтығының көлемі мен сапасын айқындауда шешуші рөл атқарды.

Деректер жинау нақты пайдалану жағдайларына жақын ортада жүргізілді: температура +10 °С-тан +40 °С-қа дейін, ылғалдылық 90 %-ға дейін, және шаңның болуы – шахталардағы жұмыс істеп тұрған техниканың қалыпты жағдайы ретінде. Осы кезеңде-ақ бастапқы («шикі») деректерді тікелей талдауға қолдану мүмкін еместігі анықталды. Сенсор көрсеткіштерінде жиі шуылдар, қысқа мерзімді секірулер мен ауытқулар байқалды, бұлар механикалық әсерлер мен ауа ағыстарының тұрақсыздығынан туындады.

Сондықтан алғашқы кезең ретінде деректерді алдын ала өңдеу жүргізілді. Бұл үдеріс бірнеше қадамнан тұрды: шуылдарды сүзгілеу – жылжымалы орташа және Калман сүзгілерін қолдану арқылы, мәндерді нормализациялау – өлшеу диапазондарын



салыстырмалы түрге келтіру үшін, деректерді белгілеу (разметка) – шекті рұқсат етілген концентрациялардан (ШПК) асу деңгейіне қарай.

Осы амалдардың нәтижесінде деректерге «қауіпсіз/қауіпті» бинарлық белгілер қойылып, оларды классификациялау міндеттерінде қолдануға мүмкіндік туды (GOST 12.1.005-88, 1988). Алдын ала өңдеу кезеңдерінің негізгі қадамдары 1-кестеде келтірілген.

### 1-кесте. Мәліметтерді өңдеу кезеңдері

Өңдеу кезеңі	Әдіс	Мақсаты
Шуды сүзу	Жылжымалы орташа, Калман сүзгісі	Тербелістерді тегістеу, артефактілерді жою
Нормализация	Диапазондарды масштаптау	Мәліметтерді бірыңғай шкалаға келтіру
Белгілеу	Бинарлық белгі «қауіпті/қауіпсіз»	Оқыту үлгілерін қалыптастыру

*Ескерту – автор (Құсаинов, 2025) эксперименттік деректері негізінде құрастырған*

Деректерді алдын ала өңдеу аяқталғаннан кейін келесі кезеңде машиналық оқыту алгоритмдерін салыстыру жүргізілді. Модельдерді таңдау әртүрлі әдістердің уақыттық қатарларды өңдеу тәсілдеріне негізделді.

Сызықтық регрессия уақыт пен CO концентрациясы арасындағы жалпы тәуелділікті бағалау үшін базалық әдіс ретінде пайдаланылды.

Random Forest және XGBoost алгоритмдері сызықты емес тәуелділіктермен және шуыл деңгейі жоғары деректермен тиімді жұмыс істеуімен ерекшеленді (Hochreiter S., Schmidhuber J., 1997), бұл шахта жағдайларында аса өзекті болды.

Тірек векторлар әдісі (SVM) шекті рұқсат етілген концентрациялардан (ШПК) асу жағдайларын бинарлы классификациялау үшін тиімді құрал ретінде қарастырылды (Chen T., Guestrin C., 2016).

Ал LSTM (Long Short-Term Memory) желісі CO концентрациясын уақыт бойынша болжауға қолданылды, себебі бұл рекурренттік нейрондық желі түрі ұзақ мерзімді тәуелділіктерді ескеріп, аномалды ауытқуларды алдын ала болжауға мүмкіндік береді (Welch G., Bishop G., 2006).

2-кестеде қолданылған машиналық оқыту модельдері туралы мәліметтер келтірілген.

Модельдердің жұмыс сапасын бағалау үшін бірнеше метрикалар жиынтығы қолданылды. Болжау қатесі MAE (Mean Absolute Error) және RMSE (Root Mean Squared Error) көрсеткіштері арқылы есептелді (Li X. и др., 2022), олар сәйкесінше орташа және орта квадраттық қателікті сипаттайды. Сонымен қатар, модельдің нақты тәуелділіктерді қаншалықты дәл бейнелейтінін анықтау мақсатында  $R^2$  (детерминация коэффициенті) пайдаланылды.

Қосымша түрде, берілген дабыл шектері (мысалы, CO концентрациясы 50 ppm және 100 ppm-нан жоғары болғанда) бойынша классификация дәлдігі бағаланды. Бұл көрсеткіш өндірістік қауіпсіздік тұрғысынан ең практикалық және қолданбалы критерий болып табылады.



## 2-кесте. Машиналық оқыту алгоритмдерінің модельдері

Модель	Міндеті	Қолдану ерекшеліктері
Сызықтық регрессия	Регрессия	Қарапайым интерпретация, бірақ бейсызық тәуелділіктерге әлсіз
Random Forest	Классификация/регрессия	Шуға төзімді, бейсызық байланыстармен жақсы жұмыс істейді
XGBoost	Классификация/регрессия	Жоғары дәлдік, гиперпараметрлерді баптауды қажет етеді
SVM	Бинарлық классификация	«Қауіпті/қауіпсіз» ажыратуда тиімді
LSTM	Уақыттық қатарлар	Ұзақ мерзімді тәуелділіктерді ескереді, күрт ауытқуларды болжай алады
<i>Ескерту – автор (Қусаинов, 2025) эксперименттік деректері негізінде құрастырған</i>		

Зерттеу үдерісінің барлық кезеңдері Python бағдарламалық ортасында жүзеге асырылды. Машиналық оқыту есептерін орындау үшін scikit-learn және TensorFlow/Keras кітапханалары пайдаланылды. Уақыттық қатарлармен және деректерді өңдеумен жұмыс істеу мақсатында NumPy және Pandas құралдары қолданылды, ал нәтижелерді визуализациялау үшін Matplotlib кітапханасы пайдаланылды. Мұндай құралдар жиынтығы деректерді сенсорлардан жинаудан бастап, модельдерді талдау мен салыстыру нәтижелерін графикалық түрде көрсетуге дейінгі толық өңдеу циклін іске асыруға мүмкіндік берді.

Осылайша, зерттеудің әдістемелік негізі нақты IoT-сенсорларды (SENSOR - Mine 4GN газ талдағыштары) және заманауи машиналық оқыту алгоритмдерін біріктірді. Бұл тәсіл алынған нәтижелердің дәлдігі мен сенімділігін қамтамасыз етіп, оларды шахталық өндіріс жағдайында практикалық тұрғыдан қолдануға мүмкіндік берді.

### НӘТИЖЕЛЕР ЖӘНЕ ОЛАРДЫ ТАЛҚЫЛАУ

SENSOR-Mine 4GN газталдағышын пайдалану арқылы CO концентрациясын мониторингтеу алгоритмдерінің тиімділігін тексеру мақсатында 0-200 ppm өлшеу диапазонында эксперименттік деректер жиналды. Бақылау параметрі ретінде құрылғыда орнатылған 20 ppm деңгейіндегі дабыл шегі пайдаланылды. Бұл мән санитарлық нормалар мен тұйық кеңістіктер үшін белгіленген шекті рұқсат етілген концентрацияға (ШРК) сәйкес келеді.

Сенсордың техникалық сипаттамаларына сәйкес, оның өлшеу дәлсіздігі  $\pm 10\%$  F.S. (яғни  $\pm 20$  ppm шкалада 0-200 ppm аралығында) болғандықтан, тек лездік асуларды тіркеу ғана емес, дабылды растау логикасын құрастыру да маңызды болды. Тек қана шартты түрде  $x_t \geq 20$  ppm болғанда дабыл беру жеткіліксіз екені анықталды, себебі өлшеу деректерінің шуылдылығы мен құрылғылық белгісіздіктер нәтижесінде көптеген жалған дабылдар пайда болды (Zampolli S. и др., 2004).

Жалған дабылдар санын азайту мақсатында растау ережесі енгізілді: дабыл келесі шарттардың кемінде біреуі орындалғанда ғана расталды:

- екі қатарынан алынған өлшеулер шекті мәннен жоғары болса;
- үш өлшеуден алынған жылжымалы орташа мән  $MA_3(t) \geq 20$  болған жағдайда;
- ағымдағы мән шектен 10 ppm-нан артық асқан жағдайда ( $x_t \geq 30$ ).

Жылжымалы орташа мән келесі формула бойынша есептелді (Brown R.G., Hwang P.Y.C., 2012):

$$MA_k(t) = \frac{1}{k} \sum_{i=0}^{k-1} x_{t-i} \quad (1)$$

мұнда  $k$  – орташа есептеу терезесінің өлшемі (осы жағдайда  $k = 3$ ).



3-кестеде СО көрсеткіштерінің уақыттық қатары мен дабыл логикасының мысалы келтірілген.

3-кесте. СО өлшеулері және дабыл логикасы

№	СО, ppm	Дабыл ( $\geq 20$ ppm)	Дабылды растау (МА немесе $\geq 30$ ppm)
1	12	Жоқ	Жоқ
2	14	Жоқ	Жоқ
3	13	Жоқ	Жоқ
4	15	Жоқ	Жоқ
5	16	Жоқ	Жоқ
6	14	Жоқ	Жоқ
7	160	Да	Иә (жедел апат)
8	18	Жоқ	Жоқ
9	17	Жоқ	Жоқ
10	15	Жоқ	Жоқ
11	16	Жоқ	Жоқ
12	18	Жоқ	Жоқ
13	20	Иә	Жоқ (растауды күту)
14	22	Иә	Иә (қатарынан $2 \geq 20$ )
15	25	Иә	Иә
16	28	Иә	Иә
17	32	Иә	Иә
18	36	Иә	Иә
19	40	Иә	Иә
20	45	Иә	Иә

*Ескерту – автор (Қусаинов, 2025) эксперименттік деректері негізінде құрастырған*

Кестеден көрініп тұрғандай, 20 ppm және одан жоғары мәндерде дабыл анықтаудың қарапайым логикасы артық концентрацияны 13-жазбада (20 ppm) тіркейді. Алайда өлшеу дәлсіздігін ескере отырып, бұл мән сенімді деп есептелмейді. Расталған дабыл тек 14-жазбада, яғни 22 ppm кезінде іске қосылады, бұл деректердің нақтылығын арттырып, жалған дабыл қауіпін төмендетеді. Кенет арту жағдайында (7-жазба, 160 ppm) дабыл бірден іске қосылады, себебі бұл көрсеткіш шекті мән мен аспаптың қателік диапазонынан едәуір жоғары.

Айта кету керек, SENSOR – Mine 4GN газталдағышы дабылды анықтаудың кіріктірілген логикасымен жабдықталған: ол алынған дабыл деректерін 10-15 секунд ішінде қайталап өлшеу арқылы тексереді және орташа әрекет ету уақыты  $t \leq 15$  секунд болғанда дабыл іске қосылады.

Осылайша, ұсынылған схема жүйенің сезімталдығы мен тұрақтылығы арасында теңгерімді қамтамасыз етеді:

- қауіпті шығарындыларды өткізіп алмауға мүмкіндік береді;
- 20 ppm шекті деңгейі маңында жалған дабылдардың санын азайтады;
- кеніш жағдайларына тән қысқа мерзімді шу әсерлері мен газ концентрациясының біртіндеп артуын ескереді.

Өлшеу жұмыстары сенімділікті қамтамасыз ету мақсатында бақыланатын зертханалық жағдайларда жүргізілді. Тәжірибе барысында ортаның негізгі параметрлері тұрақты деңгейде ұсталды: температура 24-26 °C аралығында, ал салыстырмалы



ылғалдылық 45-48 % RH деңгейінде болды. Бұл көрсеткіштер сенсорлардың жұмысына сыртқы факторлардың әсерін минимизациялауға мүмкіндік берді.


Экспериментке барлығы 10 датчик қатысып, бірдей жағдайларда 5 күн бойы үздіксіз өлшеулер жүргізілді. Әр датчик CO концентрациясының әртүрлі деңгейлерінде (0–200 ppm диапазонында) сынақтан өтті. Соңдықтан деректер жиыны – әртүрлі концентрацияларда алынған уақыттық қатарлардан тұратын өлшеулер сериясы.

Сынақ кезінде датчиктердің табиғи ерекшеліктеріне байланысты аздаған шу мен қысқа мерзімді секірулер байқалды. Газ талдағыштың бағдарламалық қамтамасыздандыруы бастапқы сүзгілеуді орындағанымен, қосымша өңдеу қажет болды.

Алдын ала өңдеу барысында уақыт бойынша тұрақты емес, кенеттен пайда болып, қайталанбаған аномальды мәндер деректерден алынып тасталды. Мұндай нүктелер нақты процесті көрсетпейтіндіктен, модельдеуге кедергі келтіреді. Тазарту уақыттық тұрақтылықты тексеру және шығыс мәндерді сүзу тәсілдерімен жүргізілді.

Шудың әсерін азайту үшін жылжымалы орташа және адаптивті Калман сүзгісі сияқты әдістер қолданылды. Бұл тәсілдер деректерді тегістеп, модельдерді оқытуға ыңғайлы күйге келтірді.

1-суретте SENSOR – Mine 4GN газталдағышынан алынған CO өлшемдері мен дабылдың іске қосылу логикасы көрсетілген: көк түспен нақты CO өлшемдері, сары түспен дабыл талдауы, ал қызыл түспен расталған дабыл белгіленген.



**1-сурет.** CO өлшемдері және дабылдың іске қосылу логикасы

*Ескерту – автор (Кусаинов, 2025) эксперименттік деректері негізінде құрастырған*

Машиналық оқыту модельдерін (Random Forest, XGBoost, SVM, LSTM) баптау кезінде гиперпараметрлерді оңтайландыру жүргізілді, бұл болжамның дәлдігі мен тұрақтылығын арттыруға мүмкіндік берді. Параметрлерді таңдау GridSearchCV және RandomSearch әдістерін қолдана отырып жүзеге асырылды. Оптималды мәндер кросс-валидация негізінде таңдалды, бұл модельдің дәлдігі мен әртүрлі деректер жиынтықтарында нәтижелердің тұрақтылығын қамтамасыз етті. Мұндай тәсіл болжам сапасын арттыруға және артық оқытудың әсерін азайтуға мүмкіндік берді.

Алдын ала сүзгіден өткізу және дабылдарды растау кезеңінен кейін алынған деректер машиналық оқыту алгоритмдерін оқыту мен сынау үшін пайдаланылды. Зерттеу барысында келесі әдістер қарастырылды:

– Сызықтық регрессия (LR) - кіріс деректері мен CO деңгейі арасындағы тәуелділікті орнатуға арналған базалық модель;



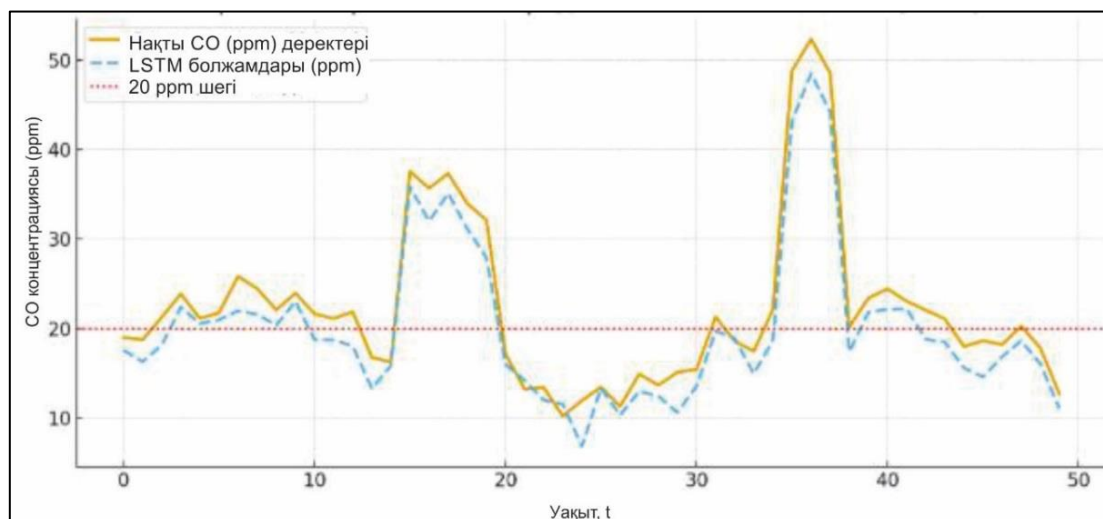
- Random Forest (RF) - шудың және оқшау мәндердің әсеріне төзімді ансамбльдік әдіс;
  - XGBoost – бейсызық тәуелділіктері бар уақыттық қатарларда тиімді жұмыс істейтін градиенттік бустинг әдісі;
  - LSTM (Long Short-Term Memory) – уақыттық тәуелділіктерді ескеретін қайталамалы нейрондық желі.
  - Модельдердің сапасын бағалау үшін келесі метрикалар қолданылды:
  - MAE (Mean Absolute Error) – орташа абсолюттік қате;
  - RMSE (Root Mean Square Error) – орташа квадраттық қате;
  - $R^2$  – детерминация коэффициенті;
  - Accuracy at Alarm Threshold – дабыл шегі (20 ppm) бойынша классификация дәлдігі.
- CO концентрациясын бақылауға арналған машиналық оқыту алгоритмдерінің салыстырмалы тиімділік нәтижелері 4-кестеде көрсетілген.

**4-кесте.** Машиналық оқыту алгоритмдерінің салыстырмалы тиімділік нәтижелері

Алгоритм	MAE (ppm)	RMSE (ppm)	$R^2$	Тревога шегіндегі дәлдік (%)
Сызықтық регрессия (LR)	6,8	9,5	0,72	84,3
Random Forest (RF)	4,2	6,1	0,89	91,7
XGBoost	3,7	5,4	0,92	93,5
LSTM	2,9	4,1	0,95	95,8

*Ескерту – автор (Қусаинов, 2025) эксперименттік деректері негізінде құрастырған*

Алынған нәтижелерге сүйене отырып, 2-суретте көрсетілген график тұрғызылды. Онда LSTM моделі арқылы болжаған CO мәндері мен датчиктің нақты деректері салыстырылған. Графиктен нейрондық желінің уақыттық қатардың динамикасын ең дәл қайталайтыны және аномалияларды анықтау кезіндегі кідірістерді барынша азайтатыны байқалады.



**2-сурет.** Нақты және болжаулы CO мәндерінің салыстырмасы (LSTM)

*Ескерту – автор (Қусаинов, 2025) эксперименттік деректері негізінде құрастырған*

2-суреттен көрініп тұрғандай, LSTM моделі уақыттық қатардың динамикасын жоғары дәлдікпен қайталайды, соның ішінде концентрацияның аномальды секірістері жағдайында да дабылдарды тіркеудегі кідірістерді азайтады.



Зерттеу нәтижелері рекурренттік нейрондық желілерді жабық кеңістіктердегі газ ортасын бақылау міндеттерінде қолданудың орынды екенін көрсетті. Дәстүрлі сигналдарды өңдеу әдістерімен салыстырғанда, LSTM уақыттық тәуелділіктерді ескеріп, газ концентрациясын дәлірек болжай алады, бұл шахталар мен тоннельдердегі СО деңгейінің динамикалық өзгерістерінде аса маңызды.

Осылайша, машиналық оқыту әдістерін, әсіресе рекурренттік нейрондық желілерді қолдану IoT-сенсорлар деректері негізінде СО концентрациясын бақылаудың дәлдігі мен сенімділігін едәуір арттырады.

Сонымен қатар, дабылды растау ережелерін және кейінгі машиналық оқыту алгоритмдерін қолдануға негізделген деректерді өңдеу әдістемесі кешенді талдау сызбасын қалыптастырды. Ол мына элементтерді біріктіреді:

- бастапқы сүзгілеу және жалған дабылдардың санын азайту;
- сигналдардың сенімділігін арттыру үшін жылжымалы орташа мәндер мен бейімделгіш шектерді қолдану;
- машиналық оқыту алгоритмдері арқылы СО концентрациясын болжау.

Салыстырмалы талдау көрсеткендей, сызықтық регрессия сияқты дәстүрлі статистикалық әдістер тек базалық дәлдік деңгейін қамтамасыз етеді. Ал ансамбльдік тәсілдер (Random Forest, XGBoost), әсіресе рекурренттік нейрондық желілер (LSTM), нәтижелерді айтарлықтай жақсартты – әрі регрессиялық метрикалар (MAE, RMSE, R<sup>2</sup>), әрі дабылды дұрыс анықтау көрсеткіштері бойынша.

Осылайша, алынған нәтижелер фильтрациялау ережелері мен машиналық оқыту әдістерін газ ортасын бақылау міндетіне біріктірудің жоғары тиімділігін дәлелдейді. Бұл жүйенің шудың әсеріне төзімділігін, қауіпті шығарындыларды анықтау қабілетін және СО концентрациясының динамикасын нақты уақыт режимінде сенімді болжауды қамтамасыз етеді.

Эксперимент нәтижелері машиналық оқыту алгоритмін таңдау СО концентрациясын бақылау дәлдігіне тікелей әсер ететінін көрсетті. Ең қарапайым модель – сызықтық регрессия базалық болжам деңгейін қамтамасыз еткенімен, бейсызық тәуелділіктер мен шуды ескеру қабілеті шектеулі. Бұл R<sup>2</sup> көрсеткішінің төмендігімен (0,72) және жоғары қателік мәнімен (MAE = 6,8 ppm) расталды.

Ансамбльдік типтегі алгоритмдер, мысалы Random Forest және XGBoost, шудың және оқшау мәндердің әсеріне төзімділікті көрсетті. Әсіресе XGBoost жоғары нәтиже берді - R<sup>2</sup> = 0,92 және дабыл дәлдігі 93,5 %, бұл уақыттық қатарларды талдауда бустингті қолдану бойынша алдыңғы зерттеулермен сәйкес келеді.

Ең үздік нәтижелерді рекурренттік нейрондық желі LSTM көрсетті. Уақыттық тәуелділіктерді ескеру қабілеті арқасында ол ең төмен қателікке (MAE = 2,9 ppm, RMSE = 4,1 ppm) және ең жоғары дабыл дәлдігіне (95,8 %) жетті. Бұл көрсеткіштер газ ортасын бақылау міндеттерінде терең оқытудың тиімділігін дәлелдейді, мұны соңғы ғылыми еңбектер де растайды.

Айта кету керек, болжау дәлдігінің артуы өнеркәсіптік қауіпсіздік міндеттерімен тікелей байланысты. СО шекті мәндерінің артуын сенімді анықтау жалған дабылдар ықтималдығын азайтып, нақты инциденттерге уақтылы әрекет етуге мүмкіндік береді.

Дегенмен алынған нәтижелерді келесі шектеулерді ескере отырып қарастыру қажет:

- талдау тек бір типті газоанализатор деректеріне (SENSOR-Mine 4GN) негізделген, бұл нәтижелердің басқа құрылғыларға таратылуын шектеуі мүмкін;
- деректер жиыны ұзақтығы және сценарийлер алуандығы бойынша шектеулі болды;
- зерттеу бақыланатын жағдайда жүргізілді, ал нақты шахта ортасы қосымша факторларды (температура, ылғалдылық, шаң жүктемесі) қамтуы мүмкін.



Қорытындылай келе, LSTM моделі IoT-сенсорлар деректері негізінде СО мониторингі үшін негізгі талдау құралы ретінде өз әлеуетін растады. Алайда жүйенің сенімділігін арттыру үшін деректер базасын кеңейту, далалық сынақтар жүргізу және интеллектуалды предиктивті аналитика модульдерімен интеграцияны дамыту қажет.

### ҚОРЫТЫНДЫ

Жүргізілген зерттеу нәтижелері IoT-сенсорларын машиналық оқыту алгоритмдерімен біріктіріп қолдану көміртек тотығының (СО) концентрациясын бақылау сенімділігін айтарлықтай арттыратынын көрсетті. Бұл тәсіл шахталар мен тоннельдер сияқты жабық өндірістік кеңістіктерде ауа сапасын нақты уақыт режимінде бақылауға мүмкіндік береді.

Зерттеу аясында кешенді тәсіл ұсынылды: бастапқы шуды сүзу, дабылды растау ережелерін енгізу және СО концентрациясын болжау үшін машиналық оқыту модельдерін қолдану.

Модельдерді салыстыру нәтижесінде сызықтық регрессия тек базалық деңгейдегі болжамды қамтамасыз ететіні және шудың әсеріне төзімсіз екені анықталды. Ал Random Forest және XGBoost сияқты ансамбльдік әдістер оқшау мәндерге төзімділікті көрсетіп, дабыл дәлдігін арттырды. Ең жоғары нәтижелерді уақыттық тәуелділіктерді ескеретін рекурренттік нейрондық желі (LSTM) көрсетті – ол газ концентрациясының күрт өзгерістерін алдын ала болжауға қабілетті болды.

Осылайша, сүзгілеу, дабылды растау және терең оқыту әдістерін біріктіретін ұсынылған тәсіл көміртек тотығының қауіпті деңгейлерін тиімді анықтайтын және жалған дабылдар санын азайтатын сенімді мониторинг жүйесін қалыптастырады.

Болашақта деректер базасын кеңейту, жүйені нақты шахталық жағдайларда сынақтан өткізу және басқа газ модульдерін интеграциялау арқылы кешенді экологиялық мониторинг жүйесін құру жоспарлануда.

**МҮДДЕЛЕР ҚАЙШЫЛЫҒЫ:** Авторлар мүдделер қақтығысының жоқ екенін мәлімдейді.

### ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

- Li, J., Wu, Y., & Jiang, D. (2020). Real-time monitoring system for hazardous gases in coal mines based on wireless sensor networks. *Journal of Sensors*, 2020, 1–10.
- Zhang, Y., Chen, H., & Liu, Q. (2019). Carbon monoxide exposure and health effects in underground mining environments. *International Journal of Environmental Research and Public Health*, 16(18), 3385.
- International Labour Organization (ILO). (2018). *Safety and health in underground coalmines*. Geneva: ILO.
- Qin, Y., Zhang, S., & Liu, Y. (2021). Intelligent early warning system for mine gas accidents based on big data analytics. *Safety Science*, 141, 105349.
- Li, X., Huang, B., & Wu, Y. (2022). Advances in mine ventilation and gas monitoring technologies. *Journal of Cleaner Production*, 362, 132384.
- Kumar, S., & Singh, R. (2020). IoT-based predictive safety systems for underground mines. *IEEE Transactions on Industrial Informatics*, 16(8), 5214–5223.
- Chen, L., Wang, P., & Zhao, H. (2023). AI-driven early warning systems for hazardous gas detection in mining operations. *Computers & Industrial Engineering*, 178, 109348.
- Wang, J., Liu, Y., & Li, H. (2022). Integrated digital systems for occupational safety in underground mines. *Safety Science*, 148, 105620.
- Satybaldina, D., Isainova, A., Glazyrina, N., & Shagabudinov, A. (2024). Statistical methods for feature extraction for multisensor gas analytics systems. *Vestnik KazATK*, 2, 131–141. <https://doi.org/10.52167/1609-1817>



- Haleem, A., Javaid, M., & Singh, R. P. (2025). Encouraging Safety 4.0 to enhance industrial culture: An extensive study of its technologies, roles, and challenges. *KeAi*, 3(2), 32.
- Khasenova, Z.T., Rakyshyeva, M.A., Glazyrina, N.S., Isainova, A.N., & Mukatov, A.T. (2024). Sensor technologies and machine learning: New opportunities for environmental monitoring. *Vestnik VKTU*, 3, 217–232. [https://doi.org/10.51885/1561-4212\\_2024\\_3\\_217](https://doi.org/10.51885/1561-4212_2024_3_217)
- Tukushova, A. E., Rakhmetullina, S. Zh., & Penenko, A. V. (2024). Development of an algorithm for predicting air pollution based on data from Ust-Kamenogorsk. *Vestnik VKTU*, 3, 208–218. [https://doi.org/10.51885/1561-4212\\_2024\\_3\\_208](https://doi.org/10.51885/1561-4212_2024_3_208)
- ГОСТ 12.1.005-88. (1988). Общие санитарно-гигиенические требования к воздуху рабочей зоны. Москва: Издательство стандартов. // GOST 12.1.005-88. (1988). Obshchie sanitarnogigienicheskie trebovaniya k vozdukhu rabochey zony [General sanitary requirements for workplace air]. Moscow: Izdatelstvo standartov. (In Russ.)
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794.
- Welch, G., & Bishop, G. (2006). An introduction to the Kalman filter. University of North Carolina.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- Zampolli, S., Elmi, I., Ahmed, F., Passini, M., Cardinali, G. C., Nicoletti, S., & Dori, L. (2004). An electronic nose based on solid state sensor arrays for low-cost indoor air quality monitoring applications. *Sensors and Actuators B: Chemical*, 101(1–2), 39–46.
- Brown, R. G., & Hwang, P. Y. C. (2012). *Introduction to random signals and applied Kalman filtering*. John Wiley & Sons.
- Zampolli, S., Elmi, I., Ahmed, F., Passini, M., Cardinali, G. C., Nicoletti, S., & Dori, L. (2004). An electronic nose based on solid state sensor arrays for low-cost indoor air quality monitoring applications. *Sensors and Actuators B: Chemical*, 101(1–2), 39–46.
- Brown, R. G., & Hwang, P. Y. C. (2012). *Introduction to random signals and applied Kalman filtering*. John Wiley & Sons.

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Кусаинов Ануар Бейбутович** – докторант, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан  
**Кусаинов Ануар Бейбутович** – докторант, Восточно-Казахстанский технический университет им. Д. Серікбаева, г. Усть-Каменогорск, Казахстан  
**Kussainov Anuar Beibutovich** – PhD student, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan  
e-mail: [ak@kab.kz](mailto:ak@kab.kz)  
ORCID: <https://orcid.org/0009-0005-9962-7237>



**Жомартқызы Гүлназ** – PhD докторы, қауымдастырылған профессор, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

**Жомартқызы Гүлназ** – доктор PhD, ассоциированный профессор, Восточно-Казakhstanский технический университет имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан

**Zhomartkyzy Gulnaz** – PhD, Associate Professor, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan  
e-mail: gzhomartkyzy@edu.ektu.kz

ORCID: <https://orcid.org/0000-0003-1465-3451>



**Rajermani Thinakaran** – PhD докторы, қауымдастырылған профессор, INTI International University, Лабу қ., Малайзия

**Rajermani Thinakaran** – доктор PhD, ассоциированный профессор, INTI International University, г. Лабу, Малайзия

**Rajermani Thinakaran** – PhD, Associate Professor, INTI International University, Labu, Negeri Sembilan, Malaysia  
e-mail: rajermani@yahoo.com

ORCID: <https://orcid.org/0009-0007-2677-3406>