

DOI: <https://doi.org/10.36910/6775-2524-0560-2025-61-23>

УДК 004.738.5:004.85:

Мусієнко Максим Павлович¹, д.т.н., професор

<https://orcid.org/0000-0001-9228-2233>

Мусієнко Олена Юріївна², магістрант

¹ Черкаський національний університет ім. Б. Хмельницького, м. Черкаси, Україна

² Чорноморський національний університет ім. П. Могили, м. Миколаїв, Україна

ІНТЕГРАЦІЯ П'ЄЗОКЕРАМІЧНИХ ІОТ-СИСТЕМ МОНІТОРИНГУ З AMAZON SAGEMAKER ДЛЯ ПРОГНОЗНОГО АНАЛІЗУ

Мусієнко М. П., Мусієнко О. Ю. Інтеграція п'єзокерамічних ІоТ-систем моніторингу з Amazon SageMaker для прогнозного аналізу. У статті розглядається вирішення науково-практичної задачі переходу від реактивного моніторингу до прогнозного аналізу для ІоТ-систем, що базуються на високочутливих п'єзокерамічних датчиках. На відміну від рішень, які зосереджені тільки на зборі та зберіганні даних, в роботі запропоноване комплексне рішення, що забезпечує глибоку інтеграцію з платформою машинного навчання Amazon SageMaker. Запропонований варіант ґрунтується на трьох паралельних потоках: збір даних (Data Ingestion Flow) для формування «озера даних» в Amazon S3, навчання моделі (Model Training Flow) з використанням AWS Glue для інженерії ознак, та прогнозовий аналіз у реальному часі (Inference Flow) на базі SageMaker Endpoints. Описано методику побудови елементів машинного навчання, що включає критичний етап інженерії ознак (Feature Engineering) для перетворення складних «сирих» сигналів п'єзодатчиків (наприклад, RMS, FFT) у придатні для аналізу дані. Проведено аналіз застосування алгоритмів, зокрема Random Cut Forest (RCF) для виявлення аномалій «без вчителя» та XGBoost для класифікації несправностей «з вчителем». Ефективність архітектури підтверджено експериментально на стенді в середовищі AWS Academy Learning Lab, що імітувало як системні (знос), так і раптові ударні аномалії. Модель RCF продемонструвала високі показники, досягнувши 91% точності та 88% повноти у виявленні несправностей. Результати доводять придатність запропонованого рішення для побудови масштабованих систем прогнозової діагностики.

Ключові слова: п'єзокерамічні датчики, ІоТ-системи, AWS (Amazon Web Services), Amazon SageMaker, машинне навчання, прогнозовий аналіз, виявлення аномалій.

Musiyenko M., Musiyenko O. Integration of Piezoceramic IoT Monitoring Systems with Amazon SageMaker for Predictive Analysis. The article addresses the scientific and practical problem of transitioning from reactive monitoring to predictive analysis for IoT systems based on highly sensitive piezoceramic sensors. Unlike solutions focused solely on data collection and storage, this work proposes a comprehensive solution ensuring deep integration with the Amazon SageMaker machine learning platform. The proposed approach is based on three parallel flows: the Data Ingestion Flow for creating a «data lake» in Amazon S3, the Model Training Flow using AWS Glue for feature engineering, and the real-time Inference Flow based on SageMaker Endpoints. The methodology for constructing the machine learning components is described, including the critical stage of Feature Engineering, which transforms complex «raw» piezosensor signals (e.g., RMS, FFT) into analysis-ready data. The application of algorithms is analyzed, particularly the Random Cut Forest (RCF) for unsupervised anomaly detection and XGBoost for supervised fault classification. The architecture's effectiveness was experimentally validated on a testbed within the AWS Academy Learning Lab environment, simulating both systemic (wear-and-tear) and sudden shock anomalies. The RCF model demonstrated high performance, achieving 91% precision and 88% recall in fault detection. The results demonstrate the suitability of the proposed solution for building scalable predictive diagnostics systems.

Keywords: piezoceramic sensors, IoT systems, AWS (Amazon Web Services), Amazon SageMaker, machine learning, predictive analysis, anomaly detection.

Постановка наукової проблеми. Сучасний розвиток промислового Інтернету Речей (IIoT) відкриває широкі можливості для моніторингу та діагностики стану промислового обладнання в режимі реального часу. Ефективне функціонування таких систем безпосередньо залежить від чутливості та надійності первинних перетворювачів (датчиків), серед яких особливе місце займають п'єзокерамічні датчики, здатні фіксувати широкий спектр динамічних параметрів, таких як вібрація, деформації, тиск тощо. Інтеграція таких сенсорних систем із хмарними платформами, наприклад, Amazon Web Services (AWS), вже довела свою ефективність для вирішення завдань збору, передачі та надійного зберігання великого обсягу даних.

Проте, більшість існуючих архітектур зосереджені на вирішенні першого етапу – забезпеченні надійної доставки та зберігання телеметрії (наприклад, з використанням сервісів AWS IoT Core, Lambda та Timestream). Аналіз цих даних часто залишається реактивним, базуючись на візуалізації та контролі за перевищенням порогових значень, що вимагає постійного втручання оператора.

Недоліки суто реактивного підходу призводять до непланових зупинок обладнання, значних фінансових втрат через простій та аварійні ремонти. На противагу цьому, прогнозований підхід дозволяє перейти до стратегії проактивного технічного обслуговування. Ключова перевага такого підходу полягає у здатності не просто констатувати факт збою, а заздалегідь ідентифікувати

початкові аномалії та спрогнозувати ймовірну відмову. Це, у свою чергу, дає можливість оптимізувати графіки ремонтів, мінімізувати час простою та суттєво знизити експлуатаційні витрати.

Таким чином, виникає важливе науково-практичне завдання: здійснити перехід від реактивних моделей моніторингу до прогнозних. Це завдання вимагає не просто збору даних, а створення комплексного, автоматизованого процесу для їх інтелектуального аналізу.

Наукова проблема, вирішенню якої присвячена дана робота, полягає у розробці та дослідженні архітектури та методики інтеграції п'єзокерамічних IoT-систем моніторингу з високорівневими сервісами машинного навчання, зокрема Amazon SageMaker. Необхідно вирішити задачу підготовки комплексних даних від п'єзодатчиків та побудови на їх основі прогнозних моделей, які дозволять автоматично ідентифікувати аномалії та прогнозувати відмови обладнання до їхньої появи.

Аналіз останніх досліджень. На сьогоднішній день проведено багато досліджень в галузі п'єзокерамічних датчиків для моніторингу стану обладнання, де, звісно, більшість уваги приділено розробці саме конструкцій високочутливих п'єзоперетворювачів. Щодо моніторингу стану обладнання, то більшість наукових праць у цій галузі присвячена методам обробки сигналів (наприклад, швидке перетворення Фур'є тощо) та застосуванню інструментів для виявлення дефектів на основі цих сигналів [1, 2]. Проте такі обчислення зазвичай виконуються локально, незважаючи на те, що перспективним є використання можливостей хмарних технологій, що є наступним кроком досліджень.

Отже інтеграція IoT-датчиків з хмарними провайдерами (наприклад, AWS) є вельми перспективним напрямком, оскільки може використати багато переваг хмарних сервісів: надійне, зручне та безпечне зберігання та обробка сенсорних даних [3-5]. Зокрема, у роботі [3] представлена та експериментально перевірена архітектурна модель інтеграції п'єзокерамічних IoT-систем в інфраструктуру Amazon Web Services. Ця архітектура ефективно вирішує задачу збору даних через AWS IoT Core, їх обробки за допомогою AWS Lambda та надійного зберігання у спеціалізованих сховищах, таких як Amazon Timestream, DynamoDB та S3. Також детально проаналізовані питання забезпечення безпеки цього конвеєра даних за допомогою сервісів AWS IoT Device Defender, KMS та політик IAM. Однак, у зазначених роботах кінцевою метою є зберігання та візуалізація вимірювальних даних, що відповідає самій реактивній моделі моніторингу, а не прогнозній.

Проте, як зазначалося вище, використання хмарних технологій, зокрема сервісів AWS, дає багато переваг за рахунок використання різних сервісів провайдера, в тому числі і інструментів для прогнозування [6-7], зокрема, сервісу Amazon SageMaker. Існують готові схемні рішення, що показують використання SageMaker для аналізу даних з IoT-пристроїв, наприклад, для обробки інформації на основі даних про температуру, вібрацію, частоту обертів тощо [8]. Проте, аналіз цих робіт показує, що вони в більшості розглядають типові спрощені задачі, де в якості джерел даних виступають датчики з відносно простою структурою сигналу (наприклад, сигнал від загальноцільових MEMS-акселерометрів [9]). Проте системи моніторингу IoT-пристроїв, що розглядаються в роботі, пов'язані з обробкою складних, зашумлених сигналів від спеціалізованих п'єзокерамічних систем і вимагають більш деталізованого підходу.

Таким чином, аналіз останніх досліджень показує наявність ефективних локальних методів аналізу складних сигналів п'єзодатчиків; наявність надійних хмарних архітектур для збору та зберігання даних з цих датчиків та наявність потужних хмарних сервісів для прогнозного аналізу IoT-даних. Проте практично відсутні комплексні дослідження, що описують інтеграції високочутливих п'єзокерамічних систем моніторингу безпосередньо з керованими хмарними сервісами машинного навчання, такими як Amazon SageMaker, для вирішення саме прогнозних завдань. Вирішенню цього питання присвячена робота авторів.

Мета роботи полягає у розробці методики та засобів інтеграції п'єзокерамічних IoT-систем моніторингу з сервісами машинного навчання хмарного провайдера AWS, зокрема Amazon SageMaker, для забезпечення масштабованої та автоматизованої прогнозної діагностики стану промислового устаткування.

Виклад основного матеріалу дослідження. Вирішення поставленої наукової проблеми вимагає розробки комплексної системи, яка б не тільки збирала дані, але й забезпечувала їх інтелектуальний аналіз. Запропонована архітектура ґрунтується на вже апробованих підходах до збору та зберігання сенсорної телеметрії [3-5], але суттєво розширює їх, інтегруючи керовані сервіси машинного навчання для здійснення прогнозної функції.

Архітектуру доцільно розглядати як три логічні потоки, що функціонують, як правило, паралельно:

- потік збору та зберігання даних (*Data Ingestion Flow*);
- потік навчання моделі (*Model Training Flow*);
- потік прогнозного аналізу (*Inference Flow*).

Перший потік - Data Ingestion Flow (збору та зберігання даних). Цей потік відповідає за надійну доставку «сирих» даних від п'єзокерамічних датчиків до хмарного сховища. Цей етап є базовим для всієї системи і значною мірою спирається на архітектуру, яка була досліджена авторами в [3].

Потік даних виглядає наступним чином (рис. 1). П'єзокерамічний IoT-пристрій (наприклад, на базі ESP32 з п'єземагнітним тахометром або вібродатчиком тощо) передає результати вимірювання у форматі JSON через протокол MQTT до сервісу AWS IoT Core. Спеціально налаштоване правило маршрутизації (IoT Rule) в AWS IoT Core аналізує вхідні повідомлення та перенаправляє їх на функцію AWS Lambda для первинної обробки (наприклад, валідації або фільтрації). Lambda-функція розподіляє потік на дві складові:

- дані для довгострокового зберігання та подальшого навчання моделі, що акумулюються у «озері даних» (Data Lake) на базі Amazon S3;
- дані для моніторингу в реальному часі, що можуть додатково направлятись до Amazon Timestream [3].




Рис. 1. Схема потоку Data Ingestion Flow - збору та зберігання даних

Другий потік - Model Training Flow (навчання моделі) - є ключовим елементом для побудови прогнозної функції. Його робота відбувається періодично (наприклад, щоночі) або за вимогою. Накопичені в Amazon S3 попередні дані використовуються як джерело для навчання.

Сервіс AWS Glue може бути використаний для виконання ETL-процесів (Extract, Transform, Load) - очищення даних та інженерії ознак (Feature Engineering). На цьому етапі «сирі» дані перетворюються у вектори ознак (списки числових параметрів), придатні для моделі машинного навчання. Прикладами таких ознак є середньоквадратичне значення (RMS), пікові значення, статистичні моменти сигналу, а також результати швидкого перетворення Фур'є, що відображають частотний склад сигналу.

Підготовлений набір даних (dataset) подається на вхід спеціалізованого завдання навчання (Training Job) в Amazon SageMaker. Тут відбувається безпосереднє навчання моделі (наприклад, з використанням алгоритму Random Cut Forest для виявлення аномалій) та її валідація. Результатом є файл навченої моделі, який зберігається в Amazon S3 та реєструється у SageMaker.

Третій потік - Inference Flow (прогнозного аналізу) - реалізується для обробки нових даних в реальному часі та використовує модель, яка була створена на попередньому (другому) потоці.

Навчена модель розгортається як постійно діюча кінцева точка Amazon SageMaker (SageMaker Endpoint). Нові дані від датчиків, що надходять до AWS IoT Core, перенаправляються на іншу Lambda-функцію (Inference Lambda). Ця Lambda-функція в реальному часі викликає SageMaker Endpoint та передає йому поточні дані датчика (вже перетворені у потрібний вектор

ознак). SageMaker Endpoint миттєво повертає прогноз (наприклад, «Normal», «Anomaly» або «Time-to-Failure»).

Цей результат може бути використаний для негайного реагування (наприклад, через Amazon SNS для надсилання сповіщення оператору) або збережений в Amazon DynamoDB для фіксації поточного стану обладнання.

Машинне навчання. Вирішальним для переходу від реактивного моніторингу до прогнозного є ефективне використання можливостей машинного навчання. Запропонована методика фокусується на створенні оптимізованого потоку в Amazon SageMaker, який дозволяє перетворити складні та зашумлені сигнали п'єзокерамічних датчиків на корисні прогнози. Цей потік можна розділити на три основні взаємопов'язані етапи:

- підготовка даних;
- навчання моделі;
- розгортання для виконання прогнозів.

Етап підготовки та інженерії ознак (Data Preparation and Feature Engineering). «Сирі» дані вимірювального сигналу, що надходять від п'єзокерамічних датчиків, часто є високочастотними, зашумленими та можуть містити аномалії, що не пов'язані з несправностями обладнання. Тому безпосереднє використання цих даних для навчання моделей машинного навчання є малоефективним.

Основна задача цього етапу - перетворення «сирих» часових рядів на інформативні вектори ознак, які краще відображають стан об'єкта аналізу. Цей процес, відомий як інженерія ознак (Feature Engineering), може включати наступні кроки:

- очищення даних: фільтрація шумів, усунення пропусків, нормалізація даних;
- сегментація: розбиття безперервних потоків даних на окремі часові вікна або сегменти;
- вилучення ознак у часовій області: розрахунок таких параметрів, як RMS, пікові значення тощо;
- вилучення ознак у частотній області: розрахунок параметрів на основі швидкого перетворення Фур'є (FFT) для аналізу домінуючих частот та їх амплітуд, що є критично важливим для діагностики механічних несправностей (наприклад, дисбалансу або розцентрування обертових валів).

Виконання цих ETL-процесів та інженерії ознак може бути реалізовано з використанням сервісів AWS Glue (для пакетної обробки великих накопичених даних) або AWS Lambda (для обробки в реальному часі на етапі прогнозування).

Етап вибору та навчання моделі (Model Selection and Training). Після підготовки наборів даних (datasets) з вилученими ознаками, наступним кроком є вибір алгоритму машинного навчання та його навчання. Вибір конкретного алгоритму SageMaker залежить від поставленої задачі та наявності маркованих даних (тобто даних, де відомі несправності).

Можна виділити два основні підходи (таблиця 1): прогнозування аномалій (без вчителя) та класифікація несправностей (з вчителем).

Перший підхід застосовується, коли накопичені дані не мають розмітки про несправності. Його задача - виявити будь-яку поведінку, що відхиляється від норми. Оптимальним вибором для цього є вбудований алгоритм Amazon SageMaker - Random Cut Forest (RCF) [10]. Він ефективно виявляє несподівані сплески, зміни в поведінці сигналу або інші аномалії в часових рядах, що характерно для початкових стадій відмов обладнання [11].

Другий підхід застосовується у випадку, коли наявний набір даних, де кожному запису стоїть у відповідності конкретний стан (наприклад, «Норма», «Дисбаланс», «Несправність підшипника»), задача зводиться до класифікації. Для прогнозування конкретного класу несправності доцільно використовувати потужні алгоритми, такі як XGBoost [12, 13].

Сам процес навчання запускається як спеціалізоване завдання навчання (Training Job), яке SageMaker автоматично конфігурує, запускає та зупиняє, зберігаючи вихідний файл навченої моделі в Amazon S3.

Отже вибір конкретного алгоритму SageMaker для прогнозного аналізу стану обладнання залежить від наявності та характеру накопичених даних, а також від поставленої технічної задачі.

Таким чином, запропонована методика дозволяє гнучко адаптувати рішення машинного навчання до специфічних вимог та наявних даних, забезпечуючи перехід від простого моніторингу до прогнозного аналізу.

Таблиця 1. Порівняння ключових характеристик алгоритмів Amazon SageMaker для задач прогновної діагностики

Характеристика	Random Cut Forest (RCF)	XGBoost
Задача	виявлення аномалій	класифікація / регресія
Тип навчання	без вчителя	з учителем
Вимоги до даних	не вимагає маркованих даних про несправності	потребує марковані дані про несправності
Принцип	ізолює аномалії як точки, які легко відсторонити від решти даних	будує послідовність слабких моделей (дерев рішень) для точного прогнозу
Застосування	виявлення незвичайних даних (відхилень)	прогнозування типів несправностей
Переваги для IoT	добре працює з часовими рядами, швидко виявляє аномалії	висока точність та стійкість до зашумлених даних, масштабованість
Недоліки / обмеження	не виявляє тип несправності (лише її наявність)	потребує значного обсягу маркованих даних

Етап розгортання та виконання прогнозу (Model Deployment and Inference). Завершальним етапом є розгортання навченої моделі для отримання реальних прогнозів. У SageMaker це досягається шляхом створення «кінцевої точки» (SageMaker Endpoint) - постійно діючого, високодоступного API, який приймає на вхід нові дані (вектор ознак) і миттєво повертає прогноз.

Як було показано при описі третього потоку, у потоці Inference Flow нові дані від датчика надходять до Inference Lambda. Ця функція виконує ту ж саму інженерію ознак (розраховує RMS, FFT тощо), що й на етапі навчання, щоб перетворити «сирі» дані у вектор ознак. Lambda-функція викликає SageMaker Endpoint, передаючи йому цей вектор. У відповідь SageMaker Endpoint повертає прогноз (наприклад, «Аномалія» або «Тип несправності В»), який далі використовується для сповіщення оператора.

Приклад реалізації. Для практичної верифікації розробленої архітектури та методики моніторингу було зібрано експериментальний стенд, що імітує роботу промислового обладнання та генерує вібраційні сигнали, які є об'єктом аналізу.

За основу стенду було взято установку, що включає:

- джерело вібрації: електродвигун AMS1141M з асиметричним навантаженням на валу, що створює контрольовану вібрацію;
- датчик вібрації: консольний п'єзоперетворювач, що складається з гнучкої оцинкованої сталеві пластина 35x20x0,4 мм марки 08пс/3сп та чотирьох асиметричних біморфних п'єзоелементів типу muRata 7BB-12-9. Таке виконання забезпечує значно вищу чутливість до згинальних коливань, що є критичним для реєстрації слабких аномалій;
- система контролю: для верифікації даних використовувався тахометр (для вимірювання частоти обертання) та осцилограф (для візуалізації «сирого» сигналу з п'єзоелемента).

Імітація несправностей (аномалій) досягалася шляхом зміни частоти обертання двигуна та внесення додаткового дисбалансу в асиметричне навантаження, що симулювало такі стани, як знос підшипника або розбалансування ротора. Для моделювання ударних аномалій, таких як раптові удари чи поштовхи, на платформу стенду подавалися короткочасні контрольовані ударні навантаження.

Розгортання хмарної частини архітектури проводилось з використанням навчальної платформи AWS Academy Learning Lab. Це середовище надало безпечний, ізольований доступ до повнофункціональних сервісів AWS, що дозволило провести експериментальну апробацію без необхідності створення та налаштування комерційного облікового запису.

Для безпечної автентифікації пристрою було згенеровано та завантажено на мікроконтролер сертифікати X.509 (клієнтський сертифікат та приватний ключ). Для збору та зберігання даних було створено сховище даних у сервісі Amazon S3, який виступав у ролі «озера даних» (Data Lake) для зберігання «сирих» показників вібрації.

В AWS IoT Core було налаштовано правило (IoT Rule), яке аналізувало надходження даних. При надходженні кожного нового повідомлення, це правило автоматично (без участі серверів) перенаправляло та зберігало копію JSON-повідомлення у S3-бакеті.

Для аналізу зібраних даних було використано сервіс Amazon SageMaker, який було підключено до створеного S3-бакет як до джерела даних.

Навчання моделі відбувалося безпосередньо в середовищі SageMaker з використанням вбудованого алгоритму Random Cut Forest (RCF).

Після навчання, модель була розгорнута як постійно діюча кінцева точка (SageMaker Endpoint). Це дозволило надсилати нові дані про вібрацію в режимі реального часу та отримувати миттєву оцінку «аномальності».

Для імітації повноцінної системи моніторингу, було створено функцію AWS Lambda. Ця функція спрацьовувала при виявленні аномалії (коли сигнал від SageMaker Endpoint перевищував визначений поріг) та надсилала повідомлення у сервіс Amazon Simple Notification Service (SNS).

Проведений експеримент підтвердив працездатність запропонованого рішення. Дані з консольного п'єзоперетворювача були успішно зібрані та передані до хмари AWS.

Модель RCF в Amazon SageMaker продемонструвала високу ефективність у виявленні імітованих несправностей. Для перевірки було використано тестову вибірку, що містила 85% даних «нормальної» роботи та 15% імітованих аномалій (що включали як системні відхилення - імітацію зносу, так і випадкові - раптові ударні навантаження).

Аналіз результатів показав, що модель особливо ефективна у виявленні раптових ударних аномалій, коректно ідентифікуючи їх як серйозні відхилення від норми. Це призвело до високого загального показника повноти у 88% (система успішно зафіксувала 8 з 9 реальних аномальних подій, мінімізуючи ризик пропуску критичного збою).

Водночас точність досягла значення у 91% (система фіксувала аномалію у 9 з 10 випадків), що свідчить про низький рівень хибних спрацювань.

Висновки та перспективи подальших досліджень.

У статті описано рішення інтеграції п'єзокерамічних IoT-систем моніторингу з хмарними сервісами AWS, що реалізує перехід від простого реактивного збору даних до прогностичного аналізу стану обладнання. Рішення ґрунтується на трьох паралельних потоках: Data Ingestion Flow (збір даних через AWS IoT Core та зберігання в S3), Model Training Flow (періодичне навчання моделей машинного навчання в SageMaker) та Inference Flow (застосування навчених моделей для аналізу нових даних у реальному часі). Все це дозволяє не просто фіксувати збої, а й заздалегідь ідентифікувати аномалії, що призводять до них.

Ключовим елементом методики є потік машинного навчання в Amazon SageMaker, який починається з інженерії ознак (Feature Engineering) для перетворення «сирих» вібраційних сигналів у придатні для аналізу вектори (наприклад, RMS, FFT). Залежно від наявності маркованих даних, архітектура гнучко використовує алгоритм Random Cut Forest (RCF) для виявлення аномалій (без вчителя) або XGBoost для класифікації конкретних несправностей (з вчителем). Практична верифікація в середовищі AWS Academy Learning Lab на стенді з імітацією системних (знос) та ударних (поштовхи) аномалій підтвердила високу ефективність моделі RCF, яка досягла 91% точності та 88% повноти у виявленні несправностей.

Перспективи подальших досліджень полягають у розширенні аналітичних можливостей системи, зокрема у переході від виявлення аномалій «без вчителя» (RCF) до класифікації конкретних типів несправностей «з вчителем». Це вимагатиме збору та розмітки великого набору даних з експериментального стенду для навчання таких моделей, як XGBoost. Окрім цього, важливим напрямком є апробація розробленої архітектури в реальних промислових умовах та її адаптація для повністю автономних IoT-вузлів.

Список бібліографічного опису

1. Kolok P., Hodon M., Sevcik P., Hotz L., Remy N. Low-Cost IoT-Based Predictive Maintenance Using Vibration. Intelligent Industrial Process Control Systems: 2nd Edition (a special issue of Sensors). 2025. No. 25. 6610. URL: <https://doi.org/10.3390/s25216610>.
2. Safian A., Wu N., Liang X. Development of an embedded piezoelectric transducer for bearing fault detection. Mechanical Systems and Signal Processing. 2023. Vol. 188. 109937. URL: <https://doi.org/10.1016/j.ymssp.2022.109987>.
3. Мусієнко М.П., Мусієнко О.Ю. Інтеграція IoT-систем збору сенсорних даних на основі п'єзокерамічних датчиків у хмарну інфраструктуру AWS // Комп'ютерно-інтегровані технології: освіта, наука, виробництво. - Луцьк: ЛНТУ, 2025. № 60. - С. 217-223. DOI: <https://doi.org/10.36910/6775-2524-0560-2025-60-23>.

4. Bouslama A., Laaziz Y., Tali A., Eddabbah M. AWS and IoT for Real-time Remote Medical Monitoring / International Journal of Intelligent Enterprise. 2019. Vol. 6, no. 2-4. P. 369–381. URL: <https://doi.org/10.1504/IJIE.2019.101137>.
5. Clement. AWS IoT Core in Healthcare: Real-Time Patient Monitoring. Amazon Web Services. URL: <https://surl.li/tckfib> (дата звернення: 17.11.2025).
6. What is Predictive Maintenance?. Amazon Web Services. URL: <https://surl.li/bgqera> (дата звернення: 17.11.2025).
7. Guidance for Predictive Maintenance with Amazon Monitron. Amazon Web Services. URL: <https://surl.li/hnwvbu> (дата звернення: 17.11.2025).
8. Predictive Maintenance with AWS IoT | CloudRail | IFM. NorthBay, LLC. URL: <https://surl.lu/cqdlhh> (дата звернення: 17.11.2025).
9. Activity Recognition Using SmartPhone Sensor Data on Amazon SageMaker. GitHub, Inc. URL: <https://surl.lu/qnfnbo> (дата звернення: 17.11.2025).
10. Random Cut Forest (RCF) Algorithm. Amazon Web Services. URL: <https://surl.li/vvmcxy> (дата звернення: 17.11.2025).
11. Guha S., Mishra N., Roy G., Schrijvers O. Robust Random Cut Forest Based Anomaly Detection On Streams / Proceedings of The 33rd International Conference on Machine Learning. 2016. P. 2712–2721. URL: <https://surl.li/eaiktt> (дата звернення: 17.11.2025).
12. XGBoost algorithm with Amazon SageMaker AI. Amazon Web Services. URL: <https://surl.li/xddqdk> (дата звернення: 17.11.2025).
13. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System. KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 13 August 2016. P. 785–794. URL: <https://doi.org/10.1145/2939672.2939785> (дата звернення: 17.11.2025).

References

1. Kolok P., Hodon M., Sevcik P., Hotz L., Remy N. Low-Cost IoT-Based Predictive Maintenance Using Vibration. Intelligent Industrial Process Control Systems: 2nd Edition (a special issue of Sensors). 2025. No. 25. 6610. URL: <https://doi.org/10.3390/s25216610>.
2. Safian A., Wu N., Liang X. Development of an embedded piezoelectric transducer for bearing fault detection. Mechanical Systems and Signal Processing. 2023. Vol. 188. 109937. URL: <https://doi.org/10.1016/j.ymssp.2022.109987>.
3. Мусієнко М.П., Мусієнко О.Ю. Інтеграція IoT-систем збору сенсорних даних на основі п'єзокерамічних датчиків у хмарну інфраструктуру AWS // Комп'ютерно-інтегровані технології: освіта, наука, виробництво. - Луцьк: ЛНТУ, 2025. № 60. - С. 217-223. DOI: <https://doi.org/10.36910/6775-2524-0560-2025-60-23>.
4. Bouslama A., Laaziz Y., Tali A., Eddabbah M. AWS and IoT for Real-time Remote Medical Monitoring / International Journal of Intelligent Enterprise. 2019. Vol. 6, no. 2-4. P. 369–381. URL: <https://doi.org/10.1504/IJIE.2019.101137>.
5. Clement. AWS IoT Core in Healthcare: Real-Time Patient Monitoring. Amazon Web Services. URL: <https://surl.li/tckfib> (date of access: 17.11.2025).
6. What is Predictive Maintenance?. Amazon Web Services. URL: <https://surl.li/bgqera> (date of access: 17.11.2025).
7. Guidance for Predictive Maintenance with Amazon Monitron. Amazon Web Services. URL: <https://surl.li/hnwvbu> (date of access: 17.11.2025).
8. Predictive Maintenance with AWS IoT | CloudRail | IFM. NorthBay, LLC. URL: <https://surl.lu/cqdlhh> (date of access: 17.11.2025).
9. Activity Recognition Using SmartPhone Sensor Data on Amazon SageMaker. GitHub, Inc. URL: <https://surl.lu/qnfnbo> (date of access: 17.11.2025).
10. Random Cut Forest (RCF) Algorithm. Amazon Web Services. URL: <https://surl.li/vvmcxy> (date of access: 17.11.2025).
11. Guha S., Mishra N., Roy G., Schrijvers O. Robust Random Cut Forest Based Anomaly Detection On Streams / Proceedings of The 33rd International Conference on Machine Learning. 2016. P. 2712–2721. URL: <https://surl.li/eaiktt> (date of access: 17.11.2025).
12. XGBoost algorithm with Amazon SageMaker AI. Amazon Web Services. URL: <https://surl.li/xddqdk> (date of access: 17.11.2025).
13. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System. KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 13 August 2016. P. 785–794. URL: <https://doi.org/10.1145/2939672.2939785> (date of access: 17.11.2025).