

УДК 629.064:631.372:004.8 [https://doi.org/10.32515/2664-262X.2025.12\(43\).1.227-237](https://doi.org/10.32515/2664-262X.2025.12(43).1.227-237)**О. О. Матвієнко**, доц., канд. техн. наук, **В. В. Аулін**, проф., д-р техн. наук,**А. В. Гриньків**, ст. дослідник, канд. техн. наук*Центральноукраїнський національний технічний університет, м. Кропивницький, Україна**e-mail: AulinVV@gmail.com*

Стан та напрями розвитку архітектури даних для інтелектуальної оцінки технічного стану мобільних машин підприємств агропромислового виробництва

У статті подано критичний огляд сучасних існуючих наборів даних з сенсорів для інтелектуальної оцінки технічного стану вузлів і механізмів мобільних машин агропромислового виробництва шляхом застосування методів машинного навчання. Показано обмеженість існуючих публічних наборів даних, відсутність уніфікації методики і архітектури збору даних в умовах агропромислового підприємства. Запропоновано концепцію і архітектуру для збору даних з сенсорів на вузлах і механізмах мобільних машин агропромислового виробництва з подальшою обробкою методами машинного навчання для інтелектуальної оцінки технічного стану.

мобільні машини, агропромислове виробництво, інтелектуальна система, технічний сервіс, машинне навчання, прогнозне технічне обслуговування, мультисенсорна діагностика, діагностичні сигнали, виявлення аномалій

Постановка проблеми. Мобільні машини агропромислового виробництва (ММАПВ) працюють у змінних, часто жорстких умовах середовища і навантажувальних режимах, що ускладнює своєчасне виявлення деградації вузлів і планування сервісу. Планові й реактивні підходи технічного обслуговування (ТО) не відображають реального технічного стану та призводять до непередбачуваних відмов і зростання витрат. Потрібен перехід до інтелектуального технічного сервісу, заснованого на інтеграції сенсорних вимірювань і методів машинного навчання для онлайн-діагностики та прогнозного обслуговування [1].

Водночас, попри стрімкий розвиток штучного інтелекту (ШІ) і, зокрема, машинного навчання (МН), у відкритому доступі бракує якісних наборів даних для інтелектуальної оцінки технічного стану вузлів та механізмів машин загалом і ММАПВ зокрема. У роботах в цьому напрямі дані відсутні або недоступні для відтворення. Немає й усталеної архітектури та узгодженої методики збору таких даних у реальних умовах підприємств агропромислового комплексу (АПК), що гальмує стандартизацію та бенчмаркінг рішень в напрямку інтелектуальної оцінки технічного стану ММАПВ.

Аналіз останніх досліджень і публікацій. У межах предметної області інтелектуальної оцінки технічного стану мобільних машин агропромислового виробництва релевантні джерела даних виявилися поодинокими, фрагментарними та гетерогенними за модальністю (вібрація, акустика, електричні сигнали), режимами збирання і якістю супровідних метаданих. На базі класифікації сенсорних сигналів і сценаріїв діагностики [2] здійснено систематичний відбір і стратифікацію наборів даних на три категорії: публічні; одержані авторами та формально доступні «за запитом»; повністю закриті.

У табл. 1 узагальнено відкриті набори даних, релевантні до мобільних машин агропромислового виробництва: зазначено джерело даних, об'єкт контролю (вузли машини), модальність сигналів (вібрація, акустичний сигнал тощо) та короткий опис даних. Посилання на набори даних подано в загальному списку літератури [23-34].

У табл. 2 показано, що низка дослідників працює саме з відкритими публічними наборами даних і звітує результати у наукових публікаціях [3-17]. Для кожного випадку стисло окреслено постановку задачі (класифікація технічних станів, виявлення аномалій, прогнозування залишкового ресурсу), протокол оцінювання та метрики якості, що застосовувалися в роботах (зокрема, для класифікації – точність, F1-міра, ROC-AUC; для регресійних оцінок – MAE, RMSE; для прогнозних оцінок – CRPS). Окремо відзначимо, що жодне з проаналізованих джерел не надало зафіксованого обчислювального середовища (Python / R / MATLAB) у вигляді lock-файлів, контейнерних образів, здатних забезпечити повну відтворюваність заявлених результатів при наявності скриптів відтворення.

Таблиця 1 – Характеристика публічних наявних наборів даних з сенсорів, релевантних з вузлами і механізмами мобільних машин агропромислового виробництва

Коротка назва	Розшифровка аббревіатури в назві	Модальність / сфера	Короткий опис (агрорелевантність)
DCASE'20 T2 [23]	Detection and Classification of Acoustic Scenes and Events 2020 Task 2	Акустика (звуки машин)	Звуки вентиляторів, насосів, клапанів, конвеєрів — допоміжні вузли у мобільній агротехніці
DCASE'21 T2 [24]	Detection and Classification of Acoustic Scenes and Events 2021 Task 2	Акустика (звуки машин)	Як у DCASE'20, але з доменним зсувом; включає редуктор/слайд-рейл
IMS [25]	Intelligent Maintenance Systems (NASA PCoE/IMS Rexnord) Run-to-Failure	Вібрація (підшипники)	Run-to-failure підшипників валів — типова деградація трансмісії/насосів
CWRU [26]	Case Western Reserve University Bearing Data Center	Вібрація (підшипники)	Штучні дефекти підшипників за різних навантажень (редуктори/вали)
SEU/DDS [27]	Southeast University / Drivetrain Dynamic Simulator	Вібрація (підшипники, редуктор)	Редуктор і підшипники на стенді DDS; умови 20-0 / 30-2 (трансмісії/приводи)
Paderborn/Kat [28]	Paderborn University — Chair of Design and Drive Technology	Вібрація (підшипники; також струм)	Вібрація підшипників у приводі; за потреби канал MCSA
JNU [29]	Jiangnan University Bearing Dataset	Вібрація (підшипники)	Підшипники на різних швидкостях (600–1000 rpm); варіативність режимів
PHM2009 [30]	Prognostics and Health Management 2009 Gearbox Challenge	Вібрація (редуктор)	Редуктор з акселерометрами (аналог коробок/приводів навісного обладнання)
MFPT [31]	Society for Machinery Failure Prevention Technology	Вібрація (підшипники; стенд + польові)	Польові піднабори: масляний насос, проміжний вал, планетарний підшипник
MaFaulDa [32]	Machinery Fault Database (SpectraQuest rig)	Вібрація (роторні вузли)	Дисбаланс, невірнє врівноваження, дефекти підшипників — типові для валів та редукторів
Purdue Motor [33]	Purdue Motor Testbed Vibration (Abdallah et al., 2023)	Вібрація (електродвигун)	3 осі; piezo 3.2 кГц і MEMS 10 Гц; 100–600 rpm; 3 стани (норма, передвідмова, відмова)
UCI HIL [34]	University of California, Irvine — Hydraulic Systems	Мультисенсор (гідросистема)	Тиски, витрати, температури, потужність; мішені: охолоджувач, клапан, витоки насоса, акумулятор

Джерело: розроблено авторами

Серед проаналізованих робіт трапляються кейси, де автори використовують власні (непублічні) експериментальні дані й декларують готовність надати їх за

запитом. Як правило – це лабораторні вимірювання вібрацій або акустичних сигналів на стендах або виробничих установках з обмеженнями доступу. У роботі [18] у розділі Data Availability прямо зазначено, що «дані, представлені в цьому дослідженні, доступні на запит кореспондуючому автору». У роботі [19] описано повноцінний вібростенд з випробуванням підшипників, шківів, крильчаток, електродвигунів, але відкритого архіву сирих даних немає (операційні дані підприємства/лабораторії). До цієї «напіввідкритої» категорії також належить ситуація, коли використовують публічні сирі дані. В той же час похідні набори ознак/результатів авторів надаються лише «за запитом» [7]. Такі практики корисні як джерело реалістичних сигналів, проте вони обмежують відтворюваність і порівнюваність. Зазначимо, що для коректного повторення експериментів необхідні: формалізований протокол доступу, чітка ліцензія й стабільне сховище.

Таблиця 2 – Використання публічних наборів даних з сенсорів, релевантних з вузлами і механізмами мобільних машин агропромислового виробництва в наукових роботах

Коротка назва наборів даних	Літературне джерело	Завдання	Протокол	Метрики
DCASE'20 T2	3	виявлення аномалій (без нагляду)	офіційний протокол DCASE	AUC, pAUC
DCASE'21 T2	4	виявлення аномалій (без нагляду)	офіційний протокол DCASE з domain shift (source/target)	AUC, pAUC
IMS	5, 6, 7	класифікація станів або прогнозований залишковий ресурс	leave-one-run/bearing-out (рекоменд.)	Accuracy, F1; RMSE, MAE
CWRU	5, 8, 10, 12	класифікація дефектів	k-fold або fixed train/test; cross-load/speed (рекоменд.)	Accuracy, F1
SEU/DDS	10, 12	класифікація (4-клас підшипник / 5-клас редуктор)	умови 20-0 / 30-2; cross-condition (рекоменд.)	Accuracy, F1
Paderborn/KAt	11, 13	класифікація станів	мультимодальність (ACC+MCSA); leave-one-bearing-out або cross-mode	Accuracy, F1
JNU	12	класифікація станів	multi-speed (600–1000 rpm); open-set (за потреби)	Accuracy, F1
PHM2009	12	класифікація станів редуктора	офіційний протокол PHM (p0–p5)	Accuracy, F1
MFPT	14	класифікація станів підшипника	стенд/польові піднабори; unit-wise або cross-load	Accuracy, F1
MaFaulDa	15	класифікація станів вузлів привода	multi-condition; multi-sensor	Accuracy, F1
Purdue Motor	17	класифікація рівня дефекту	transfer Piezo↔MEMS; cross-RPM	Accuracy, F1
UCI NIL	16	класифікація/регресія станів компонентів	cycle-wise; cross-condition (за потреби)	Accuracy, F1; MAE, RMSE

Джерело: розроблено авторами

Окрему групу становлять роботи, де використано власні експериментальні дані без будь-яких механізмів доступу для сторонніх дослідників (ані публічних архівів, ані

надання «за запитом»). При цьому типовими прикладами є лабораторні стенди для випробувань підшипників і редукторів із детально описаною апаратурою та режимами, але без репозиторіїв даних і без розділу Data Availability: [20] (аграрний контекст, підшипники та вібрації), [21] (вібродіагностика ротора на стенді, класичні ознаки + ML), [9] (приклад хвильових ознак у діагностиці роторів) та [22] (нейромережевий підхід з власними вимірами). Повна закритість отриманих наборів даних унеможливорює незалежну перевірку й пряме порівняння методів. У методологічній частині підкреслюється, що такі публікації корисні для ідей і схем вимірювань, але не формують відтворюваних еталонів і мають обмежену цінність для бенчмаркінгу архітектур обробки даних технічного стану ММАПВ.

Отже, проведений аналіз наявних джерел даних, релевантних інтелектуальній оцінці технічного стану вузлів і механізмів ММАПВ, засвідчив їхню кількісну обмеженість і фрагментарність. Крім того, не виявлено усталеної практики надання закріплених обчислювальних середовищ (Python/R/MATLAB), що гарантували б повну відтворюваність опублікованих результатів. Крім цього, доцільно супроводжувати майбутні публікації файлами залежностей (lock-files) або контейнерними образами та мінімальними інструкціями відтворення.

Постановка завдання. Метою даної роботи є обґрунтування науково-методичних засад формування та використання наборів сенсорних даних для інтелектуальної оцінки технічного стану мобільних машин агропромислового виробництва та обґрунтування референтної архітектури збору та управління даними в умовах підприємств АПК, з урахуванням польових сценаріїв.

Для досягнення мети розв'язуються наступні завдання:

1. Систематизувати доступні джерела даних, виконати їх структурований опис за типами сигналів, об'єктами контролю, умовами збирання інформації про технічний стан, частотою та форматом, і виявити ключові прогалини.

2. Визначити вимоги й мінімально достатню структуру «паспорта датасету» для ММАПВ: перелік сигналів і робочих частот, еталонні режими навантаження, правила маркування станів і відмов, обов'язкові метадані (машина, експлуатаційний контекст, сервісні події), критерії якості та відтворюваності, а також вимоги до відкритості, конфіденційності та ліцензування;

3. Запропонувати референтну архітектуру збору, передачі, зберігання та підготовки даних для інтелектуальної системи технічного сервісу (ICTS) ММАПВ і надати практичні рекомендації щодо поетапного впровадження в виробничих та польових умовах.

Виклад основного матеріалу. Моніторинг і обслуговування за станом (CBM – condition-based maintenance) у цій роботі розглядаються як базовий підхід до підтримання працездатності мобільних машин агропромислового виробництва. Методична основа спирається на референтну функціональну архітектуру OSA-CBM у відповідності до стандарту ISO 13374 (рівні від знімання даних і первинної обробки до виявлення станів, оцінювання «здоров'я», прогнозування залишкового ресурсу та формування рекомендацій). Для навчання й валідації алгоритмів використовуються еталонні мітки істини (ground truth), що походять із зовнішніх джерел (акти дефектування, журнали технічного обслуговування, сервісні записи) і забезпечують коректну прив'язку подій і станів.

У межах цієї рамки запропоновано узгоджений підхід до побудови сенсорних наборів даних у логіці «від глобального до детального»: від пріоритизації парку та відбору критичних вузлів до архітектури збору й управління даними, стійкої до

перебоїв зв'язку, і подальшого оброблення відповідно до OSA-CBM/ISO 13374. Сукупність рішень узагальнено трьома блок-схемами (рис. 1–3).

Першочерговим етапом є ранжування об'єктів спостереження. На рівні парку мобільних машин виокремлюються класи машин: трактори, комбайни, обприскувачі, автотранспорт тощо. Для кожного класу визначаються критичні вузли, виконується спрощена оцінка ризиків (light-FMEA) та економічних наслідків. За підсумками оцінювання визначається узагальнений бал і формується карта пріоритетів A/B/C. Для вузлів категорії A складають стислий план вимірювань: перелік потрібних сигналів, місця встановлення датчиків, робочі частоти, правила синхронізації часу та мітки подій. Відповідну логіку пріоритизації парку та формування мінімального плану сенсоризації відображено на рис. 1. Архітектуру збору й управління даними наведено на рис. 2. Блок-схему оброблення даних і підтримки рішень відповідно до OSA-CBM/ISO 13374 представлено на рис. 3.




Рисунок 1 – Блок-схема пріоритизації моніторингу парку ММАПВ

Джерело: розроблено авторами




Рисунок 2 – Блок-схема архітектури збору та управління даними сенсорів.

Джерело: розроблено авторами



Рисунок 3 – Блок-схема архітектури CBM за ISO 13374 (OSA-CBM)

Джерело: розроблено авторами

Пріоритизація моніторингу парку реалізується з виділенням підмножин машин та їхніх вузлів, моніторинг яких дає найбільший ефект з погляду запобігання відмовам і

скорочення простоїв. На рівні парку формалізується склад класів машин. Для кожного класу за участі експлуатаційних фахівців визначаються критичні вузли та механізми, фіксуються найбільш імовірні режими відмов і ключові діагностичні симптоми. Ці вузли стають кандидатами на первинну сенсоризацію та подальше включення в архітектуру збору даних.

Оцінювання виконується за багатокритеріальною моделлю зі зважуванням факторів: тяжкість наслідків відмови і простоїв; імовірність настання; детектовність відповідними сенсорами; сезонність й навантаження; регуляторні та безпекові вимоги; економіка простою. Інтегральний бал переводиться у категорії А/В/С (високий, середній, базовий пріоритет) із фіксацією порогів для прозорості прийняття рішень. Зазначимо, що для категорії А формулюється мінімальний план вимірювань (цільові сигнали, точки встановлення, частоти, синхронізація, мітки подій), який безпосередньо живить подальші етапи.

Очікуваними артефактами етапу є: матриця «клас машини – вузол» із позначенням рівнів пріоритету; компактна таблиця light-FMEA (вузол → типова відмова → симптом → орієнтовні сигнали і сенсори); перелік вузлів категорії А з коротким планом сенсоризації. При цьому узагальнений робочий потік відображено на рис. 1.

Архітектура реалізує принцип offline-first (архітектурний підхід, що гарантує безперервне знімання, локальне буферування та відкладену доставку даних за нестійкого зв'язку) й забезпечує тяглість телеметрії в польових умовах. На польовому рівні сенсори під'єднано до вузла збору даних на краю мережі (Edge/DAQ — edge data acquisition) з єдиним часом, синхронізованим за супутниковими навігаційними системами та мережевим протоколом часу (GNSS/NTP), і з мітками подій. Дані міжканально синхронізуються та записуються у локальний буфер. За відсутності зв'язку спрацьовує механізм store-and-forward (накопичення у черзі та гарантована повторна доставка з контролем дублювання), що спирається на ідемпотентний прийом. Передача до центрального контуру виконується протоколами з низькими накладними витратами – MQTT або HTTP(S) із керованими політиками ретрансляції та безпеки.

У центрі дані завантажуються до сховища часових рядів (TSDB) і репозиторію, що зберігає великі обсяги даних різного типу (Data Lake) з логічним поділом на сирі дані, оброблені дані, мітки та метадані. Поверх сховища працює каталог (реєстр) метаданих, у якому зберігається «паспорт датасету» (ідентифікація, канали, частоти, схеми міток, версії ПЗ/прошивок, умови ліцензування); тут же фіксуються походження даних (lineage) та версіювання релізів. Базові політики конфіденційності й доступу (анонімізовані ідентифікатори, контроль прав) задаються на рівні каталогу, що мінімізує ризики витоків чутливих атрибутів.

Шар підготовки даних (ETL – екстракція, трансформація та завантаження) очищує записи, узгоджує час, синхронізує канали й ділить потоки на вікна з урахуванням подій і станів; сформовані вибірки публікуються у вигляді версійованих релізів для конвеєра машинного навчання (ML-пайплайна). Зв'язок із системою управління технічним обслуговуванням (CMMS) двосторонній: журнали ТО й акти дефектування формують еталонні мітки, а виходи моделей повертаються як діагностичні показники. Для кожного релізу діють приймальні критерії якості (покриття, відношення сигналу до шуму, пропуски, баланс класів), що забезпечує відтворюваність.

Розглядаючи функціональну архітектуру слід зазначити, що вона узгоджена з ISO 13374 (профіль OSA-CBM) та визначає послідовність перетворень від «сирих» потоків до керувальних впливів. Рівень знімання даних (Data Acquisition) забезпечує єдиний час, первинну валідацію та доставку у сховище. Підготовка даних (Data Manipulation)

виконує наступні функції: нормалізація, синхронізація каналів; видалення артефактів; стандартна сегментація та формування ознак; чітке версіювання результатів.

На рівні виявлення стану (State Detection) реалізуються алгоритми контролю аномалій і класифікації станів (норма, перехід, деградація, відмова) з використанням міток подій і сервісних даних як ground truth. Оцінка технічного стану (Health Assessment) при цьому агрегує висновки по вузлах і формує інтегральні індикатори придатності в контексті режиму експлуатації. Блок прогнозування (Prognostics) оцінює залишковий ресурс та ймовірність відмови на горизонті планування; закладається можливість поєднання фізичних і даних-орієнтованих моделей.

Завершальний рівень — рекомендації/відображення (Advisory/Presentation) — транслює оцінки в дії: попередження, порогові тригери CBM, завдання у CMMS, а також зворотний зв'язок для уточнення міток і покращення моделей. Для кожного рівня визначено вхід і вихід, формат інтерфейсу й мінімальні метрики якості: затримка, частка пропусків, точність і recall (повнота) для станів, MAE (Mean Absolute Error), CRPS (Continuous Ranked Probability Score) для прогнозованого залишкового ресурсу, що забезпечує відтворюваність та порівнянність реалізацій (рис. 3).

Дослідження показало, що для відтворюваності та порівнянності результатів кожен реліз даних супроводжується «паспортом» мінімального складу: ідентифікація та версія; об'єкт та межі застосування (клас машини, вузол, сценарій); канали й частоти знімання, синхронізація часу та мітки подій; схема маркування станів і джерела ground truth; опис препроцесингу й версій програмного забезпечення; умови доступу й ліцензування та правила анонімізації.

Пропонується контроль якості релізу (acceptance gates), який полягає в наступному:

- покриття режимів – наявність репрезентативних інтервалів «норма, перехід, деградація» для вибраних вузлів;
- синхронізація каналів – похибка не більше ~ 5 мс між високочастотними каналами; узгоджені таймштампи;
- пропуски й артефакти — не більш як ~ 1 % пропусків на канал після очищення; задокументовані методи обробки артефактів;
- якість сигналу – мінімальні вимоги до відношення сигналу до шуму та до спектральних показників, а також відсутність систематичного зсуву та дрейфу;
- класовий баланс і відтворюваність – бажано, щоб дисбаланс не перевищував орієнтовно 10:1, а якщо це неможливо, то слід описати обрану процедуру балансування;
- дані мають надходити щонайменше з кількох машин або кількох циклів роботи;
- версіювання та походження – застосовуються семантичні версії з коротким журналом змін і фіксацією ланцюга перетворень (lineage) для кожного релізу.

Висновки. 1. Запропоновано та апробовано методологічний підхід до формування та використання сенсорних даних для інтелектуальної оцінки технічного стану мобільних машин агропромислового виробництва, що узгоджено з логікою «від глобального до детального» і профілем OSA-CBM/ISO 13374. Підхід забезпечує відтворюваність та придатність даних до застосування у задачах діагностики, прогнозування та підтримки прийняття рішень у сервісних процесах підприємств агропромислового комплексу.

2. Систематизовано доступні джерела даних, зібрано та структуровано публічні набори даних, узагальнено непрямі і закриті джерела; показано дефіцит даних саме для оцінки технічного стану вузлів мобільних машин агропромислового виробництва.

3. Визначено вимоги до наборів даних та сформовано «паспорт датасету» мінімального складу (сигнали, частоти, синхронізація та мітки, ground truth, метадані, правовий режим), а також задано приймальні критерії (acceptance gates) для релізів.

4. Запропоновано референтну архітектуру offline-first для збору та управління даними (польовий рівень → транспорт → TSDB/Data Lake → каталог → ETL → ML-контур → CMMS) та функціональну блок-схему CBM за ISO 13374, що разом зі схемою пріоритизації утворюють узгоджений конвеєр.

Список літератури

1. Аулін В. В., Гриньків А. В., Головатий А. О., Лисенко С. В., Голуб Д. В., Кузик О. В., Тихий А. А. Методологічні основи проектування та функціонування інтелектуальних транспортних і виробничих систем: монографія під заг. ред. д.т.н., проф. Ауліна В. В. Кропивницький: Видавець Лисенко В. Ф., 2020. 428с.
2. Матвієнко О. О., Аулін В. В. Класифікація типів сигналів та методів машинного навчання для інтелектуальної оцінки технічного стану мобільних машин підприємств агропромислового виробництва. *Збірник наукових праць. Науковий вісник. Технічні науки*. 2025. № 11(42)_II. С. 298–312. DOI: 10.32515/2664-262X.2025.11(42).2.298-312.
3. Wang Y., Zheng Y., Zhang Y., Xie Y., Xu S., Hu Y., He L. Unsupervised anomalous sound detection for machine condition monitoring using classification-based methods. *Applied Sciences*. 2021. Vol. 11, No. 23. 11128. DOI: 10.3390/app112311128.
4. Cheng T., Guo F. Machine anomalous sound detection based on audio synthesis generative adversarial network. *Journal of Physics: Conference Series*. 2024. Vol. 2816, No. 1. 012041. DOI: 10.1088/1742-6596/2816/1/012041.
5. Khorram A., Khalooei M., Rezghi M. End-to-end CNN + LSTM deep learning approach for bearing fault diagnosis. *Applied Intelligence*. 2021. Vol. 51, No. 2. P. 736–751. DOI: 10.1007/s10489-020-01859-1.
6. Chegini S. N., Manjili M. J. H., Bagheri A. New fault diagnosis approaches for detecting the bearing slight degradation. *Meccanica*. 2020. Vol. 55, No. 1. P. 261–286. DOI: 10.1007/s11012-019-01116-x.
7. Brito L. C., Susto G. A., Brito J. N., Duarte M. A. V. Fault detection of bearing: An unsupervised machine learning approach exploiting feature extraction and dimensionality reduction. *Informatics*. 2021. Vol. 8, No. 4. 85. DOI: 10.3390/informatics8040085.
8. Attaran B., Ghanbarzadeh A., Moradi S. A novel intelligent fault diagnosis approach for critical rotating machinery in the time-frequency domain. *International Journal of Engineering. Transactions C: Aspects*. 2020. Vol. 33, No. 4. P. 668–675. DOI: 10.5829/ije.2020.33.04a.18.
9. Bouaouiche K., Menasria Y., Khalfa D. Diagnosis of rotating machine defects by vibration analysis. *Acta IMEKO*. 2023. Vol. 12, No. 1. P. 1–6. DOI: 10.21014/actaimeko.v12i1.1438.
10. Singh M. T. Graph-based fault diagnosis for rotating machinery: Adaptive segmentation and structural feature integration. *arXiv preprint*. 2025. arXiv:2504.20756. URL: <https://arxiv.org/abs/2504.20756>.
11. Matania O., Bachar L., Bechhoefer E., Bortman J. Signal processing for the condition-based maintenance of rotating machines via vibration analysis: A tutorial. *Sensors*. 2024. Vol. 24, No. 2. 454. DOI: 10.3390/s24020454.
12. Zhang B., Zhou C., Li W., Ji S., Li H., Tong Z., Ng S.-K. Intelligent bearing fault diagnosis based on open set convolutional neural network. *Mathematics*. 2022. Vol. 10, No. 21. 3953. DOI: 10.3390/math10213953.
13. Lessmeier C., Kimotho J. K., Zimmer D., Sextro W. Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification. In: *Proceedings of the European Conference of the Prognostics and Health Management Society 2016 (PHME 2016)*, 5–8 July 2016, Bilbao, Spain. PHM Society, 2016. URL: <https://papers.phmsociety.org/index.php/phme/article/view/1577>.
14. Saad A., Usman A., Arif S., Liwicki M., Almqvist A. Bearing fault detection scheme using machine learning for condition monitoring applications. In: *Proceedings of the International Conference on Mechanical, Automotive and Mechatronics Engineering (ICMAME 2023)*, 29–30 April 2023, Dubai, UAE. 2023. URL: <https://www.diva-portal.org/smash/get/diva2:1793876/FULLTEXT01.pdf>.
15. Ignjatovska A., Shishkovski D., Pecioski D. Classification of present faults in rotating machinery based on time and frequency domain feature extraction. *Vibroengineering Procedia*. 2023. Vol. 51. P. 22–28. DOI: 10.21595/vp.2023.23667.
16. Zhang D., Zheng K., Liu F., Li B. Fault diagnosis of hydraulic components based on multi-sensor information fusion using improved TSO-CNN-BiLSTM. *Sensors*. 2024. Vol. 24, No. 8. 2661. DOI: 10.3390/s24082661.
17. Abdallah M., Joung B.-G., Lee W. J., Mousoulis C., Raghunathan N., Shakouri A., Sutherland J. W., Bagchi S. Anomaly detection and inter-sensor transfer learning on smart manufacturing datasets. *Sensors*. 2023. Vol. 23, No. 1. 486. DOI: 10.3390/s23010486.
18. Ciaburro G., Iannace G. Machine-learning-based methods for acoustic emission testing: A review. *Applied Sciences*. 2022. Vol. 12, No. 20. 10476. DOI: 10.3390/app122010476.

19. Rahman A., Hoque M. E., Rashid F., Alam F., Ahmed M. M. Health condition monitoring and control of vibrations of a rotating system through vibration analysis. *Journal of Sensors*. 2022. Article ID 4281596. DOI: 10.1155/2022/4281596.
20. Kateris D., Moshou D., Gialamas T., Gravalos I., Xyradakis P. Bearing fault diagnosis in mechanical gearbox, based on time and frequency-domain parameters with MLP-ARD. *Journal of Agricultural Machinery Science*. 2014. Vol. 10, No. 2. P. 101–106. URL: <https://dergipark.org.tr/tr/download/article-file/558529>.
21. Elsamanty M. M., Salman W. S., Ibrahim A. A. Fault diagnosis of rotary machines based on vibration signature and machine learning algorithm. *Engineering Research Journal (Shoubra)*. 2021. Vol. 50, No. 1. P. 41–47. DOI: 10.21608/erjsh.2021.225704.
22. Oulmane A., Lakis A. A., Mureithi N. W. Application of Fourier descriptors and artificial neural network to bearing vibration signals for fault detection and classification. *Universal Journal of Aeronautical & Aerospace Sciences*. 2014. Vol. 2. P. 37–54. URL: <https://www.papersciences.com/Oulmane-Univ-J-Aer-Aerosp-Scien-Vol2-2014-3.pdf>.
23. Koizumi Y., Kawaguchi Y., Imoto K., Nakamura T., Nikaido Y., Tanabe R., Purohit H., Suefusa K., Endo T., Yasuda M., Harada N. DCASE 2020 Challenge Task 2 Development Dataset. Version 1.0. [Dataset]. Zenodo. 2020. DOI: 10.5281/zenodo.3678171.
24. Kawaguchi Y., Imoto K., Koizumi Y., Harada N., Niizumi D., Dohi K., Tanabe R., Purohit H., Endo T. DCASE 2021 Challenge Task 2 Development Dataset. Version 1.0. [Dataset]. Zenodo. 2021. DOI: 10.5281/zenodo.4562016.
25. National Aeronautics and Space Administration (NASA). IMS Bearings. [Dataset]. NASA Open Data Portal. 2023. URL: <https://data.nasa.gov/dataset/ims-bearings> (дата звернення: 1.09.2025).
26. Case Western Reserve University Bearing Data Center : веб-сайт. URL: <https://engineering.case.edu/bearingdatacenter> (дата звернення: 1.09.2025).
27. Cathy Siyu. Mechanical-datasets. [Dataset]. GitHub. URL: <https://github.com/cathysiyu/Mechanical-datasets> (дата звернення: 1.09.2025).
28. Paderborn University, Chair of Design and Drive Technology (KAT). Bearing Datacenter: Data sets and download. [Dataset]. URL: <https://mb.uni-paderborn.de/kat/forschung/kat-datacenter/bearing-datacenter/data-sets-and-download> (дата звернення: 1.09.2025).
29. Clark Gable Wang. JNU-Bearing-Dataset. [Dataset]. GitHub. URL: <https://github.com/ClarkGableWang/JNU-Bearing-Dataset> (дата звернення: 1.09.2025).
30. Prognostics and Health Management Society (PHM Society). Public data sets : веб-сторінка. URL: <https://phmsociety.org/public-data-sets/> (дата звернення: 1.09.2025).
31. Society for Machinery Failure Prevention Technology (MFPT). Fault data sets : веб-сторінка. URL: <https://www.mfpt.org/fault-data-sets/> (дата звернення: 1.09.2025).
32. josh101. Machinery Fault Database — Induction Motor Fault. [Dataset]. Kaggle. URL: www.kaggle.com/datasets/josh101/machinery-fault-database-induction-motor-fault (дата звернення: 1.09.2025).
33. Purdue University. Purdue Motor dataset. [Dataset]. Google Drive. URL: drive.google.com/drive/u/2/folders/1QX3chnSTKO3PsEhi5kBd9WwMBmOriJ8 (дата звернення: 1.09.2025).
34. UCI Machine Learning Repository. Condition monitoring of hydraulic systems. [Dataset]. University of California, Irvine. URL: archive.ics.uci.edu/dataset/447/condition+monitoring+of+hydraulic+systems (дата звернення: 1.09.2025).

References

1. Aulin, V. V., Hryniv, A. V., Holovaty, A. O., Lysenko, S. V., Holub, D. V., Kuzyk, O. V., & Tykhyi, A. A. (2020). Methodological foundations of design and operation of intelligent transportation and manufacturing systems. Lysenko V.F. [in Ukrainian].
2. Matviienko, O. O., Aulin V.V. (2025). *Classification of signal types and machining methods for intelligent assessment of the technical mill of mobile machines for agro-industrial production*. *Central Ukrainian Scientific Bulletin. Technical Sciences*, (11(42)_II), 298–312. [https://doi.org/10.32515/2664-262X.2025.11\(42\).2.298-312](https://doi.org/10.32515/2664-262X.2025.11(42).2.298-312) [in Ukrainian].
3. Wang, Y., Zheng, Y., Zhang, Y., Xie, Y., Xu, S., Hu, Y., & He, L. (2021). *Unsupervised anomalous sound detection for machine condition monitoring using classification-based methods*. *Applied Sciences*, 11(23), 11128. <https://doi.org/10.3390/app112311128>
4. Cheng, T., & Guo, F. (2024). *Machine anomalous sound detection based on audio synthesis generative adversarial network*. *Journal of Physics: Conference Series*, 2816(1), 012041. <https://doi.org/10.1088/1742-6596/2816/1/012041>
5. Khorram, A., Khalooei, M., & Rezghi, M. (2021). *End-to-end CNN + LSTM deep learning approach for bearing fault diagnosis*. *Applied Intelligence*, 51(2), 736–751. <https://doi.org/10.1007/s10489-020-01859-1>
6. Chagini, S. N., Manjili, M. J. H., & Bagheri, A. (2020). *New fault diagnosis approaches for detecting the bearing slight degradation*. *Meccanica*, 55(1), 261–286. <https://doi.org/10.1007/s11012-019-01116-x>

7. Brito, L. C., Susto, G. A., Brito, J. N., & Duarte, M. A. V. (2021). *Fault detection of bearing: An unsupervised machine learning approach exploiting feature extraction and dimensionality reduction. Informatics*, 8(4), 85. <https://doi.org/10.3390/informatics8040085>
8. Attaran, B., Ghanbarzadeh, A., & Moradi, S. (2020). *A novel intelligent fault diagnosis approach for critical rotating machinery in the time-frequency domain. International Journal of Engineering, Transactions C: Aspects*, 33(4), 668–675. <https://doi.org/10.5829/ije.2020.33.04a.18>
9. Bouaouiche, K., Menasria, Y., & Khalfa, D. (2023). *Diagnosis of rotating machine defects by vibration analysis. Acta IMEKO*, 12(1), 1–6. <https://doi.org/10.21014/actaimeko.v12i1.1438>
10. Singh, M. T. (2025). *Graph-based fault diagnosis for rotating machinery: Adaptive segmentation and structural feature integration. arXiv*. <https://arxiv.org/abs/2504.20756>
11. Matania, O., Bachar, L., Bechhoefer, E., & Bortman, J. (2024). *Signal processing for the condition-based maintenance of rotating machines via vibration analysis: A tutorial. Sensors*, 24(2), 454. <https://doi.org/10.3390/s24020454>
12. Zhang, B., Zhou, C., Li, W., Ji, S., Li, H., Tong, Z., & Ng, S.-K. (2022). *Intelligent bearing fault diagnosis based on open set convolutional neural network. Mathematics*, 10(21), 3953. <https://doi.org/10.3390/math10213953>
13. Lessmeier, C., Kimotho, J. K., Zimmer, D., & Sextro, W. (2016). *Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification. In Proceedings of the European Conference of the Prognostics and Health Management Society 2016 (PHME 2016), Bilbao, Spain. PHM Society. https://papers.phmsociety.org/index.php/phme/article/view/1577*
14. Saad, A., Usman, A., Arif, S., Liwicki, M., & Almqvist, A. (2023, April 29–30). *Bearing fault detection scheme using machine learning for condition monitoring applications. In Proceedings of the International Conference on Mechanical, Automotive and Mechatronics Engineering (ICMAME 2023), Dubai, United Arab Emirates. https://www.diva-portal.org/smash/get/diva2:1793876/FULLTEXT01.pdf*
15. Ignjatovska, A., Shishkovski, D., & Pecioski, D. (2023, October 20–21). *Classification of present faults in rotating machinery based on time and frequency domain feature extraction. Vibroengineering Procedia*, 51, 22–28. <https://doi.org/10.21595/vp.2023.23667>
16. Zhang, D., Zheng, K., Liu, F., & Li, B. (2024). *Fault diagnosis of hydraulic components based on multi-sensor information fusion using improved TSO-CNN-BiLSTM. Sensors*, 24(8), 2661. <https://doi.org/10.3390/s24082661>
17. Abdallah, M., Joung, B.-G., Lee, W. J., Mousoulis, C., Raghunathan, N., Shakouri, A., Sutherland, J. W., & Bagchi, S. (2023). *Anomaly detection and inter-sensor transfer learning on smart manufacturing datasets. Sensors*, 23(1), 486. <https://doi.org/10.3390/s23010486>
18. Ciaburro, G., & Iannace, G. (2022). *Machine-learning-based methods for acoustic emission testing: A review. Applied Sciences*, 12(20), 10476. <https://doi.org/10.3390/app122010476>
19. Rahman, A., Hoque, M. E., Rashid, F., Alam, F., & Ahmed, M. M. (2022). *Health condition monitoring and control of vibrations of a rotating system through vibration analysis. Journal of Sensors*, 2022, Article 4281596. <https://doi.org/10.1155/2022/4281596>
20. Kateris, D., Moshou, D., Gialamas, T., Gravalos, I., & Xyradakis, P. (2014). *Bearing fault diagnosis in mechanical gearbox, based on time and frequency-domain parameters with MLP-ARD. Journal of Agricultural Machinery Science*, 10(2), 101–106. <https://dergipark.org.tr/tr/download/article-file/558529>
21. Elsamanty, M. M., Salman, W. S., & Ibrahim, A. A. (2021). *Fault diagnosis of rotary machines based on vibration signature and machine learning algorithm. Engineering Research Journal (Shoubra)*, 50(1), 41–47. <https://doi.org/10.21608/erjsh.2021.225704>
22. Oulmane, A., Lakis, A. A., & Mureithi, N. W. (2014). *Application of Fourier descriptors and artificial neural network to bearing vibration signals for fault detection and classification. Universal Journal of Aeronautical & Aerospace Sciences*, 2, 37–54. www.papersciences.com/Oulmane-Univ-J-Aer-Aerosp-Scien-Vol2-2014-3.pdf
23. Koizumi, Y., Kawaguchi, Y., Imoto, K., Nakamura, T., Nikaido, Y., Tanabe, R., Purohit, H., Suefusa, K., Endo, T., Yasuda, M., & Harada, N. (2020, March 1). *DCASE 2020 Challenge Task 2 Development Dataset (Version 1.0) [Dataset]. Zenodo. https://doi.org/10.5281/zenodo.3678171*
24. Kawaguchi, Y., Imoto, K., Koizumi, Y., Harada, N., Niizumi, D., Dohi, K., Tanabe, R., Purohit, H., & Endo, T. (2021, March 1). *DCASE 2021 Challenge Task 2 Development Dataset (Version 1.0) [Dataset]. Zenodo. https://doi.org/10.5281/zenodo.4562016*
25. National Aeronautics and Space Administration. (2023, November 2). *IMS Bearings [Dataset]. NASA Open Data Portal. https://data.nasa.gov/dataset/ims-bearings*
26. Case Western Reserve University. (n.d.). *Bearing Data Center. Case School of Engineering. https://engineering.case.edu/bearingdatacenter*

27. Cathy Siyu. (n.d.). *Mechanical-datasets* [Dataset]. GitHub. github.com/cathysiyu/Mechanical-datasets.
28. Paderborn University, Chair of Design and Drive Technology (KAT). (n.d.). *Bearing Datacenter: Data sets and download* [Dataset]. mb.uni-paderborn.de/kat/forschung/kat-datacenter/bearing-datacenter/data-sets-and-download
29. Clark Gable Wang. (n.d.). *JNU-Bearing-Dataset* [Dataset]. GitHub. github.com/ClarkGableWang/JNU-Bearing-Dataset.
30. Prognostics and Health Management Society. (n.d.). *Public data sets*. PHM Society. phmsociety.org/public-data-sets/.
31. Society for Machinery Failure Prevention Technology. (n.d.). *Fault data sets*. MFPT. www.mfpt.org/fault-data-sets/.
32. josh101. (n.d.). *Machinery Fault Database — Induction Motor Fault* [Dataset]. Kaggle. www.kaggle.com/datasets/josh101/machinery-fault-database-induction-motor-fault.
33. Purdue University. (n.d.). *Purdue Motor dataset* [Dataset]. Google Drive. <https://drive.google.com/drive/u/2/folders/1QX3chnSTKO3PsEhi5kBdf9WwMBmOriJ8>.
34. UCI Machine Learning Repository. (n.d.). Condition monitoring of hydraulic systems [Dataset]. University of California, Irvine. <https://archive.ics.uci.edu/dataset/447/condition+monitoring+of+hydraulic+systems>.

Oleksandr Matviienko Assoc. Prof., PhD tech. sci., **Viktor Aulin**, Prof., Dr. tech. sci.,
Andriy Grynkiy, Sr. Researcher, PhD tech. sci.

Central Ukrainian National Technical University, Kropyvnytskyi, Ukraine

Status and Development Directions of Data Architecture for Intelligent Assessment of the Technical Condition of Mobile Machines of Agro-Industrial Enterprises

This article provides a critical survey and a practical method for assembling sensor datasets that support intelligent assessment of the technical condition of mobile agricultural machines. The survey maps available sources and shows that domain-relevant datasets are scarce, fragmented, and rarely documented with stable collection procedures. To address these gaps, the paper proposes a coherent “global to detail” pathway that links fleet decisions, field acquisition, and analytics into a reproducible blueprint.

The pathway begins with fleet-level prioritization that identifies machine classes and critical components, outlines typical failure modes and observable symptoms, and balances severity, likelihood, detectability, seasonal load, safety, and downtime costs. The result is a prioritized roadmap for sensor installation and a compact measurement plan specifying signals, installation points, sampling frequencies, and event time-stamping.

Data collection and management follow an offline-first architecture suitable for unstable connectivity in fields. Sensors feed an edge acquisition unit with unified time derived from global navigation satellite systems and the network time protocol; measurements are buffered locally and delivered with store-and-forward when links reappear, using lightweight message transports such as message queue telemetry and secure hypertext transfer. In the central environment, data land in a time-series repository or data lake governed by a metadata catalog that records dataset passports, provenance, versions, privacy and access rules, and licensing terms. A preprocessing layer performs extraction, transformation and loading, cleans artifacts, harmonizes time, and segments streams into versioned releases for model development.

Analytics follow the functional reference defined by the ISO 13374 for condition monitoring: acquisition, manipulation, state detection, health assessment, prognostics with remaining useful life estimation, and advisory generation with integration into computerized maintenance management systems. Each dataset release carries a minimal passport and acceptance gates that verify regime coverage, synchronization accuracy, limits on missing data, signal-to-noise quality, class balance, and explicit lineage with semantic versioning. The survey also found no sources providing pinned computational environments that guarantee full reproducibility; future publications should include dependency lock files or container images and concise replication guides.

mobile machines, agricultural production, intelligent system, technical service, machine learning, predictive technical maintenance, multisensory diagnostics, diagnostic signals, anomaly detection

Одержано (Received) 15.09.2025

Прорецензовано (Reviewed) 18.09.2025

Прийнято до друку (Approved) 19.09.2025