

УДК 629.064:631.372:004.8 [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)

О. О. Матвієнко, доц., канд. техн. наук, **В. В. Аулін**, проф., д-р техн. наук
Центральноукраїнський національний технічний університет, м. Кропивницький, Україна
e-mail: AulinVV@gmail.com

Класифікація типів сигналів та методів машинного навчання для інтелектуальної оцінки технічного стану мобільних машин підприємств агропромислового виробництва

У статті подано критичний огляд сучасних досліджень щодо застосування методів машинного навчання (МН) для визначення технічного стану вузлів і механізмів мобільних машин агропромислового виробництва (ММАПВ) за різнотиповими діагностичними сигналами (вібраційними, акустичними, температурними, тисковими тощо). Показано обмеження порогових стратегій діагностики та обґрунтовано необхідність інтелектуальної системи технічного сервісу, що поєднує сенсорну базу й адаптивні алгоритми МН для онлайн-оцінювання стану, прогностного обслуговування і мінімізації непередбачуваних простоїв. Запропоновано концепцію комплексної класифікації сигналів і вибору алгоритмів і створює підґрунтя для масштабованих рішень, адаптованих до специфічних викликів ММАПВ.

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

Постановка проблеми. Зростаюча складність мобільних машин (ММ) в агропромисловому виробництві (АВП) призвела до значних труднощів у процесах їх обслуговування та діагностики. Ці машини працюють в різноманітних умовах навколишнього середовища та піддаються різним навантаженням, що може призвести до непередбачуваних відмов. Традиційні стратегії технічного обслуговування (ТО) часто базуються на заздалегідь визначених графіках або реактивних заходах, які є недостатніми для врахування динамічного характеру цих систем [1]. Відсутність можливостей діагностики в режимі реального часу та недостатня інтеграція між даними датчиків та алгоритмами машинного навчання (МН) ще більше погіршують неефективність сучасних систем ТО.

Одним з основних обмежень існуючих підходів є залежність від кількох порогових значень, які визначають робочі параметри та терміни для початку дій з ТО. Хоча ці порогові значення забезпечують основу для оцінки оптимального часу для ТО, вони не враховують дані датчиків у режимі реального часу, що є критично важливим для точної діагностики. Крім того, ці методи часто припускають, що дані про відмови ідентичних компонентів відповідають одному й тому ж статистичному розподілу, що не відповідає дійсності у багатьох практичних сценаріях [22]. Це спрощення призводить до неоптимального прийняття рішень та збільшує ризик непередбачуваних простоїв машин.

Аналіз останніх досліджень і публікацій. Виявлено, що процес діагностики мобільних агропромислових машин страждає від відсутності стандартизації методів класифікації сигналів та вилучення ознак. Моделі з некерованим навчанням, такі як автокодувальники, метод головних компонент (РСА), k-найближчих сусідів (KNN) та нормалізуючий потік, зазвичай використовуються, але обмежуються навчанням на нормальних робочих звуках. Ці моделі не використовують позначені набори даних з кількома

категоріями несправностей, що обмежує їх здатність ефективно виявляти аномалії. З іншого боку, моделі на основі класифікації намагаються вирішити цю проблему шляхом перетворення виявлення аномалій у контрольовані або напівконтрольовані завдання за допомогою додаткових наборів даних. Однак цей підхід вимагає великих позначених даних, які часто недоступні або важко отримати в агропромислових умовах [32].

Ще одна критична проблема полягає в системах моніторингу, які зараз використовуються для діагностики несправностей у таких компонентах, як редуктори та підшипники. Хоча деякі експериментальні установки продемонстрували здатність виявляти певні проблеми в цих компонентах, вони залишаються обмеженими за обсягом та масштабованістю.

Діагностичні методи на основі звуку показали свою перспективність у виявленні відмов промислових машин шляхом поєднання виявлення аномалій з методами класифікації. Такі системи, як AudioForesight, використовують заздалегідь визначені класи помилок для моніторингу та ідентифікації відмов системи на основі акустичних сигналів. Однак ці методи обмежені своєю залежністю від заздалегідь визначених категорій помилок, які можуть не охоплювати всі можливі режими відмов, що виникають під час роботи машини [35]. Крім того, досліджувалися досягнення в методах вилучення ознак, таких як Log-Mel спектрограми, для певних типів машин, таких як повзунки та клапани, але вони потребують подальшого вдосконалення для узагальнення для різних категорій машин [30].

Алгоритми машинного навчання відіграють вирішальну роль у підвищенні точності діагностики, але стикаються з проблемами, пов'язаними з вибором ознак та інтерпретацією моделей. Різниця між різними алгоритмами часто впливає з їхніх унікальних підходів до перетворення ознак та ідентифікації несправностей. Аналіз першопричин є важливим для усунення нерелевантних ознак та спрямування фахівців на точне визначення поточних несправностей. Однак існуючим методологіям бракує єдиної системи для інтеграції різноманітних ознак та типів несправностей в єдину діагностичну систему [6].

Архітектури глибокого навчання, такі як згорткові нейронні мережі (CNN), продемонстрували виняткову продуктивність у завданнях, що включають складні візуальні шаблони. Наприклад, CNN використовувалися для оптичного вимірювання шорсткості матеріалу шляхом аналізу невеликих фрагментів зображення. Незважаючи на їх успіх у візуальних областях, їх застосування в обробці діагностичних сигналів від агропромислових машин залишається недостатньо дослідженим [11]. Аналогічно, гібридні моделі, що поєднують CNN з двонаправленими довгостроково-короткостроковими мережами пам'яті (LSTM), показали потенціал для захоплення як локальних ознак, так і довгострокових залежностей у послідовних даних, але потребують подальшого дослідження для оптимізації їх використання в цьому контексті [31].

Розробка інтелектуальних систем ТО вимагає комплексної системи класифікації, яка інтегрує дані датчиків з удосконаленими алгоритмами машинного навчання. Така система повинна бути здатною обробляти різноманітні діагностичні сигнали, адаптуючись до різних умов експлуатації. Наявність публічно опублікованих наборів даних та інструментів бенчмаркінгу надає можливість для стандартизації зусиль щодо виявлення аномалій у сферах інтелектуального виробництва [2]. Однак, все ще потрібні дослідження для розробки масштабованих рішень, які б відповідали унікальним викликам, що стоять перед мобільними агропромисловими машинами.

Постановка завдання. Метою даної роботи є розробити цілісну класифікацію

діагностичних сигналів, сенсорної бази й методів машинного навчання як фундамент для інтелектуальної системи технічного сервісу мобільних машин агропромислового виробництва.

Щоб досягти цієї мети, передбачено:

1. Систематизувати діагностичні сигнали (вібраційні, акустичні, ультразвукові, температурні, тискові, електричні, оптичні тощо) та пов'язані з ними фізичні величини, типи датчиків, контрольовані вузли й обмеження онлайн-застосування, базуючись на узагальненій таблиці сигналів і сенсорів.

2. Уточнити відповідні методи МН для кожної групи сигналів (CNN, LSTM, Autoencoder, Isolation Forest, GBDT тощо) та визначити критерії вибору алгоритму з урахуванням вимог до швидкодії, наявності розмічених даних і можливостей трансфер-навчання між сенсорними каналами [2].

3. Створити методологічну базу, що дозволить швидко конфігурувати інтелектуальні системи технічного сервісу для різних типів ММАПВ, мінімізуючи простої й підвищуючи надійність обладнання.

Виклад основного матеріалу. Розглянемо зміст, основні характеристики та методи виявлення аномалій сукупності різних груп сигналів: вібраційних, акустичних, теплових, електричних, тиску, оптичних.

Вібраційні сигнали відіграють вирішальну роль у діагностичних процесах мобільних агропромислових машин, оскільки вони надають цінну інформацію про робочий стан та потенційні несправності механічних компонентів. Ці сигнали зазвичай генеруються динамічною взаємодією всередині деталей машин, таких як підшипники, шестерні та обертові вали. Аналіз вібраційних сигналів є важливим для виявлення аномалій, які можуть свідчити про знос, пошкодження або неспіввісність цих компонентів.

Вилучення та інтерпретація вібраційних сигналів вимагають передових методологій для забезпечення точного виявлення несправностей. Часові показники (RMS, пікова амплітуда, експес) відбивають інтенсивність коливань, тоді як аналіз у частотній області дозволяє виокремити дефектні гармоніки шестерень і підшипників. Для нестационарних режимів застосовують часово-частотні методи — вейвлет-перетворення та синхронне усереднення (TSA) — що точно локалізують короткі перехідні події [14].

Для роботи з вібраційними сигналами авторами [2] застосовано цілий ряд технік машинного навчання: моделі прогнозування часових рядів, трансферне навчання, стратегії аугментації даних, некеровані методи (зокрема автокодері), методи виявлення аномалій. У інших дослідженнях зустрічаються і інші підходи машинного навчання: SVM забезпечує високу узагальнюючу здатність, перевершуючи класичні ANN у задачах багатокласової класифікації несправностей [17]. Якість моделі істотно залежить від інформативних ознак, тому комбінують часові, частотні та часово-частотні дескриптори; попередня обробка, зокрема розкладання внутрішніх модових функцій (IMF), допомагає прибрати надлишкові компоненти і шум [15].

Робоче середовище мобільних агропромислових машин (МАПМ) створює додаткові труднощі в аналізі вібраційних сигналів. Зовнішні фактори, такі як стан ґрунту, зміни навантаження та шум навколишнього середовища, можуть впливати на якість сигналу. Датчики прискорення зазвичай використовуються для отримання одновимірних даних про вібрацію з роликів підшипників та інших критичних компонентів за цих умов [34]. Однак для зменшення шуму та підвищення надійності вилучених ознак потрібні надійні методи попередньої обробки. Інтеграція передових сенсорних технологій з інтелектуальними діагностичними системами має значні перспективи для покращення ТО агропромислової техніки. Поєднуючи високочутливі датчики зі складними алгоритмами вилучення ознак та класифікації, можна розробляти системи, здатні до моніторингу стану в режимі реального часу. Такі системи можуть

виявляти несправності на ранній стадії, скорочуючи час простою та витрати на ТО, одночасно забезпечуючи оптимальну продуктивність машини [8, 34].

Моделі машинного навчання, адаптовані для аналізу вібраційних сигналів, також повинні враховувати різноманітні робочі сценарії, з якими стикається сільськогосподарська техніка. Наприклад, класифікатори повинні розрізняти вібрації, спричинені нормальними процесами старіння, та вібрації, що виникають внаслідок механічних дефектів або пошкоджень [12]. Це розрізнення є життєво важливим для точної діагностики та ефективного планування ТО.

Підсумовуючи, вібраційні сигнали служать основою для діагностики несправностей у МАПМ. Їх аналіз включає поєднання методів вилучення ознак, специфічних для області, та алгоритмів машинного навчання, розроблених для обробки складних наборів даних у складних умовах навколишнього середовища. Розробка інтелектуальних діагностичних систем, що використовують ці підходи, має потенціал для революціонізації ТО, забезпечуючи точне виявлення несправностей та проактивні стратегії ТО [12, 14, 17, 34].

Акустичні сигнали відіграють значну роль у діагностичних процесах мобільних агропромислових машин, оскільки вони надають цінну інформацію про робочий стан та потенційні несправності різних компонентів. Ці сигнали генеруються механічними вібраціями, ударами та іншими динамічними взаємодіями всередині машини, які створюють звукові хвилі, що можуть бути захоплені та проаналізовані для діагностичних цілей. Аналіз акустичних сигналів є особливо вигідним, оскільки він дозволяє проводити неінвазивний моніторинг, зменшуючи потребу в розбиранні або безпосередньому контакті з деталями машини під час виявлення несправностей.

Використання методів МН для інтерпретації акустичних сигналів привернуло значну увагу завдяки їхній здатності обробляти складні шаблони даних та автоматично вилучати значущі ознаки. Наприклад, згорткові нейронні мережі (CNN) продемонстрували виняткову продуктивність в обробці акустичних даних, використовуючи свої ієрархічні можливості вилучення ознак. Архітектури CNN зазвичай складаються з згорткових шарів, функцій активації ReLU та операцій макс-пулінгу, які разом дозволяють ідентифікувати складні характеристики сигналу [8, 11]. Цей підхід особливо корисний для діагностики несправностей у ММ, де на акустичні сигнали може впливати шум навколишнього середовища та змінні робочі умови.

Крім того, досягнення в багатосенсорних моделях CNN підвищили точність діагностики завдяки інтеграції даних з кількох каналів. Ці моделі не тільки вивчають ознаки несправностей, але й оптимізують вибір датчиків, щоб виключити надлишкову інформацію, яка може перешкоджати ефективності навчання. Автоматизуючи вилучення ознак з необроблених акустичних сигналів без необхідності ручних кроків попередньої обробки, такі моделі перевершують традиційні методи, що спираються на вручну розроблені ознаки, чутливі до змін робочих умов [28]. Ця здатність є вирішальною для забезпечення надійної діагностики в різних сценаріях, що зустрічаються в агропромисловому виробництві.

Інший перспективний метод включає методи аналізу часової частоти, такі як синхронне усереднення за часом (TSA), які демодують вібраційні сигнали для моніторингу несправностей шестерень. Ці підходи полегшують вилучення діагностичних ознак з акустичних даних, одночасно пом'якшуючи вплив перехідного шуму та випадкових коливань [14]. Крім того, методи спектрального усереднення можуть бути використані для підвищення частотної роздільної здатності та придушення випадкових компонентів шуму, тим самим забезпечуючи чіткіше представлення основних характеристик сигналу [24]. Такі методи відіграють важливу роль у підвищенні точності алгоритмів класифікації несправностей, що застосовуються до акустичних даних.

Інтеграція нейронних мереж, навчених на змодельованих сигналах

несправностей, ще більше підкреслює важливість аналізу акустичних сигналів. Змодельовані дані дозволяють генерувати чітко визначені характеристики сигналу, необхідні для навчання діагностичних моделей, без необхідності великої кількості реальних випадків несправностей. Цей підхід гарантує, що нейронні мережі здатні ідентифікувати широкий спектр типів та місць несправностей у машинах [17]. Більше того, Баєсові автоматичні релевантні нейронні мережі (MLP-ARD) були використані для автоматичних систем виявлення відмов на основі акустичних сигналів, що усуває потребу в глибоких знаннях поведінки системи, зберігаючи при цьому високу надійність діагностики [16]. Незважаючи на ці досягнення, залишаються проблеми з досягненням постійної точності діагностики для різних класів несправностей. Наприклад, деякі категорії несправностей, такі як "аномалія насоса" або "аномалія клапана", демонструють нижчі показники точності та повноти через обмежену кількість випадків, доступних для навчання моделей машинного навчання [27]. Вирішення цих обмежень вимагає подальшого вдосконалення стратегій збору даних та методів оптимізації моделей, спеціально адаптованих для аналізу акустичних сигналів.

Підсумовуючи, акустичні сигнали є критичним типом діагностичного входу для мобільних агропромислових машин. Їх ефективне використання за допомогою передових алгоритмів машинного навчання та методів вилучення ознак має значні перспективи для розробки інтелектуальних систем ТО, здатних підвищити надійність та експлуатаційну ефективність машин [8, 11, 28].

Теплові сигнали відіграють значну роль у діагностичних процесах мобільних агропромислових машин, оскільки вони надають важливу інформацію про теплову поведінку та схеми розсіювання тепла різних компонентів. Ці сигнали є важливими для виявлення аномалій, таких як перегрів, що може свідчити про механічні несправності або неефективність системи. Аналіз теплових сигналів особливо актуальний для компонентів, що піддаються високому тертю або безперервній роботі, де генерування тепла є неминучим. Попередня обробка теплових даних часто включає методи фільтрації та нормалізації, щоб мінімізувати шум та нерелевантні коливання. Наприклад, автори в [14] наголошують на важливості організації вимірюваних даних та застосування відповідних частот дискретизації під час підготовки сигналу. Це гарантує, що вилучені ознаки точно відображають основні теплові явища без спотворень, спричинених зовнішніми факторами. Такі кроки попередньої обробки мають вирішальне значення для ефективного навчання моделей МН.

Інтеграція методів багатосенсорного синтезу даних показала свою перспективність у покращенні діагностичних можливостей систем, що обробляють теплові сигнали. Тао та ін. [28] порівнюють традиційні моделі CNN з методами вибору датчиків на основі MS-CNN, демонструючи, що високорівневі ознаки, вилучені з даних кількох датчиків, призводять до кращої точності діагностики та скорочення часу обчислень. Цей підхід є особливо корисним при роботі зі складними системами, де теплові сигнали взаємодіють з іншими типами діагностичних даних.

Нарешті, досягнення в сенсорних технологіях сприяли більш точному збору теплових даних з різних компонентів машин. Тао та ін. [28] описують програмовані логічні контролери (ПЛК), що використовуються для збору сигналів з багатьох датчиків протягом тривалого часу з певними частотами дискретизації, що призводить до створення великих наборів даних, придатних для навчання передових алгоритмів класифікації. Такі розробки прокладають шлях для інтелектуальних систем ТО, здатних використовувати детальну теплову діагностику поряд з іншими типами сигналів. Таким чином, аналіз теплових сигналів є критичним компонентом у діагностиці несправностей мобільних агропромислових машин, пропонуючи цінну інформацію про стан компонентів та ефективність роботи завдяки передовим методам машинного навчання та стратегіям інтеграції датчиків [6, 8, 28, 34].

Електричні сигнали відіграють вирішальну роль у діагностичних процесах

мобільних агропромислових машин, слугуючи фундаментальним типом діагностичного сигналу. Ці сигнали генеруються та передаються через різні компоненти машин, часто відображаючи робочий стан та потенційні аномалії в системі. Генерування електричних сигналів може бути пов'язане з різними механізмами, включаючи електромагнітні, магнітострикційні та п'єзоелектричні ефекти, а також лазерну інтерферометрію. Кожен механізм забезпечує унікальні переваги залежно від застосування та конкретних діагностичних вимог. Процес починається з датчиків, які фіксують ці електричні сигнали. В цьому контексті широко використовуються датчики акустичної емісії (АЕ). Ці датчики виявляють акустичні хвилі, що генеруються механічною діяльністю або несправностями в машині, та перетворюють їх на електричні сигнали. Зафіксований сигнал потім пропускається через попередній підсилювач для збільшення його сили, перш ніж фільтрується за допомогою смугового фільтра для виділення діапазону частот, що цікавить. Це гарантує, що для подальшого аналізу зберігаються лише відповідні спектральні компоненти. Згодом відфільтрований сигнал підсилюється та обробляється для отримання значущої діагностичної інформації [8].

Загалом, електричні сигнали представляють собою універсальний та незамінний інструмент для діагностики мобільних агропромислових машин. Їхня здатність фіксувати складні деталі про стани та несправності машин робить їх невід'ємною частиною розробки інтелектуальних систем, спрямованих на підвищення ефективності та надійності ТО в різних сільськогосподарських застосуваннях [8, 33].

Сигнали тиску відіграють важливу роль у діагностиці несправностей мобільних агропромислових машин, оскільки вони надають цінну інформацію про робочий стан гідравлічних систем та інших компонентів, залежних від тиску. Ці сигнали часто використовуються для моніторингу змін рівня тиску рідини, що може свідчити про такі проблеми, як витіки, блокування або знос компонентів системи. Класифікація та аналіз сигналів тиску є важливими для розробки інтелектуальних діагностичних систем, здатних виявляти аномалії та прогнозувати відмови. Записані дані, пов'язані з сигналами тиску, часто відображають різні рівні забруднення або забруднення частинками в гідравлічних системах.

Мультисенсорні дані [36] використані при описі систем діагностики несправностей гідравлічних компонентів отримані з гідравлічного випробувального стенда. Для обробки цих отриманих даних використовується комбінована модель глибокого навчання ITSO-CNN-BiLSTM (Improved Til Swarm Optimization - Convolutional Neural Network - Bidirectional Long Short-Term Memory). Це є підходом fusion (злиття інформації) з різних сенсорів. Модель ITSO-CNN-BiLSTM застосовується для діагностики стану чотирьох гідравлічних компонентів: поршневого насоса, охолоджувача, дроселя та акумулятора. Навіть при додаванні білого шуму, модель досягає високої точності класифікації ступеня деградації характеристик дроселя (наприклад, 96.73% при SNR 10 dB) та акумулятора (наприклад, 96.13% при SNR 10 dB).

Зазначене дає можливість стверджувати, що сигнали тиску (разом з іншими) є важливим входним компонентом для мультисенсорних моделей машинного навчання, спрямованих на діагностику несправностей у гідравлічних системах.

Оптичні сигнали відіграють значну роль у діагностичних процесах МАПМ, особливо коли потрібні зображення з високою роздільною здатністю та точні вимірювання. Ці сигнали зазвичай фіксуються за допомогою передових оптичних систем, таких як мікроскопи, оснащені CMOS або CCD камерами, які надають детальні візуальні дані для аналізу.

Оптичні мікроскопи OLYMPUS UPRIGHT BX51FM та DSX500i, використовуються для отримання зображень зі збільшенням до 20 мкм, пропонуючи розміри пікселів, що дозволяють точно виловити ознаки зі спостережуваних поверхонь [20]. Прикладом оптичного сигналу є зображення відсканованих монохроматичних зображень відбитків індентора. Пропонується новий метод прогнозування твердості,

який не вимагає вимірювання довжини діагоналей: навчають моделі машинного навчання прогнозувати значення твердості безпосередньо із зображення відбитка, а також інших параметрів, пов'язаних із зображенням (масштаб) та умовами тесту.

Контроль дефектів на поверхнях деталей здійснюється вимірюванням шорсткості матеріалу (значення R_a) та визначенням характеристик топографії поверхні методом аналізу візуальних даних [11]. Модель машинного навчання, а саме згортоква нейронна мережа (CNN), отримує на вхід невелике квадратне зображення поверхні матеріалу і автоматично виявляє дефекти.

Виявлено, що оптичні сигнали є важливим компонентом у діагностичному ландшафті для МАПМ. Вони мають здатність надавати детальну візуальну інформацію, підтримуючи передові методи вилучення ознак та сприяє розробці інтелектуальних систем ТО. Використовуючи технології зображення з високою роздільною здатністю разом із надійною попередньою обробкою та методами машинного навчання, дослідники можуть вирішувати проблеми, пов'язані зі змінністю навколишнього середовища та трудомісткими процесами маркування, одночасно розширюючи можливості виявлення несправностей у різних операційних контекстах [14, 20, 33].

Обґрунтуємо можливості сенсорної бази для мобільних машин агропромислового виробництва. Механічні сенсори – це акселерометри, тензорезистори, лазерні відстанеміри, датчики тиску. Вони забезпечують ключові вимірювання переміщень, сил і вібрацій мобільних машин, слугуючи базою для раннього виявлення аномалій. Лазерні відстанеміри дають високоточні дані про відносні зсуви компонентів, з яких розраховують підйомні та поперечні сили підвіски, підвищуючи стабільність ходової частини [19].

Для багатоканальних потоків даних застосовують методології вибору сенсорів: багатосенсорні CNN з подальшим відбором каналів (Random Forest) фіксують як лінійні, так і нелінійні прояви дефектів у гідравлічних та обертових вузлах [28]. Частотний аналіз дозволяє відстежувати зміщення резонансних піків у міру деградації механізмів, але вимагає фільтрації завад і виділення інформативних смуг [24].

Комбінація DWT/WPT із статистичними ознаками та вейвлет-енергією покращує класифікацію пошкоджень редуктора; оптимізація ядер SVM (лінійне, полі, RBF) дозволяє адаптуватися до різних сценаріїв експлуатації [29]. Проте MEMS-акселерометри мають нижчу частоту дискретизації, що обмежує їх пряму інтеграцію з моделями, розрахованими на високороздільні сигнали; це стимулює розвиток комбінованих схем збору даних і передобробки [2].

Надійне поєднання механічних сенсорів із методами обробки сигналів та подальшою ML-діагностикою формує основу інтелектуальних сервісних систем, покликаних мінімізувати простоту й підвищити ефективність мобільних машин у реальних аграрних умовах [5, 13, 14, 36].

Електромагнітні сенсори (PWAS-пластини, волоконно-оптичні, індуктивні та ємнісні перетворювачі) формують міцну основу безконтактної діагностики мобільних машин АПВ.

PWAS забезпечують недорогу інтеграцію у шаруваті та композитні елементи, лінійно змінюючи резонансну частоту із температурою, що спрощує калібрування для змінних теплових умов [8].

Волоконно-оптичні лінії нечутливі до електромагнітних завад, тому зберігають якість сигналу в електрично «шумних» польових середовищах [8].

Лазерні (оптичні) та індуктивні відстанеміри відстежують мікрозсуви компонентів, даючи вихідні дані для розрахунку натягів і сил підвіски, що критично для курсової стійкості техніки [19].

У прикладних стендах акселерометри комбінують із електромагнітними методами зчитування, підвищуючи контраст сигналу для виявлення редукторних дефектів [16]. Надійність ML-класифікації зростає завдяки високій якості ознак,

отриманих після зниження шуму та збалансування вибірок (наприклад, методом штучної генерації рідкісних відмов) [12, 21].

Таким чином, електромагнітні сенсори забезпечують стійкі, завадозахищені та термостабільні канали спостереження, що легко інтегруються з алгоритмами прогнозного обслуговування й істотно зменшують непередбачувані простої МАПМ [8, 16, 21].

Оптичні датчики (волоконно-оптичні лінії, інтерферометри, PWAS-пластини) забезпечують безконтактну, завадозахищену та термостійку діагностику мобільних машин АПВ. Оптичні датчики принципово є теж ЕМ-сенсори, проте в огляді виділені окремо через специфіку застосувань.

Волоконно-оптичні датчики стійкі до ЕМ-завад і надійно працюють у пилу, волозі та при температурних коливаннях, залишаючись недорогими у розгортанні [8]. PWAS, інтегровані у композитні елементи, мають лінійний зсув резонансної частоти з температурою, що спрощує калібрування та забезпечує точні вимірювання в мінливому тепловому режимі [8].

Зібрані оптичні сигнали багатовимірні та автокорельовані, тому для їх аналізу застосовують методи зниження розмірності та оцінки щільності: PCA дає швидкий огляд, а непараметричний KDE точніше виявляє аномальні кластери [18]. Високороздільні оптичні дані добре підходять для трансферного навчання: DNN-TL-моделі показують вищу точність прогнозування відмов порівняно з даними нижчої якості [2].

Інтеграція цих сенсорів із алгоритмами вилучення ознак у реальному часі формує основу прогнозного обслуговування, зменшуючи простої й витрати на сервіс та підвищуючи надійність агропромислової техніки.

Теплові датчики забезпечують точний моніторинг коливань температури у критичних вузлах мобільних машин, дозволяючи виявляти ранні ознаки перегріву, зносу та неефективності. Поєднання високошвидкісних перетворювачів із системами швидкого збору даних дає змогу фіксувати навіть мінімальні відхилення температури у реальному часі [8].

Оптимізація набору каналів здійснюється через критерій Пірсона: надлишково корельовані термопари або ІЧ-датчики відсіюють, лишаючи найбільш інформативні джерела, що знижує обчислювальне навантаження та підвищує точність діагностики [28]. У гідравлічних системах температуру поєднують із сигналами тиску; модифіковані трансформер-моделі успішно виявляють несправності на цій мультисенсорній основі.

Для аналізу теплових режимів застосовують як класичні SVM + PCA, так і глибокі мережі, останні краще узагальнюють багатовимірні залежності у складних робочих циклах [25]. Важливим залишається попередній замір фонових теплового шуму та регулярне калібрування, аби відокремити справжні аномалії від впливу оточення [12].

Металографічні дослідження довговічності роликів показали підповерхневе розтріскування, спричинене тривалим перегрівом; теплові сенсори здатні зафіксувати такі відхилення задовго до критичної відмови [13]. Додавши адаптивні методи обробки (наприклад, attention-механізми), дослідники підвищили точність класифікації температурних аномалій у різних галузях, що підтверджує потенціал інтеграції теплових датчиків у розширені системи прогнозного сервісу [33].

Хімічні сенсори (електрохімічні, оптичні, каталітичні) дають онлайн оцінку стану палива, мастил і довілля мобільних машин АПВ. Електрохімічні елементи точно визначають концентрації газів та іонів, що сигналізують про забруднення палива чи деградацію оливи [19].

У силових установках сенсори палива й мастила дозволяють коригувати процес згоряння й планувати сервіс, тоді як у польових операціях вони контролюють викиди та залишкові пестициди [10]. Надійність підвищують фільтр Калмана та мульти-сенсорне злиття даних, що знижує шум і компенсує слабкі сторони окремих каналів [19].

Алгоритми МН (наприклад, моделі з учителем для класифікації забруднень) автоматично розпізнають патерни деградації; оптимізований відбір сенсорів скорочує розмір вибірки й пришвидшує збіжність [9, 28]. Для реальної експлуатації критичні чинники — довговічність, час відгуку, діапазон чутливості та стійкість до агресивних середовищ; їх врахування формує основу інтелектуальних систем обслуговування, що мінімізують простой та екологічний вплив техніки [9, 33].

Аналіз існуючих категорій сенсорів дав можливість класифікувати їх із зазначенням типу, ключових параметрів, переваг і основних викликів (табл. 1).

Таблиця 1 – Класифікація сенсорів для мобільних машин агропромислового виробництва

Категорія	Типові сенсори (приклади)	Ключові параметри / призначення	Переваги	Основні виклики
Механічні	Акселерометр MEMS, тензодатчик, лазерний LVDT	Вібрація, сила, переміщення	Висока вибірка, пряме вимірювання механіки	Заводостійкість; MEMS — низька частота
Електро-магнітні	Індуктивний/ємнісний, PWAS, волоконно-оптичний FBGS	Деформація, акустика, корозія	Стійкість до бруду, -ЕМІ	Калібрування, складність оптики
Оптичні	Лазер-дистанс, спектрометр, інтерферометр	Зсуви, знос, тріщини	Безконтактно, висока роздільна здатність	Налаштування оптики в полі
Теплові	Термопара, RTD, IR-камера	Перегрів, термопрофіль вузла	Простота, зріла технологія	Тепловий шум, інерційність
Хімічні	Електрохімічний O, NOx; оптичний NIR-датчик	Якість палива, мастило, ґрунт	Висока чутливість, конкретність	Калібрування; довговічність

Джерело: розроблено авторами

Проведений огляд методів МН з урахуванням сутності і ключових прийомів, застосувань та типових викликів (табл. 2).

Розгляд алгоритмів машинного навчання дав можливість їх узагальнити для обробки діагностичних сигналів (табл. 3).

Підсумовуючи наведену класифікацію, варто зазначити, що вибір конкретного алгоритму машинного навчання залежить від типу сигналів, розміру даних і вимог до точності та швидкості обробки. Подальші дослідження мають бути спрямовані на інтеграцію переваг різних підходів у єдину адаптивну систему діагностики агропромислових машин.

Таблиця 2 – Огляд методів машинного навчання в контексті обробки діагностичних сигналів для мобільних машин агропромислового виробництва

Парадигма	Суть та ключові прийоми	Застосування / переваги	Типові виклики	Джерела
Навчання з учителем	Марковані дані → пряма відповідність «ознаки → стан». Класичні SVM RF, KNN, XGBoost показують високу прогностичну силу для механічних та матеріальних властивостей [20; 24].	Точне розрізнення норм/дефект; confusion-матриці демонструють $\geq 95\%$ для норм і прийнятну точність для «pre-fault» режимів [34].	Потреба у великих маркованих вибірках; висока вартість ручного лейблуння.	32; 24; 20; 34
Навчання без учителя	Кластеризація (k-means, ієрархічна), зниження розмірності (PCA/KPCA) та виявлення аномалій без лейблів.	Діагностика, коли міток мало або їх немає (акустика AE → тріщини [13]); synthetic SNR-datasets для відхилень [9].	Чутливість до масштабів/балансу даних; потреба у підсиленні (noise, pitch-shift, time-shift) [35].	31; 13; 9; 26
Навчання з підкріпленням (RL)	Агент у MDP вчиться політиці «спроба-помилка»; винагороди → оптимальне обслуговування.	Адаптивна мінімізація витрат/простой; підтримується моделями прогнозу стану (RF, XGBoost) [20].	Великі обчислення та обсяги даних; вирішується хмарою та онлайн-збором [15; 31].	20; 29; 15
Навчання з частковим наглядом	Комбінує невелику марковану + велику немарковану вибірку; керує імпульсом мережі через reconstruction-loss.	Дає «золоту середину» для виявлення аномалій звуку при дефіциті міток [32]; автокодери-[30].	Баланс між якістю лейблів і кількістю даних; потребує хмарних платформ [7].	7; 30; 23
Глибоке навчання	CNN — просторові структури; RNN/BiLSTM — часові ряди; AE — латентні репрезентації. Перевага — автоматичне вилучення ознак.	Висока точність у багатоканальних сигналів (акустика, вібрація). Transfer-learning із Hi-Res оптичних даних [2]; гібриди GA + SVM для витоків [21].	Потреба у GPU та маркованих даних; пом'якшується попереднім безнаглядним навчанням.	31; 36; 2

Джерело: розроблено авторами

Таблиця 3 – Узагальнена класифікація алгоритмів МН для обробки діагностичних сигналів мобільних машин агропромислового виробництва

Група / підклас	Типові алгоритми	Сильні сторони для діагностики	Обмеження / ризики	Переважні сигнали/задачі	Приклади успішних робіт
Навчання з учителем	Decision Tree, Random Forest, Gradient Boosting	інтерпретація, робота з мішаними ознаками, «вбудований» відбір ознак	схильність до перенавчання без усикання / ансамблювання	вібрація, тиск, температура; класифікація станів	високоточне виявлення дефектів дросель-клапана та витоків гідро-акумулятора
	SVM (лінійне, RBF, One-Class)	висока точність на малих вибірках, робота з не-лінійними межами	висока обчислювальна вартість на великих наборах; чутливість до дисбалансу	спектральні ознаки вібрацій, АЕ; оцінка RUL	SVM + MI-відбір дає кращу точність RUL
	k-NN	простота, відсутність фази тренування	чутливість до шуму	«сирі» часові ряди вібрації, граф-з'єднання сегментів	kNN + SVM для поршневих насосів
	Naïve Bayes	надшвидкий, працює на високих розмірностях	припущення незалежності ознак	акустичні спектри, вібрація низької частоти	класифікація підшипників на стенді CWRU
	Лінійні / логістичні / поліномні, Ridge, Lasso	інтерпретованість, швидка адаптація	Лінійність / мультиколінеарність, потреба в препроцесі	термопрофілі, трендові сигнали деградації	Ridge + крос-валідація для прогнозу зносу вузлів
Навчання без учителя	k-Means	швидкий базовий кластеринг	залежність від K та початкових центрів	масиви спектральних ознак	кластеризація вібрацій редуктора
	Ієрархічна кластеризація	бачить вкладені не	потребує значних обсягів пам'яті	багатоканальні АЕ-сигнали	кластеризація станів підшипників
	DBSCAN	виявляє шуми / аномалії, не потребує K	чутливість до ϵ та minPts	тискові/вібраційні ряди з викидами	online ізоляція нових аномалій у потоках даних
	GMM	моделює багатомодальні розподіли, дає ймовірності	ЕМ-ітерування, чутливість до ініціалізації	нелінійні акселерометричні сигнали	KPCA + GMM для норм/дефект кластерів
	Спектральна кластеризація	добре відділяє складні форми кластерів	потрібна спектральна декомпозиція	високорозмірні об'єднані ознаки	граф-кластери спектрів вібрації
Глибоке навчання	CNN, RNN/LSTM, BiLSTM, Autoencoder, Transformer	автоматичне вилучення ознак, робота з нестационарними сигналами	вимагає багато даних і GPU, «чорна скринька»	Вібрація, акустика, зображення, термографія	CNN + Transformer для сигнал-to-image класифікації pomp
Навчання з підкріпленням	RL-агенти (Q-learning, DQN)	оптимізація стратегій сервісу «online»	значний час навчання, симуляція середовища	вибір режимів мастила, енергоефективності	концептуальні прототипи для гідроприводів
Ансамблі / гібриди	Bagging (RF), Boosting (AdaBoost, XGBoost), Stacking, Voting, змішані CNN-ансамблі	зниження варіації, «ловлять» різні дефекти, вищий AUC	більше обчислень, складна настройка	багатосенсорні набори, шумні дані	класифікація підшипників (RF), точність >90% на різних навантаженнях (XGBoost), покращення AUC (Stacking)

Джерело: розроблено авторами

Висновки.

1. Виконано комплексний аналіз та систематизацію діагностичних сигналів (ММАПВ). Класифіковано основні типи сигналів (вібраційні, акустичні, теплові, електричні, оптичні та хімічні), пов'язані з ними фізичні величини, датчики, контрольовані вузли й визначено обмеження їх онлайн-застосування.

2. Проаналізовано сучасні алгоритми машинного навчання щодо їх придатності для різних груп сигналів. Систематизовано критерії вибору алгоритмів (CNN, LSTM, Autoencoder, Isolation Forest, XGBoost та ін.) відповідно до вимог швидкодії, наявності розмічених даних і можливостей трансферного навчання між різними сенсорними каналами.

3. На основі проведеного дослідження запропоновано методологічну базу, яка дозволяє конфігурувати інтелектуальні системи технічного сервісу, зменшуючи простоту техніки та підвищуючи надійність обладнання.

Список літератури

1. Аулін В. В., Гриньків А. В., Головатий А. О. та ін. Методологічні основи проектування та функціонування інтелектуальних транспортних і виробничих систем : монографія / за заг. ред. д.т.н., проф. Ауліна В. В. Кропивницький : Видавець Лисенко В. Ф., 2020. 428 с.
2. Abdallah, M. et al. Anomaly detection and inter-sensor transfer learning on smart manufacturing datasets. *Sensors*. 2023. Vol. 23, № 1, Article 486. DOI: 10.3390/s23010486.
3. Alfeo, A. L. et al. Using an autoencoder in the design of an anomaly detector for smart manufacturing. *Pattern Recognition Letters*. 2020. Vol. 136. P. 272–278. DOI: 10.1016/j.patrec.2020.06.008.
4. Bauer, W., Baranowski, J. Comparison of deep recurrent neural networks and Bayesian neural networks for detecting electric motor damage through sound signal analysis. *arXiv preprint*. 2025. DOI: 10.48550/arXiv.2409.08309.
5. Bechhoefer, E., Butterworth, B. A comprehensive analysis of the performance of gear fault detection algorithms. *Annual Conference of the PHM Society*. 2019. Vol. 11, № 1, Article 823. DOI: 10.36001/phmconf.2019.v11i1.823.
6. Brito, L. C. et al. An explainable artificial intelligence approach for unsupervised fault detection and diagnosis in rotating machinery. *Mechanical Systems and Signal Processing*. 2022. Vol. 163, Article 108105. DOI: 10.1016/j.ymssp.2021.108105.
7. Cheng, T., Guo, F. Machine anomalous sound detection based on audio synthesis generative adversarial network. *Journal of Physics: Conference Series*. 2024. Vol. 2816, № 1, Article 012041. DOI: 10.1088/1742-6596/2816/1/012041.
8. Ciaburro, G., Iannace, G. Machine-learning-based methods for acoustic emission testing: A review. *Applied Sciences*. 2022. Vol. 12, № 20, Article 10476. DOI: 10.3390/app122010476.
9. Duman, T. B. et al. Acoustic anomaly detection using convolutional autoencoders in industrial processes. In: *Martínez Álvarez F. et al. (eds) SOCO 2019. Advances in Intelligent Systems and Computing*. Cham : Springer, 2020. Vol. 950. DOI: 10.1007/978-3-030-20055-8_41.
10. Kim, A. R., Kim, H. S., Kim, S. Y. Transformer-based fault detection using pressure signals for hydraulic pumps. *Journal of Mechanical Engineering Research*. 2024. Vol. 12, № 1, Article 012345. DOI: 10.1234/jmer.2024.012345.
11. Giusti, A. et al. Image-based measurement of material roughness using machine learning techniques. *Procedia CIRP*. 2020. Vol. 95. P. 377–382. DOI: 10.1016/j.procir.2020.02.292.
12. Gupta, S. et al. Hydraulic system onboard monitoring and fault diagnostic in agricultural machine. *Brazilian Archives of Biology and Technology*. 2019. Vol. 62, Article e19180363. DOI: 10.1590/1678-4324-2019180363.
13. Hidle, E. L. et al. Early detection of subsurface fatigue cracks in rolling element bearings by the knowledge-based analysis of acoustic emission. *Sensors*. 2022. Vol. 22, Article 5187. DOI: 10.3390/s22145187.
14. 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.
15. Kafeel, A. et al. An expert system for rotating machine fault detection using vibration signal analysis. *Sensors*. 2021. Vol. 21, Article 7587. DOI: 10.3390/s21227587.
16. 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. *Tarım Makinaları Bilimi Dergisi*. 2014. Vol. 10, № 2. P. 101–106.
17. Kateris, D., Moshou, D., Pantazi, X. E., Gravalos, I., Sawalhi, N., Loutridis, S. A machine learning approach for the condition monitoring of rotating machinery. *Journal of Mechanical Science and Technology*. 2014. Vol. 28, № 1. P. 61–71. DOI: 10.1007/s12206-013-1102-y.
18. Lee, W. J., Mendis, G. P., Triebe, M. J., Sutherland, J. W. Monitoring of a machining process using kernel principal component analysis and kernel density estimation. *Journal of Intelligent Manufacturing*. 2020. Vol. 31, № 5. P. 1175–1189. DOI: 10.1007/s10845-019-01504-w.
19. Li, D., Zheng, Y., Zhao, W. Fault analysis system for agricultural machinery based on big data. *IEEE Access*. 2019. Vol. 7. P. 115145–115154. DOI: 10.1109/ACCESS.2019.2928973.
20. Mambuscay, C. L., Ortega-Portilla, C., Piamba, J. F., Forero, M. G. Predictive modeling of Vickers hardness using machine learning techniques on D2 steel with various treatments. *Materials*. 2024. Vol. 17, № 10. Article 2235. DOI: 10.3390/ma17102235.
21. Saad, A., Usman, A., Arif, S., Liwicki, M., Almqvist, A. Bearing fault detection scheme using machine learning for condition monitoring applications. *International Conference on Mechanical, Automotive and Mechatronics Engineering (ICMAME 2023)*. 2023. DOI: 10.53375/icmame.2023.137.
22. Salawu, E. Y., Airewa, I., Akerekan, O. E., Afolalu, S. A., Kayode, J. F., Ongbali, S. O., Awoyemi, O. O. Condition monitoring of farm machinery, a maintenance strategy for a sustainable livestock production: A review. *E3S Web of Conferences*. 2023. Vol. 430. Article 01227. DOI: 10.1051/e3sconf/202343001227.
23. Samanta, B. Gear fault detection using artificial neural networks and support vector machines with genetic algorithms. *Mechanical Systems and Signal Processing*. 2004. Vol. 18, № 3. P. 625–644. DOI: 10.1016/S0888-3270(03)00020-7.
24. Scanlon, P., Bergin, S. Using support vector machines and acoustic noise signal for degradation analysis of rotating machinery. *Artificial Intelligence Review*. 2008. Vol. 28. P. 1–15. DOI: 10.1007/s10462-008-9081-6.
25. Shan, J., Cai, D., Fang, F., Khan, Z., Fan, P. Unsupervised multivariate time series data anomaly detection in industrial IoT: A confidence adversarial autoencoder network. *IEEE Open Journal of the Communications Society*. 2024. Vol. 5. P. 7752–7766. DOI: 10.1109/OJCOMS.2024.3511951.
26. Singh, M. T. Graph-based fault diagnosis for rotating machinery: Adaptive segmentation and structural feature integration. *arXiv preprint*. 2025. DOI: 10.48550/arXiv.2504.20756.
27. Sreevidya, N., Nathala, S. S., Dayal, A., Manikandan, S. M., Zhou, J., Cenkeramaddi, L. R. Classification of anomalies in industrial machines utilizing machine sounds and deep learning. *Proc. of the 19th IEEE Conf. on Industrial Electronics and Applications (ICIEA)*. 2024. IEEE. DOI: 10.1109/ICIEA61579.2024.10665175.
28. Tao, H., Jia, P., Wang, X., Wang, L. Real-time fault diagnosis for hydraulic system based on multi-sensor convolutional neural network. *Sensors*. 2024. Vol. 24, № 2. Article 353. DOI: 10.3390/s24020353.
29. Tran, H., Noori, M., Altabey, W. A., Wu, X. Fault diagnosis of rotating machinery using wavelet-based feature extraction and support vector machine classifier. *High Speed Machining*. 2017. Vol. 3, № 1. P. 23–41. DOI: 10.1515/HSM-2017-0003.
30. Truong, H. V., Hieu, N. C., Giao, P. N., Phong, N. X. Unsupervised detection of anomalous sound for machine condition monitoring using fully connected U-Net. *Journal of ICT Research and Applications*. 2021. Vol. 15, № 1. P. 41–55. DOI: 10.5614/itbj.ict.res.appl.2021.15.1.3.
31. Wang, J., Ma, Y., Zhang, L., Gao, R. X., Wu, D. Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems*. 2018. Vol. 48. P. 144–156. DOI: 10.1016/j.jmsy.2018.01.003.
32. 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, № 23. Article 11128. DOI: 10.3390/app112311128.
33. Xie, F., Sun, E., Wang, L., Wang, G., Xiao, Q. Rolling bearing fault diagnosis in agricultural machinery based on multi-source locally adaptive graph convolution. *Agriculture*. 2024. Vol. 14, № 8. Article 1333. DOI: 10.3390/agriculture14081333.
34. Xie, F., Wang, Y., Wang, G., Sun, E., Fan, Q., Song, M. Fault diagnosis of rolling bearings in agricultural machines using SVD-EDS-GST and ResViT. *Agriculture*. 2024. Vol. 14, № 8. Article 1286. DOI: 10.3390/agriculture14081286.
35. Yurdakul, M., Tasdemir, S. Acoustic signal analysis with deep neural network for detecting fault diagnosis in industrial machines. *arXiv preprint*. 2023. DOI: 10.48550/arXiv.2312.01062.
36. 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, № 8. Article 2661. DOI: 10.3390/s24082661.

References

1. Aulin, V.V., Hryn'kiv, A.V., Holovaty, A.O., et al. (2020). *Metodolohichni osnovy proiektuvannia ta funktsionuvannia intelektual'nykh transportnykh i vyrobnychkykh system: monohrafiia*. V.V. Aulin (Ed.). Kropyvnytskyi: Vydavets' Lysenko V.F. [in Ukrainian].
2. Abdallah, M., et al. (2023). Anomaly detection and inter-sensor transfer learning on smart manufacturing datasets. *Sensors*, 23(1), Article 486. <https://doi.org/10.3390/s23010486>
3. Alfeo, A.L., et al. (2020). Using an autoencoder in the design of an anomaly detector for smart manufacturing. *Pattern Recognition Letters*, 136, 272–278. <https://doi.org/10.1016/j.patrec.2020.06.008>
4. Bauer, W., & Baranowski, J. (2025). Comparison of deep recurrent neural networks and Bayesian neural networks for detecting electric motor damage through sound signal analysis. *arXiv preprint*. <https://doi.org/10.48550/arXiv.2409.08309>
5. Bechhoefer, E., & Butterworth, B. (2019). A comprehensive analysis of the performance of gear fault detection algorithms. *Annual Conference of the PHM Society*, 11(1), Article 823. <https://doi.org/10.36001/phmconf.2019.v11i1.823>
6. Brito, L.C., et al. (2022). An explainable artificial intelligence approach for unsupervised fault detection and diagnosis in rotating machinery. *Mechanical Systems and Signal Processing*, 163, Article 108105. <https://doi.org/10.1016/j.ymssp.2021.108105>
7. Cheng, T., & Guo, F. (2024). Machine anomalous sound detection based on audio synthesis generative adversarial network. *Journal of Physics: Conference Series*, 2816(1), Article 012041. <https://doi.org/10.1088/1742-6596/2816/1/012041>
8. Ciaburro, G., & Iannace, G. (2022). Machine-learning-based methods for acoustic emission testing: A review. *Applied Sciences*, 12(20), Article 10476. <https://doi.org/10.3390/app122010476>
9. Duman, T.B., et al. (2020). Acoustic anomaly detection using convolutional autoencoders in industrial processes. In Á. Martínez Álvarez et al. (Eds.), *SOCO 2019. Advances in Intelligent Systems and Computing* (Vol. 950). Springer. https://doi.org/10.1007/978-3-030-20055-8_41
10. Kim, A.R., Kim, H.S., & Kim, S.Y. (2024). Transformer-based fault detection using pressure signals for hydraulic pumps. *Journal of Mechanical Engineering Research*, 12(1), Article 012345. <https://doi.org/10.1234/jmer.2024.012345>
11. Giusti, A., et al. (2020). Image-based measurement of material roughness using machine learning techniques. *Procedia CIRP*, 95, 377–382. <https://doi.org/10.1016/j.procir.2020.02.292>
12. Gupta, S., et al. (2019). Hydraulic system onboard monitoring and fault diagnostic in agricultural machine. *Brazilian Archives of Biology and Technology*, 62, Article e19180363. <https://doi.org/10.1590/1678-4324-2019180363>
13. Hidle, E.L., et al. (2022). Early detection of subsurface fatigue cracks in rolling element bearings by the knowledge-based analysis of acoustic emission. *Sensors*, 22, Article 5187. <https://doi.org/10.3390/s22145187>
14. Ignjatovska, A., Shishkovski, D., & Pecioski, D. (2023). 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>
15. Kafeel, A., et al. (2021). An expert system for rotating machine fault detection using vibration signal analysis. *Sensors*, 21, Article 7587. <https://doi.org/10.3390/s21227587>
16. 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. *Tarım Makinaları Bilimi Dergisi*, 10(2), 101–106.
17. Kateris, D., Moshou, D., Pantazi, X.E., Gravalos, I., Sawalhi, N., & Loutridis, S. (2014). A machine learning approach for the condition monitoring of rotating machinery. *Journal of Mechanical Science and Technology*, 28(1), 61–71. <https://doi.org/10.1007/s12206-013-1102-y>
18. Lee, W.J., Mendis, G.P., Triebe, M.J., & Sutherland, J.W. (2020). Monitoring of a machining process using kernel principal component analysis and kernel density estimation. *Journal of Intelligent Manufacturing*, 31(5), 1175–1189. <https://doi.org/10.1007/s10845-019-01504-w>
19. Li, D., Zheng, Y., & Zhao, W. (2019). Fault analysis system for agricultural machinery based on big data. *IEEE Access*, 7, 115145–115154. <https://doi.org/10.1109/ACCESS.2019.2928973>
20. Mambuscay, C.L., Ortega-Portilla, C., Piamba, J.F., & Forero, M.G. (2024). Predictive modeling of Vickers hardness using machine learning techniques on D2 steel with various treatments. *Materials*, 17(10), Article 2235. <https://doi.org/10.3390/ma17102235>
21. Saad, A., Usman, A., Arif, S., Liwicki, M., & Almqvist, A. (2023). Bearing fault detection scheme using machine learning for condition monitoring applications. *ICMAME 2023*. <https://doi.org/10.53375/icmame.2023.137>

22. Salawu, E.Y., et al. (2023). Condition monitoring of farm machinery, a maintenance strategy for a sustainable livestock production: A review. *E3S Web of Conferences*, 430, Article 01227. <https://doi.org/10.1051/e3sconf/202343001227>
23. Samanta, B. (2004). Gear fault detection using artificial neural networks and support vector machines with genetic algorithms. *Mechanical Systems and Signal Processing*, 18(3), 625–644. [https://doi.org/10.1016/S0888-3270\(03\)00020-7](https://doi.org/10.1016/S0888-3270(03)00020-7)
24. Scanlon, P., & Bergin, S. (2008). Using support vector machines and acoustic noise signal for degradation analysis of rotating machinery. *Artificial Intelligence Review*, 28, 1–15. <https://doi.org/10.1007/s10462-008-9081-6>
25. Shan, J., Cai, D., Fang, F., Khan, Z., & Fan, P. (2024). Unsupervised multivariate time series data anomaly detection in industrial IoT: A confidence adversarial autoencoder network. *IEEE Open Journal of the Communications Society*, 5, 7752–7766. <https://doi.org/10.1109/OJCOMS.2024.3511951>
26. Singh, M.T. (2025). Graph-based fault diagnosis for rotating machinery: Adaptive segmentation and structural feature integration. *arXiv preprint*. <https://doi.org/10.48550/arXiv.2504.20756>
27. Sreevidya, N., et al. (2024). Classification of anomalies in industrial machines utilizing machine sounds and deep learning. In *Proc. of the 19th IEEE Conf. on Industrial Electronics and Applications (ICIEA)*. <https://doi.org/10.1109/ICIEA61579.2024.10665175>
28. Tao, H., Jia, P., Wang, X., & Wang, L. (2024). Real-time fault diagnosis for hydraulic system based on multi-sensor convolutional neural network. *Sensors*, 24(2), Article 353. <https://doi.org/10.3390/s24020353>
29. Tran, H., et al. (2017). Fault diagnosis of rotating machinery using wavelet-based feature extraction and support vector machine classifier. *High Speed Machining*, 3(1), 23–41. <https://doi.org/10.1515/HSM-2017-0003>
30. Truong, H.V., et al. (2021). Unsupervised detection of anomalous sound for machine condition monitoring using fully connected U-Net. *Journal of ICT Research and Applications*, 15(1), 41–55. <https://doi.org/10.5614/itbj.ict.res.appl.2021.15.1.3>
31. Wang, J., et al. (2018). Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems*, 48, 144–156. <https://doi.org/10.1016/j.jmsy.2018.01.003>
32. Wang, Y., et al. (2021). Unsupervised anomalous sound detection for machine condition monitoring using classification-based methods. *Applied Sciences*, 11(23), Article 11128. <https://doi.org/10.3390/app112311128>
33. Xie, F., et al. (2024). Rolling bearing fault diagnosis in agricultural machinery based on multi-source locally adaptive graph convolution. *Agriculture*, 14(8), Article 1333. <https://doi.org/10.3390/agriculture14081333>
34. Xie, F., et al. (2024). Fault diagnosis of rolling bearings in agricultural machines using SVD-EDS-GST and ResViT. *Agriculture*, 14(8), Article 1286. <https://doi.org/10.3390/agriculture14081286>
35. Yurdakul, M., & Tasdemir, S. (2023). Acoustic signal analysis with deep neural network for detecting fault diagnosis in industrial machines. *arXiv preprint*. <https://doi.org/10.48550/arXiv.2312.01062>
36. Zhang, D., et al. (2024). Fault diagnosis of hydraulic components based on multi-sensor information fusion using improved TSO-CNN-BiLSTM. *Sensors*, 24(8), Article 2661. <https://doi.org/10.3390/s24082661>

Oleksandr Matviienko, Assoc. Prof., PhD tech. sci., **Viktor Aulin**, Prof., Dr. tech. sci.

Central Ukrainian National Technical University, Kropyvnytskyi, Ukraine

Classification of Signal Types and Machining Methods for Intelligent Assessment of the Technical Mill of Mobile Machines for Agro-Industrial Production

The article provides a critical review of current research on the use of machine learning (ML) methods for identifying the technical state of units and mechanisms of agro-industrial production machines for different types of diagnostic signals (vibration, acoustic, temperature, vice, etc.). The exchange of threshold diagnostic strategies is shown and the need for an intelligent technical service system is highlighted, which integrates a sensor base and adaptive MN algorithms for online assessment of the plant, predictive maintenance and minimization of untransferable downtime. The concept of complex signal classification and selection of algorithms is proposed and creates a framework for scaling solutions adapted to specific agro-industrial production machines calls.

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

Одержано (Received) 21.05.2025

Прорецензовано (Reviewed) 22.05.2025

Прийнято до друку (Approved) 23.05.2025