

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ЛЬВІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ПРИРОДОКОРИСТУВАННЯ
ФАКУЛЬТЕТ МЕХАНІКИ, ЕНЕРГЕТИКИ ТА ІНФОРМАЦІЙНИХ
ТЕХНОЛОГІЙ
КАФЕДРА МАШИНОБУДУВАННЯ

К В А Л I Ф I К A Ц I Й Н A Р O B O T A
другого (магістерського) рівня вищої освіти

на тему:

ПІдвищення ефективності роботи обладнання
використанням прогнозного обслуговування на
основі виявлення аномалій методами машинного
навчання в умовах ТОВ «КРАФТ ІННОВЕЙШН»

Виконав: студент VI курсу, групи Маш-63

Спеціальності 133 Галузеве машинобудування
(шифр і назва)
Ігор ЖУРКЕВИЧ
(Ім'я та прізвище)

Керівник: д.т.н., проф. Віталій ВЛАСОВЕЦЬ
(Ім'я та прізвище)

Дубляни 2024

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ЛЬВІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ПРИРОДОКОРИСТУВАННЯ
ФАКУЛЬТЕТ МЕХАНІКИ, ЕНЕРГЕТИКИ ТА ІНФОРМАЦІЙНИХ
ТЕХНОЛОГІЙ
КАФЕДРА МАШИНОБУДУВАННЯ

«ЗАТВЕРДЖУЮ»

Зав. кафедри _____

(підпис)

д.т.н., професор Власовець В.М.

“12” вересня 2024 р.

З А В Д А Н Н Я

на кваліфікаційну роботу студенту
Журкевичу Ігорю Романовичу

1. Тема роботи: **«Підвищення ефективності роботи обладнання використанням прогнозного обслуговування на основі виявлення аномалій методами машинного навчання в умовах ТОВ «КРАФТ ІННОВЕЙШН»**

Керівник роботи: Власовець Віталій Михайлович, д.т.н., проф.

Затверджена наказом по університету від 12.09.2024 року № 616/к-с

2. Строк здачі студентом закінченої роботи 06.12.2024 року

3. Вихідні дані: Літературні джерела за тематикою кваліфікаційної роботи відомих технологічних процесів виробництва та розрахунків технологічного обладнання; Матеріали навчальної, методичної довідкової та наукової літератури; Методики визначення економічної ефективності впровадження нового технологічного рішення.

4. Перелік питань, які необхідно розробити:

1. Огляд інформаційних джерел;

2. Виявлення аномалій в роботі обладнання;

3. Впровадження заходів для виявлення аномалій в роботі обладнання;

Основні результати і висновки;

Список використаних джерел.

5. Перелік ілюстративного матеріалу:

Ілюстративний матеріал представити у вигляді презентації у застосунку Microsoft PowerPoint: результати підготовки даних та їх обробка.

6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада Консультанта	Підпис, дата		Відмітка про виконання
		завдання видав	завдання прийняв	
1,2,3,4	Власовець В.В.. д.т.н., проф. кафедри машинобудування			

7. Дата видачі завдання: 12.09.2024 р.

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів кваліфікаційної роботи	Строк виконання етапів роботи	Відмітка про виконання
1.	<i>Виконання первого розділу</i>	<i>12.09.24-26.09.24</i>	
2.	<i>Виконання другого розділу</i>	<i>27.09.24-16.10.24</i>	
3.	<i>Виконання третього розділу</i>	<i>17.10.24-05.11.24</i>	
4.	<i>Завершення оформлення розрахунково-пояснювальної записки. Завершення роботи в цілому</i>	<i>6.11.24-06.12.24</i>	

Студент Ігор ЖУРКЕВИЧ
(підпись)

Керівник роботи Віталій ВЛАСОВЕЦЬ
(підпись)

УДК 631.332

Підвищення ефективності роботи обладнання використанням прогнозного обслуговування на основі виявлення аномалій методами машинного навчання в умовах ТОВ «КРАФТ ІННОВЕЙШН»

Журкевич І.Р. Кваліфікаційна робота. – Дубляни, Львівський національний університет природокористування, 2024р.

69 с. текст. част., 24 рис., 3табл., 68 джерел інформації.

Мета досліджень - Підвищення ефективності роботи обладнання використанням прогнозного обслуговування на основі виявлення аномалій методами машинного навчання.

Завдання досліджень:

1. Оцінити особливості та сучасний стан прогнозного обслуговування на основі виявлення аномалій методами машинного навчання.
2. Дослідити поточні труднощі та обмеження, пов'язані з його впровадженням.
3. Розробити модель машинного навчання для виявлення аномалій в роботі обладнання
4. Запропонувати напрямки подальших досліджень.

ЗМІСТ

Вступ	7
Розділ I ОГЛЯД ІНФОРМАЦІЙНИХ ДЖЕРЕЛ	9
1.1 Огляд методів виявлення аномалій	9
1.2 Короткий опис принципу GAN	14
1.3. Аналіз характеристик складних незбалансованих даних	16
1.4. Внутрішньокласові та міжкласові дисбаланси міжкласові дисбаланси в режимах несправностей	17
Розділ II ВИЯВЛЕННЯ АНОМАЛІЙ В РОБОТИ ОБЛАДНАННЯ	27
2.1. Методи обробки незбалансованих даних	27
2.2. Підходи, що використовуються для обробки часових рядів та даних частотної області	28
2.3 Навчання з перенесенням	38

Розділ III ВПРОВАДЖЕННЯ ЗАХОДІВ ДЛЯ ВИЯВЛЕННЯ АНОМАЛІЙ В РОБОТІ ОБЛАДНАННЯ	40
3.1. Виявлення аномалій	40
3.2 Проблеми та інтерпретованість методів в умовах незбалансованості змішування у малих вибірках	42
3.3 Пристрої для контролю енергоспоживання	47
Висновки та пропозиції	58
Список використаних джерел	62

ВСТУП

Актуальність теми. Актуальність досліджень у напрямку підвищення ефективності роботи обладнання за допомогою прогнозного обслуговування, заснованого на виявленні аномалій методами машинного навчання, обумовлена необхідністю зменшення простоїв, оптимізації витрат на ремонт і забезпечення безпечної експлуатації. Традиційні методи технічного обслуговування, як-от планове або реактивне, часто є недостатньо ефективними, оскільки вони не враховують реальний стан обладнання та не здатні передбачити відмови. Використання машинного навчання для аналізу великих обсягів даних, таких як вібрації, температура, струм і шум, дозволяє виявляти приховані закономірності та аномалії, які сигналізують про потенційні збої. Це забезпечує можливість раннього втручання, зменшує ризики аварій і підвищує продуктивність обладнання. З огляду на зростаючі вимоги до автоматизації, цифровізації та ефективного управління виробничими процесами, подібні дослідження є особливо актуальними для промисловості, де технічні простої можуть призводити до значних фінансових втрат. Прогнозне обслуговування, засноване на аналізі аномалій, стає важливою складовою сучасних підходів до управління обладнанням, сприяючи впровадженню інновацій і підвищенню конкурентоспроможності підприємств.

Ступінь визначення досліджуваної проблеми. Виявлення аномалій у роботі обладнання для підвищення його ефективності здійснюється різними методами машинного навчання, які включають алгоритми кластеризації (як-от DBSCAN), моделі для аналізу щільності даних (Isolation Forest) та нейронні мережі, зокрема автоенкодери. Ці підходи дозволяють виявляти аномальні відхилення у параметрах роботи, таких як температура, струм, вібрація та інші показники, через виявлення несподіваних патернів або відхилень від нормального розподілу даних. Перспективи досліджень у цій галузі включають інтеграцію методів машинного навчання з IoT-платформами для отримання даних у реальному часі, використання глибокого навчання для аналізу складних часових рядів і створення адаптивних моделей, які здатні динамічно враховувати зміни у характеристиках обладнання. Це

відкриває можливості для прогнозування відмов ще до їх виникнення, оптимізації графіків обслуговування та зменшення витрат, а також покращення надійності і продуктивності роботи систем, особливо в умовах високої технологічної складності сучасних виробничих процесів.

Мета досліджень - Підвищення ефективності роботи обладнання використанням прогнозного обслуговування на основі виявлення аномалій методами машинного навчання.

Завдання досліджень:

1. Оцінити особливості та сучасний стан прогнозного обслуговування на основі виявлення аномалій методами машинного навчання.
2. Дослідити поточні труднощі та обмеження, пов'язані з його впровадженням.
3. Розробити модель машинного навчання для виявлення аномалій в роботі обладнання
4. Запропонувати напрямки подальших досліджень.

Об'ектом роботи є обладнання, що потребує моніторингу його експлуатації.

Предметом роботи є процеси що породжують аномалії в його роботі та моделі машинного навчання, що дозволяють їх виявити завчасно до критичного стану.

Методи дослідження. У роботі були використані такі методи як спостереження, порівняння, метод статичного аналізу, метод відображення наукових досліджень у графічній, а також табличній формах, алгоритми машинного навчання DBScan та Isolation Forest.

РОЗДІЛ 1

ОГЛЯД ІНФОРМАЦІЙНИХ ДЖЕРЕЛ

1.1. Огляд методів виявлення аномалій

Промислова стратегія Німеччини до 2030 року" підкреслює переконання Німеччини в тому, що ключові проривні інновації лежать у площині діджиталізації, зокрема застосування штучного інтелекту [2]. Китайський "14-й п'ятирічний план і Концепція розвитку до 2035 року" підкреслює акцент на алгоритмах штучного інтелекту, виступаючи за глибоку інтеграцію інтелектуального виробництва в різних галузях промисловості з метою просування виробничого сектору до високотехнологічних, інтелектуальних і екологічно чистих досягнень. У глобальному промисловому ландшафті, що розвивається, механічне обладнання стикається з проблемою задоволення потреб у підвищенні ефективності, точності та управлінні складними виробничими завданнями, і все це в динамічних і складних умовах експлуатації, які часто призводять до відмов машин і інцидентів з безпекою [3]. Отже, значення моніторингу стану та діагностики несправностей машин і обладнання неможливо переоцінити, оскільки вони мають вирішальне значення для запобігання великим аваріям і підвищення ефективності виробництва. Основна мета діагностики несправностей полягає у встановленні взаємозв'язку між даними моніторингу машин і різними станами здоров'я, що забезпечує безперебійну роботу машин і обладнання [4]. Традиційні методи діагностики несправностей виявляються неефективними через їхню залежність від априорних знань і ручної обробки, що ускладнює вилучення ознак вручну для аналізу несправностей у складних, високоавтоматизованих сучасних машинах і обладнанні [5].

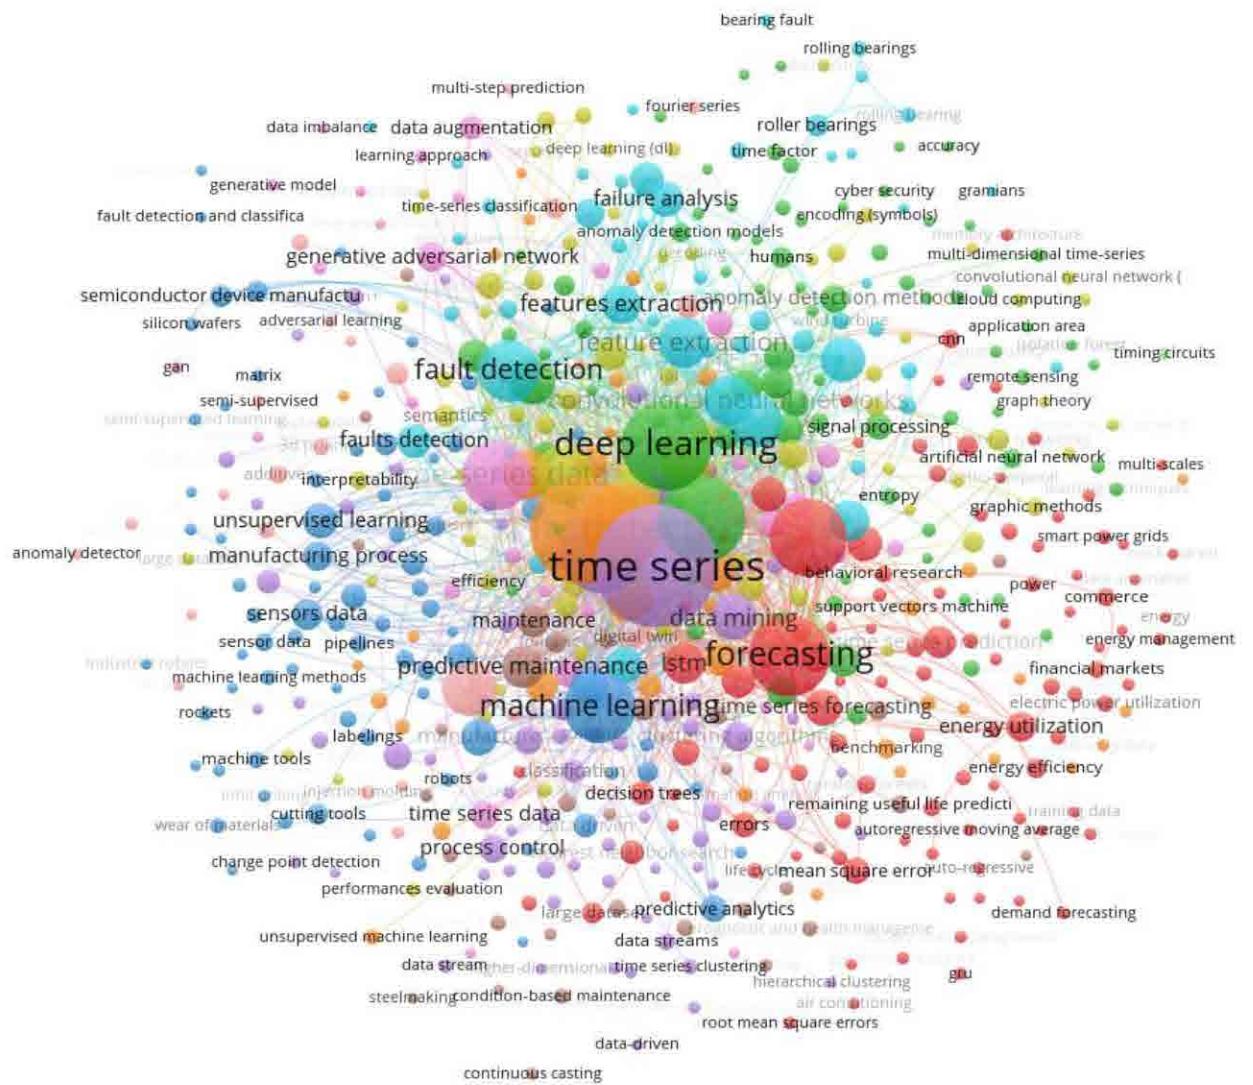


Рисунок 1.1 Розподіл кластерів досліджень за проблематикою використання рядів даних для визначення аномалій в інноваційних проектах машинобудівних підприємств

Застосування методів машинного навчання, таких як штучні нейронні мережі (ШНМ) [6], машини опорних векторів (МОВ) [7] і глибокі нейронні мережі [8], значно зменшило вплив людського фактора на діагностику несправностей. Методи діагностики несправностей на основі глибокого навчання знаходять широке застосування в обробці великих масивів даних про машини, чому сприяє широке впровадження недорогих датчиків і підключення до Інтернету (Zhao et al., 2019). Ця тенденція створює передумови для інтелектуальних методів діагностики

несправностей на основі даних, оскільки багато методів глибокого навчання, що розвиваються, постійно досягають похвальних результатів у моніторингу стану машин. Однак для того, щоб моделі глибокого навчання демонстрували ефективні і точні результати діагностики несправностей в реальних сценаріях після навчання, значна кількість категорій і збалансований розподіл розмірів вибірок мають вирішальне значення під час навчання моделі. У практичних сценаріях поступовий процес виникнення відхилень або відмов у ключових компонентах механічних систем (Yilmaz & Sýnmazçelik, 2007) обмежує кількість даних, зібраних під час аномальних станів, тоді як у нормальному робочому стані легко отримати велику кількість даних, що призводить до проблеми дисбалансу даних (Lei et al., 2020). Дисбаланс даних, коли кількість зібраних даних про несправності значно менша, ніж у нормальнích умовах, призводить до зміщення моделі в методах діагностики несправностей на основі даних (Shen et al., 2023). Останніми роками з'явилися численні підходи до вирішення проблеми незбалансованої класифікації, зосереджені на розробці методів класифікації, які одночасно забезпечують точність як для більшості, так і для меншості класів у вибірках даних. Ці підходи працюють на трьох основних рівнях: попередня обробка даних (Lin та ін., 2018), вилучення ознак (Maldonado та ін., 2014) та вдосконалення класифікатора (Batuwita & Palade, 2010). Розвиток досліджень у сфері вилучення ознак та вдосконалення класифікаторів відстає від розвитку досліджень у сфері попередньої обробки даних. Виділення ознак охоплює кілька відомих методів, зокрема алгоритм K-OFSD (K-nearest neighbors Online Feature Selection), запропонований Чжоу та ін. (2017), призначений для покращення відокремлюваності між вибірками класів більшості та меншості.

Крім того, Maldonado та ін. представили технологію масштабного коефіцієнта як вбудовану стратегію для вибору ознак (Maldonado & López, 2018). З точки зору вдосконалення класифікатора, Хан та ін. представили надійну, чутливу до вартості представлення ознак глибоку нейронну мережу, здатну автономно навчатися як мажоритарним, так і міноритарним класам (Khan et al., 2018). Вонг та ін. запропонували ансамбль чутливої до витрат глибокої нейронної мережі (CSDE)

(Wong et al., 2020), який одночасно використовує випадкову недодискретизацію та пошарове вилучення ознак у прихованому шарі глибокої нейронної мережі. Ці стратегії вдосконалення класифікатора насамперед акцентують увагу на чутливому до витрат і ансамблевому навчанні. На рівні попередньої обробки даних дослідники в основному маніпулюють балансом набору даних, збільшуячи (зменшуючи) кількість вибірок за допомогою методів передискретизації для класу меншості (більшості). Методи повторної вибірки поділяються на три групи: недостатня вибірка, надмірна вибірка та змішана вибірка (He & Garcia, 2009). Метод надмірної вибірки покращує продуктивність класифікаційної моделі за рахунок розширення даних, оскільки при класифікації незбалансованих даних класифікатор часто прагне передбачити клас більшості, щоб задовольнити загальну тенденцію до зменшення помилки, і через недостатню кількість зразків у класі меншості класифікатор не в змозі адекватно вивчити особливості класу, що призводить до неправильної класифікації зразків у класі меншості, розширяючи дані, класифікатор може краще вивчити особливості класу меншості, зменшивши упередженість і, таким чином, краще працювати з різними розподілами вибірки. Методи відбору ознак та зваженої функції втрат можуть вирішити проблеми дисбалансу без зміни обсягу даних, але вони мають певні обмеження. Відбір ознак може бути складним і привести до втрати інформації. Аналогічно, зважені функції втрат вимагають ретельного підбору ваг і чутливі до екстремальних дисбалансів, що вимагає тривалого експериментального налаштування і обмежує їхню ефективність у різних сценаріях дисбалансу. На противагу цьому, розширення даних за рахунок передискретизації пропонує більш узагальнююче та адаптивне рішення, яке ефективно справляється з більшістю проблем, пов'язаних з дисбалансом. Крім автономного застосування, багато підходів поєднують алгоритми повторної вибірки з відбором ознак, покращенням класифікатора тощо. Юань та ін. надали грунтовний огляд таких інтегрованих підходів (Yuan et al., 2023).

Порівняно з традиційними методами доповнення даних, генеративні моделі, такі як варіаційні автокодерні мережі (VAEs) (Kingma & Welling, 2022) та генеративні змагальні мережі (GANs; Goodfellow et al., 2020), можуть слугувати

ефективними інструментами для генерації вибірки в доповненні даних. Хоча метод мережевого синтезу є більш складним, отримані зразки демонструють підвищенну реалістичність і різноманітність. Нещодавно популярна модель дифузії також була застосована для діагностики незбалансованих несправностей. Янг та ін. використовували дифузійну модель для генерування даних перед діагностикою незбалансованих дефектів. Однак цей підхід виявляється менш придатним для сценаріїв з невеликою вибіркою, і його застосовність ще не була повністю продемонстрована (Yang et al., 2024). GAN, як генеративна модель, що використовує змагальне навчання, демонструє потужний потенціал для генерації зображень, даючи більш реалістичні зразки. Завдяки широким дослідженням та ітеративним вдосконаленням оригінальної GAN, її продуктивність значно покращилася. Численні запропоновані варіанти GAN ще більше покралили його адаптивність до різних типів даних у різних галузях, що демонструє зростання кількості статей, пов'язаних з GAN в галузі діагностики несправностей з моменту їх появи. Існує кілька комплексних оглядів застосування мереж GAN у діагностиці несправностей, наприклад, дослідження застосування машинного навчання в машинній діагностиці несправностей у три етапи (Lei та ін., 2020). Пан та ін. класифікували методи інтелектуальної діагностики несправностей на основі GAN за трьома аспектами: доповнення даних, трансферне навчання та виявлення аномалій (Pan et al., 2022). Однак їхня робота в основному знайомить із застосуванням і впливом традиційного машинного навчання, глибокого навчання і навчання з перенесенням, з обмеженою кількістю деталей про принципи і методи технології GAN. Брофі та ін. заглибилися в еволюцію структури GAN і зміни функції втрат при обробці даних часових рядів на основі GAN (Brophy et al., 2022). Їхнє всебічне дослідження охоплює класифікацію та методологію обробки неперервних і дискретних часових рядів за допомогою GAN, хоча в ньому лише коротко розглянуто кілька промислових застосувань. Слід зазначити, що вони не охопили методи діагностики несправностей, засновані на технології GAN, не були вичерпними. Крім того, в цих роботах рідко розглядалися сценарії, пов'язані з шумовим дисбалансом, внутрішньокласовим і міжкласовим дисбалансом, а також

багатокласовим дисбалансом, які більше відповідають потребам діагностики в промислових умовах. Отже, в цій статті проводиться всебічний огляд алгоритмів діагностики несправностей на основі GAN, щоб запропонувати розуміння застосування GAN в діагностиці несправностей і стимулювати розвиток технології GAN.

1.2 Короткий опис принципу GAN

Управління та обслуговування промислового обладнання часто призводить до стагнації виробництва, насамперед через несвоєчасну діагностику та виявлення несправностей, що потенційно може привести до інцидентів, пов'язаних з безпекою. Фундаментальною проблемою, що перешкоджає моніторингу несправностей і технічному обслуговуванню обладнання, є дефіцит зразків несправностей. Дисбаланс між даними про несправності і нормальними даними, особливо в сценаріях з обмеженою кількістю зразків, є значною перешкодою для розробки точних інтелектуальних моделей діагностики. Крім того, варіації характеристик даних, таких як амплітуда і частота, при різних швидкостях і навантаженнях вимагають комплексного підходу. Покладатися лише на окремі зразки в промисловому контексті недостатньо, оскільки це не відповідає вимогам забезпечення стабільної, безпечної та ефективної роботи обладнання в мінливих умовах і складних структурах. Побудова моделі діагностики несправностей вимагає врахування декількох факторів, включаючи наявність надлишкового шуму під час роботи обладнання, різний ступінь виходу обладнання з ладу з плином часу, дисбаланс між зразками і декількома класами через нерівномірність пошкоджень різних компонентів, а також дисбаланс, що виникає в результаті яскраво виражених характеристик часових рядів механічних несправностей. Дані в промислових умовах, як правило, демонструють дисбаланс, а традиційні моделі класифікації, такі як згорткова нейронна мережа (ЗНМ) (Chua, 1998), оптимізовані для загальної точності класифікації, часто демонструють зсув у бік класів, що становлять більшість. Цей зсув може ненавмисно ігнорувати класи меншин, які можуть мати

більшу дослідницьку значущість. Підходи до вирішення проблеми незбалансованої класифікації насамперед зосереджені на попередній обробці даних, виокремленні ознак та вдосконаленні класифікатора. Було проведено багато досліджень традиційних методів обробки незбалансованих даних, зокрема в таких сферах, як обробка даних, вирівнювання алгоритмів і навчання ансамблів. Алгоритми вирівнювання включають вартісно-чутливе навчання в процес прийняття рішень базових класифікаторів шляхом коригування ваги неправильно класифікованих вибірок меншин, пропонується інтегрувати цей вартісно-чутливий підхід в CNN (Chung et al., 2015). Два найпоширеніші методи попередньої обробки вибірок даних - це надмірна та недостатня вибірка. Основна ідея полягає в тому, щоб збалансувати всю вибірку, збільшивши кількість зразків меншості або вилучивши деякі зразки з класу більшості. Серед них методи надвибірки відіграють важливу роль, зберігаючи важливу інформацію порівняно з альтернативними методами. Однак типові методи надвибірки, включаючи випадкову надвибірку (Bennin та ін., 2018), синтетичну надвибірку меншості (SMOTE) (Chawla та ін., 2002) та ADASYN (адаптивну синтетичну) (Не та ін., 2008), створюють проблеми, такі як надмірне узагальнення, перекриття вибірок, внесення шуму та ігнорування граничних вибірок. Вей та ін. запропонували метод надмірної вибірки меншин, зваженої на більшість, на основі когерентної ієрархічної кластеризації (Cluster-MWMOTE) (Wei et al., 2020), який дозволяє уникнути ігнорування невеликих за розміром підмножин меншин, віддалених від екземплярів класу більшості, і досягти кращих результатів. Однак, по суті, SMOTE є інтерполяційною стратегією, що генерує проміжні вибірки в околицях кількох точок вибіркового простору для розширення позитивних вибірок, цей метод критикують за його механічний характер і нездатність адекватно відобразити цілісний розподіл вихідних вибірок. Однак в останні роки методи генерації вибірок на основі мережі GAN певною мірою вирішили ці проблеми, а підхід на основі GAN є спеціалізованим методом передискретизації з точки зору синтезу даних. Базова структура моделі GAN (Goodfellow et al., 2020) показана на рис. 2 і складається з генераторної моделі G (генератор) та дискримінаторної моделі D (дискримінатор), які беруть участь у двосторонній грі з нульовою сумою, де вони

конкурують між собою. Метою генератора G є вивчення розподілу ймовірностей на основі заданих даних, який відображає вхідний випадковий шум у дані спостережень. На противагу цьому, дискримінатор D має на меті оцінити, чи відповідають дані, отримані генератором G, розподілу ймовірностей реальних вибірок. Ця функція схожа на бінарний класифікатор, який оцінює ймовірність того, що згенеровані дані є реальними, зі значеннями від 0 до 1, де ідеальним результатом була б ймовірність 0,5 (Goodfellow et al., 2020). GAN має чудові показники в синтезі зображень, комп'ютерному зорі, обробці природної мови та медичному виявленні завдяки своїй надійній здатності підлаштовуватися під реальний розподіл даних (Hong et al., 2019). Стратегії передискретизації на основі GAN можуть збільшити кількість псевдовибірок з високою схожістю, тим самим оптимізуючи процес навчання моделей діагностики несправностей і підвищуючи точність діагностики. Процес навчання, заснований на ідеї змагальної гри GAN, додано до CNN як стратегію регуляризації (Han et al., 2019), щоб покращити здатність моделі до узагальнення.

1.3 Аналіз характеристик складних незбалансованих даних

Зашумлені вибірки часто демонструють суттєві відмінності від інших нормальніх вибірок. Коли категорії даних вибірки чіткі та чисті, навчання моделі може досягти швидкої збіжності. Однак наявність зашумлених елементів у навчальній вибірці значно погіршує швидкість і точність навчання, а в деяких випадках збіжність може взагалі не досягатися. Шум у малих вибірках незбалансованих даних проявляється у вигляді випадкових помилок, спричинених аномальними факторами, коли розмір вибірки обмежений, що призводить до дисбалансу в пропорціях наявних категорій вибірки. Цей шум сильно заважає навчанню з малою кількістю пострілів. Метод BSMOTE (Borderline-SMOTE), запропонований Ханом та ін., використовує метод k-NN (k-Nearest Neighbors) для обчислення евклідової відстані для визначення k найближчих сусідів вибірки (Han et al., 2005). Якщо властивості k найближчих сусідів не пов'язані з вибіркою, це вважається шумом у незбалансованих даних.Хоча метод k-NN є універсальним, неправильне

значення k може призвести до недооцінки або переоцінки шуму, ігнорування граничних вибірок або справжнього шуму. Метод обробки шуму на основі евклідової відстані, запропонований Ліном та ін., ідентифікує зразки з більшою евклідовою відстанню від центру класу як справжній шум (Batuwita & Palade, 2010). Однак цей метод підходить лише для сферичних наборів даних. В якості альтернативи Ju та ін. розглядають вибірки з більшою евклідовою відстанню від центру класу та меншою щільністю к найближчих сусідів, що належать до того ж класу, як шум (Ju et al., 2016). Такий комбінований підхід з використанням евклідової відстані та щільності сусідів певною мірою покращує виявлення шуму. Метод передискретизації, представлений K-means SMOTE (Douzas et al., 2018), використовує кластеризацію для розділення шуму. Зокрема, якщо кількість екземплярів класу більшості в субкластері перевищує кількість екземплярів класу меншості, зразки класу меншості в субкластері класифікуються як шум.

1.4 Внутрішньокласові та міжкласові дисбаланси і міжкласові дисбаланси в режимах несправностей

Міжкласовий дисбаланс відноситься до великої різниці в кількості даних між різними категоріями, що також є основною проблемою в області діагностики несправностей. Внутрішньокласовий дисбаланс виникає, коли один клас розподіляється на декілька підкласів, кожен з яких має різну кількість даних, що обговорювалося в літературі (Japkowicz, 2001; Japkowicz & Stephen, 2002) та інших роботах. Коли в промислових машинах та обладнанні виникає певний клас відмов, зміна швидкості обертання валу та різниця в навантаженні призводить до класових характеристик режиму відмови (Shen et al., 2021; An et al., 2022), що проявляється як міграція точок у просторі даних. Наявність або відсутність внутрішньокласового дисбалансу пов'язана з тяжкістю несправності при одному і тому ж стані несправності, за нормальних обставин несправні машини спочатку відчувають більш високу частоту незначних несправностей, які можуть перерости в більш серйозні несправності через кумулятивні ефекти. Ця ескалація впливає на інтелектуальну діагностику серйозних несправностей. У складних умовах експлуатації можуть виникати одночасні несправності в декількох місцях машин і обладнання, що

призводить до появи різних підкатегорій несправностей. Деякі компоненти можуть мати більшу кількість зразків несправностей, тоді як інші - меншу. Однак, всі ці зразки несправностей значно переважають над нормальними зразками. Практичний процес часто вимагає одночасного управління декількома класами меншості і більшості, що призводить до багатокласового дисбалансу в промисловому середовищі. Багатокласовий дисбаланс при малій вибірці дуже схильний до перекриття класів через велике співвідношення кількості класів меншості до класу більшості (Mukherjee et al., 2019), як показано на рис. 4, який є схемою внутрішньокласового дисбалансу, міжкласового дисбалансу і багатокласового дисбалансу, і легко проігнорувати деякі більш важливі граничні зразки під час практичної обробки.

Часовий ряд - це послідовність випадкових величин, відсортованих за часом, де спостереження згруповані на основі регулярних закономірностей або тенденцій у часі.

Загалом, часові ряди можна описати статистичними характеристиками, такими як середнє значення, дисперсія, ексцес і крутизна, які є важливими для ранньої діагностики несправностей на основі ручної обробки сигналу. В рамках інтелектуальних моделей діагностики несправностей дисбаланс даних про несправності вібраційного сигналу суттєво впливає на точність діагностики. Цей дисбаланс в першу чергу проявляється в різних типах несправностей, їх виникненні в різних вузлах синхронізації і різній тривалості несправностей. Певні специфічні умови роботи, такі як аномальне навантаження, швидкість і шум навколошнього середовища, також призводять до дисбалансу даних вибірки в межах набору часових рядів. Часова незбалансованість вібраційного сигналу також проявляється в розбіжності між довгостроковими і короткостроковими прогнозами терміну служби машини, що зумовлює необхідність сегментації вибірок даних на різних етапах. Позначення одного циклу як класу меншості, а решти циклів як класу більшості призводить до багатокласового дисбалансу з високим коефіцієнтом дисбалансу, що ілюструє, що дисбаланс часового ряду збігається з декількома типами дисбалансу. Часовий ряд вібраційного сигналу характеризується високою розмірністю даних, сильними кореляціями між точками даних і шумовими перешкодами. Вирішення проблеми складних взаємозв'язків у високорозмірних змішаних

часових рядах вимагає застосування спеціальних алгоритмів і методів для усунення надлишкового шуму з даних.

З моменту свого створення GAN стали однією з найперспективніших методологій у сфері глибокого навчання. Працюючи як модель неконтрольованого навчання, GAN широко застосовуються в комп'ютерному зорі та обробці зображень. Analogічно, в області діагностики механічних несправностей GAN продемонстрували чудову продуктивність. Навчання в умовах суперництва дозволяє генерувати дані, які дуже нагадують реальні дані з більш високого розміру. Ця здатність виявляється корисною для оптимізації незбалансованих завдань класифікації, особливо в сценаріях з обмеженою вибіркою. Використання мережі GAN для доповнення незбалансованих даних довело свою ефективність в успішному вирішенні різних завдань діагностики несправностей в промислових умовах. У цьому розділі систематично розглядається і узагальнюється принцип обробки незбалансованих даних мережею GAN і його застосування в діагностиці несправностей критично важливого обладнання і ключових компонентів з використанням журналів і конференц-доповідей, опублікованих за останні роки.

Контрольовані характеристики процесу навчання моделі GAN використовуються для опису варіантів і застосувань GAN з неконтрольованим навчанням, контролюваним навчанням і напівконтрольованим навчанням.

З моменту появи GAN він супроводжувався власною нестабільністю навчання, спричиненою зникненням градієнта та розпадом шаблону, а початкові вдосконалення змінювалися від мінімізації розбіжності JS (розбіжності Дженсена-Шеннона) (Lin, 1991) до мінімізації розбіжності KL (розбіжності Кульбака-Лейблера) (Kullback & Leibler, 1951), тобто вилучення "1" з рівняння (3), але початкова опукла оптимізація, що ґрунтується на просторі функцій густини ймовірності не можна довести, що вона збігається в просторі параметрів. Зокрема, при застосуванні методів на основі GAN для вирішення проблеми незбалансованості малих вибірок проблема колапсу мод буде більш серйозною, тому було розроблено численні стратегії вдосконалення як для усунення недоліків, притаманних GAN, так і для покращення продуктивності на малих незбалансованих наборах даних. Зорткова структура в DCGAN може краще витягувати ознаки у зразках, покращувати

стабільність процесу навчання і якість згенерованих зразків, згорткова структура повинна використовуватися для генерації даних злиття з декількох датчиків (Liu et al., 2020), і двовимірна структура згортки DCGAN була змінена (Wang et al., 2021b), а одновимірна згортка була використана для кращої генерації даних про час у вібраційному сигналі. Ця заміна структури мережі була використана як базова структура в подальшому дизайні структури GAN, і вона отримала широке застосування. VAEGAN походить від схожості функцій і структур декодера в VAE і генератора в GAN, а вихідні дані стискаються в прихований простір за допомогою кодера, і простір шуму, який відбирається близько до центру вихідного простору вибірки, може забезпечити більш надійний вхідний латентний вектор для структури GAN. Структура VAEGAN використовується для реалізації діагностики несправностей промислових часових рядів (Jiang et al., 2019), а її кодер, декодер і дискримінатор використовують щойно згадану згорткову мережу, і, що цікаво, згадується, що перед усією структурою GAN додається екстрактор ознак, що дозволяє зменшити розмір вхідних даних. На противагу цьому, техніка вибірки ковзним вікном використовується для передискретизації вихідних зразків (Wang et al., 2023c), а потім вона використовується як адаптивна стратегія для наступних завдань діагностики несправностей VAEGAN. Реконструкція фазового простору (RPS) є новою формою даних у діагностичній стратегії VAEGAN (Rathore & Harsha, 2023). Lei та ін. (2024) поєднують VAEGAN і механізм самоуваги для покращення якості згенерованих зразків. Крім того, Shirshahi та ін. (2024) використовують VAEGAN для дослідження причинно-наслідкових зв'язків між змінними, щоб визначити шляхи поширення і першопричини відмов промислових установок. Sun та ін. (2024) покращують міждоменні дані і діагностують несправності за допомогою VAEGAN, захищаючи при цьому конфіденційність даних.

Подібно до VAEGAN, який відображає реальні дані назад у прихований простір, BiGAN (Donahue et al., 2017) інтегрує закодовані вектори реальних даних з реальними даними і надсилає їх у дискримінатор з комбінацією псевдо-зразків і векторів шуму для формування двосторонньої структури. BiGAN, навчені лише на нормальніх або здорових зразках, показали багатообіцяючі результати в діагностиці несправностей промислових роботів (Pu et al., 2022, 2023a) або точної діагностики 3D-принтерів (Li et al., 2021a).

CycleGAN (Zhu et al., 2017) використовується для вивчення зв'язку відображення даних між двома доменами зразків, а циклічна втрата узгодженості змушує згенеровані зразки підтримувати характеристики даних вихідного домену при вивчені розподілу даних цільового домену. CycleGAN з посилання (Zhao & Huang, 2021) є хорошим прикладом діагностики несправностей підшипників кочення; CycleGAN використовується як доповнення даних про промислові несправності (Pu et al., 2023b), але він переробляє нове циклічно узгоджене генеративне змагальне обмеження; Для підтримки стабільних умов експлуатації та збереження узгодженості несправностей на основі CycleGAN було додано два додаткові дискримінатори (Zhao et al., 2022), щоб згенеровані зразки відповідали цільовим робочим умовам і зберігали інваріантну для домену інформацію про несправності. Крім того, Guo та ін. (2024b) використовували CycleGAN для виявлення дефектів у зразках інфрачервоної термографії незбалансованих підшипників кочення, а Qin та ін. (2024) побудували цифрову модель-близнюка на основі взаємозв'язку між вібраційним відгуком і вимірювальними сигналами. На додаток до вищезазначених варіантів GAN, існують також GAN на основі модулів та структурних удосконалень, таких як еталонний (Zhang et al., 2021c), який розділяє класифікатор підпорядкованих дискримінаторів в InfoGAN (Chen et al., 2016) та StyleGAN (Karras et al., 2019) для застосування в галузі діагностики несправностей (Wang et al., 2021a).

Модифікований варіант GAN на основі модуля також показує різницю в структурній формі функції втрат через зміну загальної структури. Однак є деякі варіанти GAN, які безпосередньо модифікують функцію втрат на основі недоліків метрики GAN. Класичні WGAN (Wasserstein GAN) та WGAN-gp (Wasserstein GAN з градієнтним штрафом) базуються на покращенні функції втрат, а відстань між розподілами вимірюється відстанню Вассерштейна.

Використовуючи WGAN, Фан та ін. (2022) і Ван та ін. (2021) розширили сферу застосування на невеликі вибірки даних для підшипників кочення, що значно підвищило точність діагностики несправностей. Вдосконалений мінімальний блок стробування інтегрований в генератор і дискримінатор WGAN для отримання прихованої інформації з часових даних потокової індустрії (Zhang et al., 2023b), а навчений стековий автокодер

використовується для виведення необхідних векторів шуму для отримання високоякісних зразків перед тим, як запропонувати генератор в WGAN (Rathore & Harsha, 2022). WGAN-gp також широко використовується: існує просте застосування WGAN-gp (Shang et al., 2023), в той час як новий дискримінатор розроблений з використанням спектральної нормалізації (SN) (Zhang et al., 2020a), а загальна діагностика несправностей базується на сигналі вібрації для досягнення розпізнавання ознак, в той час як вона використовує модель на основі WGAN-GP для виконання діагностичного завдання за допомогою поточних сигналів (Li et al., 2021b), вона спочатку застосовує операцію фільтрації до вхідних електричних сигналів.

Порівняно з оригінальною GAN, WGAN та WGAN-GP з модифікованими функціями втрат демонструють суттєве покращення стабільності навчання та якості згенерованих псевдо-зразків. Це свідчить про те, що поєднання покращення функцій втрат з модульними покращеннями може сприяти подальшому удосконаленню діагностики несправностей. Наприклад, інтеграція функцій втрат VAEGAN і WGAN була використана для досягнення більш точної діагностики несправностей (Liu та ін., 2021a; Wang та ін., 2023b). Крім того, відстань Вассерштейна продемонструвала чудову продуктивність при використанні в CycleGAN (Pu та ін., 2023a). Об'єднання функцій втрат у VAEGAN і WGAN-GP покращує можливості діагностики несправностей (Miao та ін., 2022; Guo та ін., 2024a). Крім цих удоскональень функції втрат, деякі дослідження застосовують метод LSGAN, який використовує функцію найменших квадратів втрат замість традиційної функції втрат GAN. Цей підхід не тільки підвищує стабільність навчання, але й полегшує діагностику несправностей у сценаріях планетарного приводу (Zhang et al., 2024b).

GAN для керованого навчання. Умовно-генеративна змагальна мережа (CGAN) (Mirza & Osindero, 2014) модифікує методологію навчання оригінальної GAN шляхом включення умовних обмежень через додаткову інформацію про мітки, замість того, щоб покладатися виключно на випадковий шум. Цей підхід спрямовує модель на генерування цільових даних, обумовлюючи вхідний шар як генератора, так і дискримінатора за допомогою зпитих міток. Отже, модель CGAN здатна створювати контролювані та специфічні зразки.

На основі структури DCGAN і в поєднанні з мітками категорій, Luo та ін. (2021) і Peng та ін. (2022a) успішно фіксують справжній розподіл вихідних даних вібрації за допомогою моделі CDCGAN. Аналогічно, модель CGAN може бути застосована для посилення невеликої кількості зразків несправностей для ефективного і точного виявлення несправності короткого замикання двигуна (Li et al., 2021e). Крім того, поєднання CGAN з емпіричними методами декомпозиції режимів дозволяє ідентифікувати несправності в розподільчих мережах (Hou et al., 2022). Взагалі кажучи, GAN на основі стану представляють собою спеціалізовану модифікацію модульної структури, яка вводить втрати, специфічні для певного класу. Інтегруючи різні вдосконалення з іншими структурами та функціями втрат, можна генерувати більш якісні вибірки несправностей. Впровадження ідеї теорії дифузії тренду в модель CGAN підвищує її продуктивність при додаванні даних і дозволяє отримати більш ефективну діагностику занурювальних електронасосів з надзвичайно обмеженими даними про несправності (Gao et al., 2024b). Для діагностики несправностей чиллерів введення відстані Вассерштейна в CGAN робить навчальні дані диверсифікованими і більш збалансованими (Yan et al., 2020), що ефективно покращує продуктивність діагностики несправностей чиллерів. Деякі методи адаптують CGAN до функції втрат WGAN-gp (Li та ін., 2022c; Yan та ін., 2022; Yu та ін., 2022; Gu та ін., 2023; Chen та ін., 2024; Zhang та ін., 2024c), тим самим значно покращуючи ефективність діагностики. Для того, щоб збільшити різноманітність зразків і полегшити колапс моделі, Li та ін. (2023b) додали член втрат, заснований на моделі збільшення ентропії псевдо-зразків на основі WGAN-gp, змушуючи генератор вивчати різноманітність. VAEGAN і CGAN були використані в комбінації для діагностики несправностей коробок передач (Wang та ін., 2020; Liu та ін., 2022e; Zhang та ін., 2022b). На додаток до вищезазначених стратегій вдосконалення, існують також моделі, які поєднують D2GAN з CGAN (Zheng et al., 2020).

На основі структури DCGAN і в поєднанні з мітками категорій, Luo та ін. (2021) і Peng та ін. (2022a) успішно фіксують справжній розподіл вихідних даних вібрації за допомогою моделі CDCGAN. Аналогічно, модель CGAN може бути застосована для посилення невеликої кількості зразків несправностей для ефективного і точного виявлення

неправильності короткого замикання двигуна (Li et al., 2021e). Крім того, поєднання CGAN з емпіричними методами декомпозиції режимів дозволяє ідентифікувати неправильності в розподільчих мережах (Hou et al., 2022). Взагалі кажучи, GAN на основі стану представляють собою спеціалізовану модифікацію модульної структури, яка вводить втрати, специфічні для певного класу. Інтегруючи різні вдосконалення з іншими структурами та функціями втрат, можна генерувати більш якісні вибірки неправильностей. Впровадження ідеї теорії дифузії тренду в модель CGAN підвищує її продуктивність при доповненні даних і дозволяє отримати більш ефективну діагностику занурювальних електронасосів з надзвичайно обмеженими даними про неправильності (Gao et al., 2024b). Для діагностики неправильностей чиллерів введення відстані Вассерштейна в CGAN робить навчальні дані диверсифікованими і більш збалансованими (Yan et al., 2020), що ефективно покращує продуктивність діагностики неправильностей чиллерів. Деякі методи адаптують CGAN до функції втрат WGAN-gp (Li та ін., 2022c; Yan та ін., 2022; Yu та ін., 2022; Gu та ін., 2023; Chen та ін., 2024; Zhang та ін., 2024c), тим самим значно покращуючи ефективність діагностики. Для того, щоб збільшити різноманітність зразків і полегшити колапс моделі, Li та ін. (2023b) додали член втрат, заснований на моделі збільшення ентропії псевдо-зразків на основі WGAN-gp, змушуючи генератор вивчати різноманітність. VAEGAN і CGAN були використані в комбінації для діагностики неправильностей коробок передач (Wang та ін., 2020; Liu та ін., 2022e; Zhang та ін., 2022b). На додаток до вищезазначених стратегій вдосконалення, існують також моделі, які поєднують D2GAN з CGAN (Zheng et al., 2020).

Напівкерований GAN (SSGAN) використовує дискримінатор, який функціонує як мультикласифікатор, розрізняючи класи реальних зразків і спеціальний клас псевдозразків, при цьому SSGAN приймає виключно інформацію про мітки. Цей підхід було застосовано для діагностики неправильностей обертових механізмів шляхом поєднання вейвлет-перетворення та SSGAN для маркування обмеженої кількості зразків (Liang, Deng, Wu, Li et al., 2020a). А також метод, що поєднує алгоритми кластеризації та SSGAN, об'єднуючи неконтрольовані та напівконтрольовані методи навчання для ефективного виявлення немаркованих неправильностей (Li & Zhang, 2023). Покращений алгоритм

акторно-критичного аналізу поєднується з SSGAN для діагностики помилок, коли розмір вибірки анотацій невеликий (Wang et al., 2022b). Крім того, існує тип напівкерованого навчання GAN, в якому дискримінатор DCGAN змінюється на мультикласифікатор (Zhou et al., 2023), який можна навчити, використовуючи обмежену кількість маркованих даних і велику кількість недорогих немаркованих даних.

ACGAN (Odena et al., 2017) розширює CGAN шляхом включення допоміжного класифікатора в дискримінатор, який одночасно виводить інформацію про категорії та розрізняє справжні та підроблені зразки. На відміну від CGAN, на вході ACGAN не потрібно об'єднувати зразки з мітками, але допоміжний класифікатор дискримінатора повинен вивчати інформацію про категорії вхідних зразків за допомогою доданих міток категорій. Фактично, ACGAN можна розглядати як гібрид CGAN і SSGAN, який поєднує в собі генератор, що генерує марковані зразки під контролем, і дискримінатор, який розпізнає автентичність без контролю, тому він також є різновидом GAN з напівконтрольованим навчанням. Деякі дослідження безпосередньо застосували ACGAN у своїх стратегіях моделювання, щоб покращити вибірки класів меншин та усунути класовий дисбаланс (Fu та ін., 2024; Wang та ін., 2024c). Адаптивна стратегія була розроблена для створення моделі діагностики несправностей обертових машин з використанням моделі ACGAN (Li et al., 2019). Шао та ін. (2019) і Го та ін. (2020) використовують модель ACGAN з одновимірною згортковою структурою для досягнення точної діагностики механічних несправностей. Meng та ін. (2022) і Dai та ін. (2023a) поєднують ACGAN з втратою відстані Вассерштейна, тоді як Li та ін. (2021c) поєднують ACGAN з WGAN-gp. Подальші вдосконалення структури ACGAN включають розробку подвійних допоміжних класифікаторів (Не та ін., 2020), відокремлення допоміжних класифікаторів від оригінального дискримінатора ACGAN для покращення ефективності класифікації (Li та ін., 2022b) та створення декількох генераторів зі спільними локальними вагами (Guo та ін., 2022a), щоб охопити більше моделей розподілу. Крім того, було показано, що включення умов втрати коралів збільшує різноманітність згенерованих зразків, як показали експерименти в цьому дослідженні. Крім того, деякі методи змінилися і перевели ACGAN у контролюваний режим. Наприклад, Діксіт та ін. (2021) покращили

точність класифікації, додавши надлишкову інформацію про мітки в поєднанні з методами метанавчання.

Інтегруючи базові моделі різних GAN або впроваджуючи інші цілеспрямовані вдосконалення, можна значно покращити продуктивність GAN, особливо якість згенерованих зразків, що сприятиме підвищенню точності класифікації моделей класифікації в майбутньому. Для різних завдань навчання та форм даних необхідно обирати різні цільові функції або модульні структури та парадигми навчання, а побудовані моделі ПНМ потребують подальшої оптимізації та налаштування для адаптації до різноманітних форм вхідних даних.Хоча загальна структура або принцип побудови моделей GAN залишається незмінною для різних завдань, конкретні деталі можуть відрізнятися.

РОЗДІЛ II

ВПРОВАДЖЕННЯ ЗАХОДІВ ДЛЯ ВИЯВЛЕННЯ АНОМАЛІЙ В РОБОТІ ОБЛАДНАННЯ

2.1 Методи обробки незбалансованих даних

Діагностика несправностей у промисловості спирається на різноманітні джерела даних, включаючи сигнали вібрації від датчиків, показники температури і вологості, сигнали струму і напруги, звукові сигнали, журнальну інформацію, записану під час роботи обладнання і системи, а також зображення і відеодані, зняті камерами або виявлені датчиками технічного зору.

Ці дані представлені в різних форматах і зазвичай обробляються як часові ряди або зображення під час діагностики несправностей. Вони аналізуються для таких завдань, як класифікація типів несправностей, виявлення аномалій і прогнозування терміну служби. Дані часової області переважають в промисловому аналізі несправностей; однак, дані часових рядів можуть бути перетворені в частотну область або часово-частотну область за допомогою таких методів, як швидке перетворення Фур'є (ШПФ), короткочасне перетворення Фур'є (ШПФ), вейвлет-перетворення (ВП). Крім того, з часових рядів можна виділити статистичні характеристики або перетворити дані у формати зображень для подальшого використання в якості вхідних даних. У таблиці 3 наведено посилання на відповідні роботи в цій галузі.

2.2 Підходи, що використовуються для обробки часових рядів та даних частотної області

Формування часових рядів передбачає не лише вивчення розподілу даних у кожній точці часу для фіксації статичних характеристик, але й розуміння автокореляції всередині ряду та характеристик у реальному часі. Дані часових рядів можна розділити на дискретні та безперервні часові ряди. Дискретні часові ряди можуть стикатися зі сценаріями, коли градієнт дорівнює нулю в певних точках, тоді як безперервні часові ряди стикаються з проблемами в оцінці продуктивності через довгострокові залежності в даних і відсутність стандартизованих вимірювань (Brophy et al., 2022). Дані, отримані з датчиків, походять з безперервного фізичного процесу і, таким чином, є безперервними даними. Однак комп'ютери представляють їх як дискретні часові ряди за допомогою дискретної дискретизації та обчислень. Згодом дані часових рядів можуть бути перетворені в дані частотної області за допомогою швидкого перетворення Фур'є. Працюючи з часовими рядами, ГНМ забезпечують різні структури для відбору у своїх генераторах і дискримінаторах.

Лінійна нейронна мережа. Проста лінійна нейронна мережа може обробляти часові ряди, вводячи дані послідовності в лінійну мережу, зіставляючи їх з кожним нейроном і реконструюючи початковий розподіл за допомогою змагального навчання. Наприклад, повністю зв'язана структура використовується для безпосередньої обробки вихідного часового ряду (Zhang, Chen, Li та ін., 2021c), часовий ряд перетворюється в ряд чисел у частотній області (Wang та ін., 2020), а потім дані частотної області генеруються за допомогою пільної структури зв'язків, яка також використовується для генерації даних частотної області, а в деяких посиланнях використовуються багатошарові персептрони (Zheng та ін., 2020; Li та ін., 2022c).

Одновимірна згорткова нейронна мережа. Згорткові нейронні мережі спочатку використовуються для роботи з двовимірними формами даних, такими як зображення, зокрема, зображення є ідея роботи з часовими рядами полягає в тому, щоб розглядати її як наддовгу матрицю, а ядро згортки стає розміром. Після

визначення розміру кроку та розміру проміжку одновимірне ядро згортки можна використовувати для ковзання по послідовності та виконання згорточних обчислень, як у прозорому вікні. Цей процес витягує карти ознак з послідовності. Подальші результати отримуються шляхом об'єднання, активації та інших пов'язаних операцій. В якості основної структури генератора використовується одновимірна зворотна згортка (Wang et al., 2021b), тоді як дискримінатор використовує одновимірну згорткову структуру. І генератор, і дискримінатор використовують одновимірну згортку (Shao et al., 2019), за винятком того, що в генераторі потрібна операція підвищення вибірки, і подібна конструкція використовується в інших сценаріях (Guo et al., 2020).

Двовимірна згорткова нейронна мережа. Згорткові нейронні мережі спочатку використовувалися для вилучення ознак із зображень, де матричні дані у вигляді зображень могли повністю використовувати можливості ШНМ. Можливим підходом для аналізу часових рядів є перетворення одновимірного часового ряду у двовимірну форму. Це передбачає перетворення часового ряду довжини в матрицю розміром (Li et al., 2021c; Miao et al., 2022), обробку можна продовжити, використовуючи двовимірну згорткову мережу в дискримінаторі. Навпаки, двовимірну матрицю ознак, отриману з відображення шуму в генераторі, потрібно розкласти на довжину вихідної вибірки, а потім вивести.

Рекурентні нейронні мережі. Рекурентні нейронні мережі (RNN) чудово справляються з обробкою послідовних даних. Їх циклічна структура дозволяє мережі зберігати стан пам'яті під час обробки кожного елемента послідовності і передавати цей стан пам'яті наступному елементу. Цей механізм пам'яті дозволяє RNN фіксувати часову інформацію в послідовності. Мережі довготривалої короткочасної пам'яті (LSTM) та рекурентні одиниці із закритими воротами (GRU) - це два варіанти, які вирішують проблеми градієнта та довготривалої пам'яті ШНМ. Юн та ін. запропонували новий фреймворк Time-Series Generative Adversarial Network (TimeGAN), який поєднує структури GAN і RNN з комбінацією контролюваного і неконтрольованого навчання для врахування часових кореляцій

(Yoon et al., 2019). Структура складається з автокодера та змагальної мережі, що містить генератор послідовності та дискримінатор послідовності. Розглядаючи варіант GAN з незбалансованим часовим рядом несправностей в якості об'єкта, Ши та ін. (2023) поєднують функцію втрат WGAN-gp з TimeGAN, що ефективно вирішує проблему дефіциту даних про несправності. Удосконалено архітектуру GRU як генератора і дискримінатора в WGAN (Zhang та ін., 2023b), а структура LSTM використовується в роботах (Liu та ін., 2022b; Zhao та ін., 2022; Du та ін., 2023a), в яких CycleGAN або BiGAN використовується як основа.

TransformerGAN. Ядром Transformer є механізм самоуваги, який підходить для розпаралелених обчислень і пропонує вищу точність і продуктивність, ніж RNN і CNN. Transformer використовує механізм самоуваги для фіксації кореляції між часовими кроками, ефективно обробляючи довгострокові залежності з глобальної точки зору. TTS-GAN (Li et al., 2022d) представили Transformer, який добре працює для генерації часових рядів будь-якої довжини, подібних до вихідної послідовності. І генератор, і дискримінатор моделі TTS-GAN побудовані з використанням Transformer. Сян та ін. запропонували байесівську модель Transformer для прогнозування залишкового ресурсу авіадвигунів. Ця модель інтегрує механізм вентилювання з архітектурою Transformer для покращення дистанційного прогнозування проблем часових рядів. Таке поєднання покращує обчислювальну ефективність мережі та її здатність представляти короткострокові закономірності (Xiang et al., 2024). При діагностиці несправності аерофізичної установки в генераторі використовується трансформаторна структура, коли модель WGAN використовується в якості базової структури (Yan et al., 2023), в той час як дискримінатор все ще приймає повністю пов'язану структуру. Yan та ін. (2024) також використовують комбінацію таких архітектур та інтегрують Transformer з WGAN для навчання моделі в поєднанні з навчанням з підкріпленням. У деяких роботах (Fu та ін., 2024; Zhang та ін., 2024a) і генератор, і дискримінатор використовують Transformer, щоб допомогти впоратися зі складними розподілами вибірок як для генерації вибірок несправностей, так і для дискримінації ознак

несправностей. Зокрема, Фу та ін. (2024) поєднують Transformer з ACGAN, а Чжан та ін. (2024a) поєднують Transformer з CGAN.

Мережі GAN обробляють вилучені ознаки. На відміну від безпосереднього вивчення високорозмірних і складних категорійних ознак з вихідних даних часових рядів, традиційні методи емпіричного аналізу передбачають вилучення статистичних ознак. До них відносяться максимальні та мінімальні значення, дисперсія, асиметрія та ексцес часового ряду. Використання ручного екстрактора ознак слугує для зменшення розмірності вибірки, зберігаючи при цьому основну інформацію про ознаки в максимальному обсязі (Jiang et al., 2019). У деяких дослідженнях (Zhou та ін., 2020; Pan та ін., 2021) як екстрактор ознак використовується кодер, що складається з нейронних мереж, що дозволяє вивчати типові ознаки, притаманні вихідній інформації послідовності. Крім того, вейвлет-пакетне перетворення застосовується для перетворення вихідного сигналу в гільбертовий простір, що полегшує декомпозицію ознак за різними частотами. У випадку (Lee et al., 2017), перетворення Гільберта-Хуанга використовується для отримання відмінних енергетичних спектральних характеристик за допомогою емпіричного розкладання мод. Гао та ін. (2024a) інтегрують фізичну модель, вбудовану в GAN. Ознаки, які можна інтерпретувати, виділяються за допомогою мережі вилучення ознак, а потім використовуються як вхідні дані для генератора. Крім того, деякі методи віdstежують дані хроматографії нафти для виявлення аномальних газів, що утворюються під час відмов силових трансформаторів, реєструючи їх як характерні значення, що вказують на тип відмови (Zhang et al., 2024c).

Обробка даних зображень за допомогою GAN. Зображення можна розглядати як матричний масив, де зображення у відтінках сірого представлено у вигляді одновимірної матриці, тоді як кольорове зображення представлено у вигляді тривимірної матриці, що відповідає трьом колірним каналам R (червоний), G (зелений) і B (синій). Кожен канал кількісно визначається значеннями від 0 до 255, що представляють яскравість кольору. Таке числове представлення дозволяє

конвертувати зображення в числові дані, по суті, розглядаючи зображення як безперервні дані.

Обробка зібраних зображень. У промислових умовах зображення несправностей і пошкоджень отримують за допомогою датчиків зображення, перетворення фізичних величин або прямого знімання камерою. Однак, доступна кількість зображень, що представляють ці несправності або аномалії, обмежена. Для вирішення цієї проблеми використовується технологія передискретизації на основі GAN, яка дозволяє розширити набір даних шляхом генерації додаткових зображень. Наприклад, GAN застосовують для створення високореалістичних імітаційних карт дефектів пластин (Wang et al., 2019), а можливість передачі стилю CycleGAN використовується для перетворення інфрачервоного зображення нормальної обсадної труби в інфрачервоне представлення дефектної обсадної труби (Wei et al., 2019). Також використовуючи інфрачервону термографію, Guo та ін. (2024b) застосовують безконтактну інфрачервону термографію для виявлення дефектів незбалансованих підшипників кочення. Деякі промислові пристрії вимагають бездоганних поверхонь, що зумовлює необхідність своєчасного виявлення текстури, зернистості та площинності. Для вирішення цієї проблеми запропоновано метод розпізнавання дефектів у магнітних плитках з використанням нечіткої кластеризації, що генерує змагальну мережу (Wang & Xue, 2024).

Перетворення часових рядів або спектру в зображення. Різні методи перетворення створюють різноманітні зображення. Шляхом добування квадратного кореня з вихідної довжини часового ряду та його спектру визначається довжина краю отриманого зображення. Зазвичай цю довжину вибирають у вигляді ідеального квадрата. Такий підхід дозволяє реорганізувати вихідний часовий ряд та інтегрувати його в числові матриці, які нагадують форми зображень (Xie & Zhang, 2018; Li et al., 2019; Liu et al., 2021b; Wang et al., 2021a; Che et al., 2022; Quan et al., 2024). Для узгодження з загальноприйнятым визначенням зображень чисрова матриця проходить нормалізацію до діапазону 0-255. Крім того, нормалізація сигналу іноді застосовується перед реструктуризацією часового ряду.

Після перетворення ШПФ часовий ряд перетворюється на послідовність у частотній області, і аналогічно, ряд може бути реорганізований у числову матрицю, перетворюючись таким чином на зображення (Yang et al., 2021a; Li et al., 2022c), але зміна значення яскравості та її просторовий зв'язок виражаютъ частотні характеристики, а часовий ряд також може бути перетворений у часову спектрограму за допомогою короткочасного перетворення Фур'є (Tao et al., 2020; Akhenia et al., 2022) та вейвлет-перетворення (Liang et al., 2020b; Han & Chao, 2021; He et al., 2021; Zhao & Yuan, 2021; Wang et al., 2022b; Yang et al., 2022b; Fu et al., 2024; Qiu et al., 2024; Zhong et al., 2024). На відміну від традиційних методів, які просто застосовують амплітудні характеристики в часо-частотній площині, кросовер вейвлет-перетворення використовується для отримання спектральних зображень сигналів несправностей, які можуть бути використані для захоплення комплексних характеристик, що включають амплітудні, фазові та когерентні характеристики (He et al., 2020). Перетворення Стоквелла також можна використовувати для перетворення часових рядів сигналів у двовимірні зображення в часо-частотній області (Liang et al., 2023). Чжан та ін. (2022b) і Яо та ін. (2023) використовували двовимірне вейвлет-перетворення для декомпозиції зображення на різні карти ознак, а потім об'єднали їх. Підхід до обробки зображень за допомогою GAN зазвичай передбачає двовимірну згортку. Це відрізняється від перетворення вхідного часового ряду у двовимірну форму перед застосуванням двовимірної згортки в GAN. Натомість дані у вигляді зображень обробляються безпосередньо. Більше того, окрім вищезгаданих методів перетворення часових рядів у зображення, для цього можна використовувати багато інших методів. Наприклад, вкладений графік розсіювання (Jo et al., 2018) використовується для перетворення часових рядів у спеціальний триканальний графік розсіювання (Suh et al., 2019), перетворення Гільберта-Хуанга може перетворити часовий ряд у часову спектрограму, а перетворення координат Gramian Angular Field поєднується з матрицею Грама для досягнення кодування послідовності в зображення. Analogічно, міграційне поле Маркова перетворює часові ряди в зображення на основі матриці перенесення Маркова (Ross et al., 2023).

Різні форми даних мають різні характеристики, а дані часової області, дані частотної області та дані зображень, що обробляються GAN, мають відносно високу розмірність, що зазвичай займає велику кількість обчислювальних ресурсів. Частотні дані - це спектральне представлення часового сигналу, яке має більш очевидні атрибутивні характеристики, але може втрачати частину часової інформації. Часово-частотні дані забезпечують двовимірне представлення часових рядів, що дозволяє застосовувати різні методи обробки зображень. Однак таке перетворення може привести до втрати деяких послідовних характеристик, притаманних вихідному часовому ряду. І навпаки, дані часової області є найбільш примітивними даними, а дані складні та різноманітні, але містять найбільш повну інформацію, деякі глибоко приховані особливості іноді не можуть бути вилучені, тому структура мережі потребує оптимізації для видобування важливої прихованої інформації. Використання двовимірної згортки як базової структури GAN більше підходить для даних зображень і краще відображає характеристики несправностей. Тоді як використання одновимірної згортки або ШНМ як базової структури більше підходить для даних часової або частотної області. Цей підхід зберігає оригінальні характеристики, хоча і в менш інтуїтивно зрозумілій формі. Загалом, GAN мають широкий потенціал застосування для роботи з різними формами даних, але вибір форми даних та архітектури GAN залежить від конкретних вимог завдання та наявних ресурсів даних. Дляожної форми даних потрібно зважити продуктивність моделі, вимоги до даних, обчислювальні ресурси та цілі місії, щоб визначити найбільш підходящий підхід. Крім того, GAN демонструють значно вищу обчислювальну складність і вимоги до ресурсів порівняно з деякими моделями машинного навчання, насамперед через їхній складний процес навчання в умовах суперництва.

Механізм уваги дозволяє моделі динамічно обчислювати вагуожної вхідної частини (Vaswani та ін., 2023), що допомагає вловити контекстну релевантність, тим самим покращуючи продуктивність та здатність до узагальнення моделі (Zhang et al, 2022c), а його сприйняття глобальної інформації може допомогти GAN отримати

більш важливі особливості з часових рядів або зображень, CNN має сильну здатність витягувати локальні особливості, і коли CNN та механізм уваги поєднуються, він може звертати увагу як на глобальну, так і на локальну інформацію (Wan et al, 2021; Fan та ін., 2022; Miao та ін., 2022; Liu та ін., 2022c; Zhang та ін., 2022a; Luo та ін., 2023; Shang та ін., 2023; Shao та ін., 2023a; 2023b; Tang та ін., 2023). Було прийнято метод подвійної уваги, що поєднує часову увагу та увагу до каналу (Wang, Chen та ін., 2022a). Зважаючи на проблеми зникнення градієнта та вибуху градієнта, які можуть виникнути під час навчання GAN, додавання залишкової структури може бути певною мірою полегшено, а навчання може бути стабілізовано шляхом введення залишків (Liu та ін., 2022d; Peng та ін., 2022a; Pu та ін., 2023a), а пропускаючи деякі шари мережі, можна звернути увагу на більш детальну інформацію та покращити якість згенерованих зразків. Існують також методи (Fu та ін., 2022; Tian та ін., 2023), які поєднують залишки та механізми уваги для досягнення кращих результатів. Деякі методи нормалізації також були використані для розміщення їх у структурі мережі, щоб пом'якшити проблеми градієнтного вибуху та покращити можливості узагальнення та стабільність, пакетна нормалізація є найбільш широко використовуваною в структурах, але є й інші методи, такі як градієнтна нормалізація (Fan та ін., 2022), нормалізація екземплярів (Shao та ін., 2023b) та SN (Wan та ін., 2021; Peng та ін., 2022a). Для вирішення проблеми занадто повільного бігу використовують перехресне та паралельне навчання (Jiang та ін., 2023), а для полегшення процесу навчання регуляризованого дискримінатора застосовують правило дворазового оновлення шкали (Gu та ін., 2023).

Оскільки GAN еквівалентний чорному ящику, неможливо точно контролювати якість згенерованих зразків, і навіть добре навчені моделі GAN можуть демонструвати аномальні умови, що призводить до того, що згенеровані зразки можуть містити шум, нерівномірний розподіл і різну якість. Тому якість вибірки потрібно оцінювати і перевіряти. Для даних зображень можна використовувати деякі загальновживані метрики подібності зображень, тоді як для

часових рядів можна використовувати міри подібності, специфічні для часових рядів, або перетворення в частотні характеристики. Залежно від типу даних розробляються різні механізми оцінювання. Для оцінки ефективності генеративних моделей використовують нормовану крос-кореляцію та показники розбіжності Кульбака-Лейблера (Rathore & Harsha, 2022), а також розбіжність Дженсена-Шеннона та середньоквадратичну похибку (Zhang et al., 2021b ; Luo et al., 2022b). З використанням чотирьох індексів: Початковий бал, початкова відстань Фреше, пікове відношення сигнал/шум і структурна подібність для кількісної оцінки згенерованих зображень, було розроблено метод, який поєднує стратегію оціночного скринінгу з доповненням даних, щоб полегшити пристосування згенерованих зразків до реального розподілу даних (Zhang et al., 2022d). У порівнянні з одним індикатором, створюється комплексна багатоіндикаторна система оцінювання (Fan та ін., 2022). Звичайно, деякі методи візуалізації, такі як t-розподіл-випадкове будовування близькості (Chae et al., 2024), також можна порівнювати поверхнево. Деякі методи скринінгу зразків також матимуть вплив на подальше навчання моделей класифікації, модуль скринінгу даних на основі максимальної середньої різниці (MMD) був розроблений в (Hou et al., 2023) для фільтрації схожих даних, критерій скринінгу коефіцієнта кореляції Пірсона (PCCSC) був запропонований для забезпечення якості згенерованих зразків (Li et al., 2022c), подібно до одноіндексного скринінгу, деякі методи використовують кілька числових показників, а фільтр даних у посиланнях (Liu et al., 2022c) базується на трьох показниках: дискримінантна ймовірність, розбіжність KL, MMD, використовуються дискримінантні результати, категоріальні результати та результати кореляційного аналізу (Zhao & Yuan, 2021). Зокрема, було розроблено згортковий варіаційний кодер (Shang et al., 2023), щоб спочатку дізнатися про втрати реконструкції вихідних даних, і якщо втрати реконструкції помилкового зразка були більшими за цей термін, його опускали, а в (Shao et al., 2023b) алгоритм одиночного лісу (IF) використовувався для обчислення оцінки зразка, і той, що мав високу оцінку, видалявся як аномалія. Всі вищезазначені методи скринінгу є скринінгом після навчання, тобто скринінгом в процесі навчання (Liu et al., 2023b),

який використовує алгоритм скринінгу високоякісних зразків для відбору високоякісних фальшивих зразків, згенерованих генератором, і надсилає їх на дискримінатор.

Після доповнення даних за допомогою GAN метою є збалансування кількісного співвідношення вихідного набору даних. Збалансовані дані потім використовуються для навчання класифікаторів, таких як CNN (Meng et al., 2022), SVM (Pu et al., 2022), випадковий ліс (Pu et al., 2023a), дерево рішень та інші. Класифікатори на основі ПНМ часто вдосконалюються для кращого вирішення завдань класифікації для різних типів даних. Ці класифікатори можуть бути розроблені для ідентифікації та класифікації вихідних даних часової області, перетворених спектрів і різних карт особливостей. Мережеві структури, такі як CNN, LSTM, Transformer та інші, також можуть бути використані в класифікаторах на основі нейронних мереж.

Деякі нові вдосконалення зробили GAN більш ефективними в діагностиці несправностей. Чжан та ін. (2022e) запропонували адаптивну стратегію розділення, яка адаптивно отримує латентні вектори з різних розподілів за допомогою градієнтного інверсного процесу для реалізації розділення різних розподілів бітів на вході. Лю та ін. запропонували метод регуляризації для регулювання точності дискримінатора і підтримки ефективного інформаційного градієнта шляхом регуляризації взаємної інформації між вхідною інформацією і внутрішніми особливостями дискримінатора (Liu et al., 2022c). Ці два методи ефективно сприяють підвищенню стабільності моделі. Ван та ін. розробили метод метанавчання на основі градієнтного потоку для покращення збіжності моделі (Wang et al., 2023f), тоді як Лі та ін. запропонували побудувати метанавчальні GAN зі стратегією самоконтролю, і ці моделі GAN на основі метанавчання можуть генерувати кращі псевдовибірки з невеликою кількістю зразків (Li et al., 2023a). Zhuo & Ge (2021) та Ren та ін. (2023b) запропонували GAN, що навчається кількома пострілами, для вирішення проблеми невеликої кількості зразків несправностей. Ren та ін. (2023b; Wang та ін., 2023d) і Liu та ін. (2023a) одночасно використовують

інформацію з декількох доменів для навчання моделі GAN, щоб отримати більш реалістичні та різноманітні дані. Ло та ін. використовували двоступеневу структуру GAN (2S GAN) (Luo et al., 2022a), в якій GAN першого рівня використовував TimeGAN для вилучення інформації з часових рядів, а GAN другого рівня використовував функцію керованого навчання ACGAN для покращення здатності вилучення інформації. Дінг та ін. спочатку використовували метод K-найближчого сусіда (KNN) і зробили недостатню вибірку більшості класів у нерівноважній вибірці, а потім зробили надмірну вибірку класів меншості, використовуючи вдосконалену модель TACKAN, засновану на ACGAN (Ding et al., 2022). Ван та ін. використовували суміш SMOTE і GAN для генерації вибірок, щоб збільшити розмір і різноманітність вибірки (Wang та ін., 2023a). У методі, згаданому Гао та ін. (2022a), спочатку використовується чисельне моделювання для отримання імітованих зразків несправностей, а потім ці імітовані зразки вводяться в мережу GAN разом з реальними зразками для генерації більшої кількості зразків несправностей, що значно підвищує точність подальшої класифікації.

2.3 Навчання з перенесенням

Методи, що базуються на трансферному навчанні, також широко використовуються в галузі діагностики несправностей (Li та ін., 2024c; Tang та ін., 2024; Xiao та ін., 2024), але деякі методи поєднують доповнення даних GAN з трансферним навчанням, використовуючи CycleGAN (Wang та ін., 2023e), або використовуючи DCGAN (Zhong et al., 2023), щоб спочатку доповнити дані, а потім використовувати навчання з перенесенням для навчання моделі, на відміну від них, He та ін. (2022) і Li та ін. (2022a) поєднують WGAN і TimeGAN. Cui та ін. (2024) використовували GAN для доповнення вихідних даних, використовуючи доповнені дані як джерело для трансферного навчання. У статті пропонується, що після первинного навчання ШНМ на гібридних даних, модель проходить вторинне навчання на вихідних даних. Це вторинне навчання дозволяє моделі ефективно діагностувати як складні, так і поодинокі несправності. Щодо проблеми адаптації

домену в процесі навчання, то доменна змагальна нейронна мережа (DANN) використовує змагальний підхід для перенесення ознак вихідного домену в немаркований цільовий домен. DANN складається з екстрактора ознак, дискримінатора домену та класифікатора. Дискримінатор домену допомагає екстрактору ознак у вивчені інваріантних ознак домену, тоді як класифікатор виконує класифікацію. Лю та ін. використовували DANN для перенесення ознак із змодельованих даних для досягнення високоточної діагностики (Liu & Gryllias, 2022). Аналогічно, Ван та ін. застосували DANN для підвищення точності діагностики несправностей авіадвигунів (Wang & Zhao, 2023). Лі та ін. вдосконалили структуру моделі DANN, додавши новий модуль екстракції ознак і об'єднання ознак, отримавши таким чином більше нових ознак і поліпшивши здатність класифікатора до узагальнення, що сприяє підвищенню точності діагностики (Li et al., 2024a). Ran та ін. зосередилися не тільки на доменній адаптації розподілу даних, але й на вирівнюванні градієнтного домену, подальшому зменшенні зміщення домену та отриманні доменно-інваріантних ознак (Ran та ін., 2024). Окрім загальнопромислової діагностики несправностей, доменні змагальні методи також застосовуються в управлінні енергією: у своїй роботі з оцінки ємності акумуляторів для систем зберігання енергії Яо та ін. вирішують проблему наявності великої кількості немаркованих даних про батареї в промисловому середовищі, але обмеженої кількості маркованих даних. Вони використовують методи доменного суперництва для вивчення особливостей немаркованих даних, розширяючи можливості моделі щодо вилучення особливостей і підвищуючи точність оцінки ємності акумулятора (Yao et al., 2024).

РОЗДІЛ III

ВПРОВАДЖЕННЯ ЗАХОДІВ ДЛЯ ВИЯВЛЕННЯ АНОМАЛІЙ В РОБОТІ ОБЛАДНАННЯ

3.1 Виявлення аномалій

Системи виявлення аномалій на основі GANomaly (Akcay та ін., 2019) зазвичай використовують реконструйовані відмінності між нормальними та аномальними даними для виявлення появи аномалій (Yan, 2021). Huang та ін. (2024) розробили метод виявлення несправностей для обертових механізмів з використанням GAN, який поєднує в собі стратегії локалізації аномалій за ознакою вал-рейка та градієнтом. Результати, наведені в статті, демонструють, що запропонований метод забезпечує кращу стабільність і точність порівняно з GANomaly.

Найпоширеніший сценарій застосування для діагностики несправностей на основі GAN - це міжзаводські механічні інструменти. Однак GAN також високоефективні в різних інших сценаріях. Наприклад, кілька методів (Li та ін., 2021d; Zhang та ін., 2022f; Du та ін., 2023b) використовують різні моделі GAN для генерації даних про незначні несправності, щоб вирішити проблему недостатньої кількості даних про несправності в системах HVAC. Крім того, Hu та ін. (2023) поєднали концепцію цифрових двійників з моделлю на основі WGAN для досягнення високої точності моделювання віртуальних зразків, використовуючи лише здорові фізичні зразки з різного промислового обладнання. Цей підхід ефективно підтримує безліч завдань на стороні сервера, включаючи раннє виявлення несправностей, моніторинг стану і відстеження деградації. WDCGAN, запропонований в (Chen et al., 2023), використовується для покращення даних про несправності, що генеруються електростатичним приводом літака (ЕНА), і класифікації несправностей за допомогою SDAE, забезпечуючи метод діагностики несправностей ЕНА літака. Атомні електростанції більшу частину часу працюють

в нормальних умовах, а обладнання майже завжди експлуатується в суворих умовах, таких як висока температура, високий тиск і радіоактивність, і як тільки машини і обладнання виявляється постарілими, пошкодженими і погіршать свої характеристики, це завдасть надзвичайно серйозної шкоди. Було досліджено легкий CGAN (Qian & Liu, 2022), який можна використовувати з різними класифікаторами для отримання хороших діагностичних ефектів обладнання атомних електростанцій. Для діагностики несправностей фотоелектричних (фотоелектричних) масивів за допомогою скінченних малих мічених зразків, WGAN використовується для вивчення різних розподілів даних у фотоелектричних системах (Lu et al., 2023), так що класифікатори CNN можуть бути навчені згенерованими міченими зразками для діагностики, забезпечуючи реальний метод для стабільної роботи фотоелектричних електростанцій. Діагностика несправностей на основі традиційного машинного навчання не може навчити модель з високими показниками узагальнення для діагностики дугових несправностей, тому вдосконалена модель GAN використовується для генерації даних про несправності дуги шляху карбонізації в низьковольтних кабелях (Zhang et al., 2021a), щоб діагностична модель могла більш ефективно виявляти дугові несправності. На додаток до цього, в реальному промисловому середовищі. GAN також успішно застосовуються для прогнозування відмов обладнання, оптимізації виробничих процесів та перевірки якості. Ван та ін. проаналізували реальну базу даних записів якості від виробника компресорів у Китаї і застосували метод CWGAN-XGBoost (Wang et al., 2024b), досягнувши покращення точності оцінки якості перед виробництвом на 3,77% і 3,12% відповідно. Гао та ін. (2024b) використовували реальні дані з морських нафтогазових родовищ як експериментальні зразки. Зіткнувшись з проблемою діагностики несправностей електричних заглибних насосів через брак достовірних зразків, вони поєднали CGAN для створення необхідних зразків, що значно покращило результати діагностики. Analogічно, для діагностики несправностей і виявлення поширеніх підшипників, шестерень, інструментів та інших компонентів GAN продемонстрували чудову продуктивність як в експериментах зі штучним

попшкодженням, так і в реальних попшкоджених деталях (Fu et al., 2024; Quan et al., 2024). Крім того, Ван та ін. підтвердили дієвість і практичну ефективність свого підходу, заснованого на GAN, на восьми наборах даних, включаючи дані з секторів напівпровідників, електротехніки та електромереж (Wang et al., 2024c). Ці висновки ілюструють величезний потенціал GAN для діагностики несправностей у реальних промислових сценаріях і підкреслюють широкі перспективи для подальших досліджень.

3.2 Проблеми та інтерпретованість методів в умовах незбалансованості змішування у малих вибірках

Під час збору даних з датчиків машини та обладнання стикаються з шумовим забрудненням, яке виникає не лише через шум навколишнього середовища, але й через інтерференцію між різними сигналами вібрації несправностей, а також через проблему неправильного маркування зразків, спричинену різними причинами. Коли завади впливають на чисті зразки або в наборі даних присутні чисті шумові зразки, згенеровані GAN зразки можуть демонструвати необґрунтовані ознаки несправностей, що призводить до значного відхилення від реальної ситуації. Для усунення шуму навколишнього середовища ефективним методом є попередня обробка даних перед навчанням моделі. Ян та ін. (2022a) використовують фільтр високих частот для видалення низькочастотних компонентів з сигналу вібрації, а потім перетворюють одновимірний часовий ряд в карту в градаціях сірого, що значно зменшує низькочастотні шумові перешкоди і дозволяє точно діагностувати несправності. Крім того, перетворення часових рядів у частотну (Sun et al., 2024) або часово-частотну (Zhang et al., 2023a) область за допомогою БПФ, ШПФ або CWT допомагає фільтрувати шум у певних частотних діапазонах, зберігаючи при цьому корисні компоненти сигналу. Для управління сигналами вібрації з різними частотами пропонується змагальна мережа прогресивної генерації (Ren et al., 2024), яка поступово генерує складні сигнали від низькочастотних до широкочастотних діапазонів. Цей метод розкладає сигнали на різні частотні діапазони і використовує

кілька моделей GAN, щоб зосередитися на цих діапазонах, уникнути інтерференції високоенергетичних сигналів з власними частотами несправностей. щодо зашумлених міток, Хуанг та ін. розробили покращену завадостійку допоміжну мережу генеративного класифікатора, що генерує змагальну мережу (rAC-GAN) (Huang et al., 2021). Завдяки обмеженім даним та впорядкованій взаємній інформації ця мережа демонструє вищу стійкість до шуму міток. На додаток до вищезазначених даних, що містять шумовий дисбаланс, підхід до діагностики несправностей планетарних редукторів, що використовує SDAE-GAN (Wang et al., 2018), покращує обмежені зразки за допомогою мережі GAN. Цей метод вносить шум зі статистичними характеристиками у вибірки і використовує процеси кодування і декодування для отримання безшумних вибірок. Цей підхід полегшує автоматизоване вилучення ефективних характеристик несправностей і підвищує стійкість до шуму. Для оцінки продуктивності при різних співвідношеннях сигнал/шум (Cao et al., 2022) використовується розроблений шумовий пристрій для введення шуму, з подальшим використанням структури GAN для генерації зразків-суперників, тим самим підвищуючи діагностичну точність моделі. Крім того, для нелінійного перетворення сигналу застосовується метод м'якого порогу (Zhang et al., 2023a), що ефективно зменшує шум у сигналі. Ці методи обробки шуму дають цінну інформацію для подальших досліджень щодо усунення шумового дисбалансу в діагностичних процедурах.

При усуненні дисбалансу в діагностиці несправностей метою методу доповнення даних є сприяння класифікатору в отриманні вичерпної інформації щодо внутрішньокласових і міжкласових меж з доповненого набору даних. Кілька відповідних досліджень (Li та ін., 2021d; Wang та ін., 2022a; Zhang та ін., 2022e; Tan та ін., 2023) переважно зосереджені на зменшенні міжкласового дисбалансу. Зокрема, кілька досліджень покращують баланс розподілу між класами, використовуючи як немарковані, так і марковані дані, включаючи розроблену схему напівконтрольованого самонавчання (Li et al., 2021d). Для усунення міжкласового дисбалансу застосовується умовний GAN, який ефективно пом'якшує дисбаланс

між більшістю нормальних зразків і кількома аномальними зразками (Zhang et al., 2023a). Для внутрішньокласового дисбалансу вводиться модель ACWGAN-GP для обробки даних про несправності в різних умовах зламу зубів (Li et al., 2024b), Після зменшення розмірності згенеровані вибіркові дані демонструють значне міжкласове розділення та внутрішньокласову агрегацію. Зазначається, що всебічне покращення отриманих даних потребує усунення асиметрії розподілу даних, спричиненої GAN, зокрема, забезпечення відокремленості внутрішньокласових ознак у межах діапазону різних міжкласових ознак. Цей фактор суттєво впливає на різноманітність вибірки в процесі генерації GAN.Хоча (Ren et al., 2023a) запропонували метод надання прикладів розподілу вибірки для недостатньо представлених класів, використовуючи класи з надлишком вибірок, співіснування внутрішньокласового та міжкласового дисбалансу в контексті невеликих вибірок залишається складним завданням. По-перше, обмежена кількість вибірок перешкоджає отриманню дрібнозернистої інформації про ознаки. По-друге, деякі внутрішньокласові агрегації та інші внутрішньокласові агрегації можуть перетинатися, що створює проблему для повторної вибірки на основі GAN у встановленні достовірної межі між ними.

Наразі більшість досліджень з діагностики несправностей у контексті незбалансованих часових рядів переважно зосереджені на короткострокових незбалансованих даних про несправності. Слід зазначити, що існує значна прогалина у вивченні довгострокових незбалансованих даних. Ця прогалина в першу чергу виникає через значний час, необхідний для збору даних під час тривалих відмов. Потенційне рішення полягає у прискоренні процесу еволюції несправностей і подальшому зіставленні прискорених даних з даними нормальнюї еволюції. Для вирішення цієї проблеми були застосовані GAN для виконання функції імплікації відсутніх даних, що полегшило відновлення довготривалих безперервних структурних реакцій в рамках багатоканальної просторово-часової інформації (Gao et al., 2022b). Мета полягає в тому, щоб генерувати продовження вихідного сигналу, формуючи новий сигнал (Dai та ін., 2023b). Крім того, усунення

дисбалансу в часових рядах є ключовим у дослідженнях, що стосуються прогнозування залишкового ресурсу: Huang та ін. (2022) і Zhang та ін. (2022) використовували GAN для моделювання сценаріїв деградації авіадвигунів за змінних умов роботи і різних режимів відмов, досягнувши прогнозування залишкового ресурсу. Аналогічно, у відповідь на проблему використання великої кількості навчальних даних для прогнозування ресурсу підшипників, Lu та ін. запропонували стратегію навчання, яка інтегрує метод GAN з предиктором стану (Lu et al., 2022). Ця стратегія генерує дані для прогнозування, використовуючи лише обмежені дані про деградацію часових рядів, тим самим підвищуючи продуктивність і точність предиктора.

Інтерпретованість штучного інтелекту ґрунтується на довірі користувача до системи, а також на його здатності комфортно контролювати та використовувати її (Vilone & Longo, 2021). У глибокому навчанні інтерпретованість охоплює такі ключові поняття, як працездатність, доказовість, прозорість і постпричинна інтерпретація. Наприклад, Dong та ін. використовували GAN для генерування даних сценарію розвитку відновлюваної енергетики, які узгоджуються з розподілом історичних даних (Dong et al., 2022). Вони використовували інтерпретовані характеристики, такі як середня потужність, максимальна потужність і мінімальна потужність, використовуючи приховані просторові вектори для управління процесом генерації. Для подальшого покращення інтерпретованості в інтегровану систему діагностики було включено фізичну модель. Це доповнення полегшило виокремлення ключових характеристик з підвищеною прозорістю (Yan et al., 2023). Незважаючи на ці зусилля, існуючі дослідження інтерпретованості GAN залишаються недостатніми для всебічного розуміння всієї системи доповнення даних GAN. Зокрема, у сценаріях з невеликим дисбалансом вибірки інтерпретованість також слід розглядати з різних точок зору.

Розподіл даних в умовах нерівноваги змішування більше не має чітких меж класів, а моделі внутрішньокласової та міжкласової агрегації потребують детального аналізу, а також того, як вони впливають на характеристики класів та

якість згенерованих вибірок. Для запушмлених вибірок, які конкретні способи використовуються моделлю для відкидання або маргіналізації запушмлених кластерів.

Внутрішній механізм роботи моделі GAN є дуже важливим, внутрішнє кодування генератора і кількісний підхід дискримінатора впливають на процес навчання в умовах суперництва, особливо для потенційних векторів у низьковимірному прихованому просторі, які необхідно зробити явними, щоб надати інформацію про відображення між ними і результатами розпізнавання ознак.

Форма вибірки та статистика категорій початкових вибірок інкапсулює всі характеристики даних та інформацію про ознаки. Завдяки зменшенню розмірності різні ознаки можуть бути додатково виокремлені. Незалежні від моделі методи, такі як Local Interpretable Model-agnostic Explanations, SHapley Additive exPlanations та інші, пропонують засоби для кількісної оцінки як внеску кожної ознаки, так і ступеня залежності моделі від цих ознак. Також можуть бути причетні до порушення конфіденційності та захисту даних під час генерування та обробки даних. Це часто трапляється з інформацією, що ідентифікує особу, медичними записами тощо, і щоб пом'якшити ці проблеми, з даними потрібно поводитися обережно, а одним з можливих рішень є додавання шуму до вихідних даних або генерування високо узагальнених даних. У сфері діагностики несправностей GAN з інформацією про класи вводиться в багатоклієнтський модуль вирівнювання характеристик з змагальним навчанням для адаптивного генерування еталонного розподілу (Wang та ін., 2022c), щоб побудувати глобальну модель діагностики несправностей для декількох клієнтів за умови збереження конфіденційності даних. Це пропонує нову ідею обробки, але захист даних на основі методу GAN все ще потребує подальших досліджень у галузі діагностики несправностей.

3.3 Пристрої для контролю енергоспоживання

Детектори аномалій електродвигунів AnomAlert безперервно виявляють існуючі та нові несправності на електродвигунах та обладнанні, що ними приводиться в рух. AnomAlert використовує інтелектуальний підхід, заснований на моделях заснований на моделях підхід для виявлення аномалій шляхом вимірювання сигналів струму, напруги і ряду інших датчиків. Він стаціонарно встановлюється, як правило, в центрі управління двигунами і застосовується до трифазних електродвигунів змінного струму, асинхронних або синхронних двигунів з фіксованою або змінною швидкістю (рис.3.1).



Рисунок – 3.1 Пристрій для детекції аномалій

Для перегляду даних використовується супутнє програмне забезпечення AnomAlert. AnomAlert надає як механічні (дисбаланс, неспіввісність, роликові

підшипники і т.д.) і електричні (ослаблені обмотки, короткі замикання, обмотки, короткі замикання і т.д.) виявлення аномалій, а також електричних параметрів, таких як напруга і струм дисбаланс і коефіцієнт потужності. Крім того, він може виявити зміни в навантаженні, яке відчуває двигун через аномалій в керованому обладнанні або процесі, таких як кавітації або засмічення фільтрів і екранів. AnomAlert особливо привабливий для важкодоступного приводного обладнання і може бути застосовано до більшості типів насосів, компресорів та інших подібних пристрій.

Для контролю шуму також використовується ряд датчиків, зокрема шуму (рис. 3.2).



Рисунок 3.2 Промисловий датчик шуму

Промислові датчики шуму є важливим інструментом для виявлення аномалій у роботі обладнання, оскільки вони дозволяють моніторити звукові характеристики під час експлуатації в реальному часі. Ці датчики працюють за принципом перетворення акустичних хвиль, які генерує обладнання, в електричні сигнали, що далі аналізуються для виявлення відхилень. Будь-які зміни у звукових параметрах, таких як частота, амплітуда чи спектр сигналу, можуть свідчити про наявність проблем, наприклад, зношення підшипників, надмірного тертя чи дисбалансу.

компонентів. Завдяки високій чутливості до змін звукових характеристик ці датчики забезпечують раннє виявлення потенційних несправностей, що дозволяє уникнути простойв, зменшити витрати на ремонт і забезпечити безпеку роботи обладнання. Крім того, датчики шуму інтегруються з аналітичними системами, включаючи алгоритми машинного навчання, що дозволяє автоматизувати процес аналізу й ефективно виявляти аномалії навіть у складних промислових умовах.

Промислові датчики вібрацій використовуються для виявлення аномалій у роботі обладнання завдяки здатності вимірювати коливання, які виникають під час його роботи, і аналізувати їх характеристики. Ці датчики виявляють зміни в амплітуді, частоті або спектрі вібрацій, що можуть сигналізувати про механічні дефекти, такі як зношення підшипників, дисбаланс, погане кріплення або нерівномірність у роботі деталей. За допомогою таких датчиків можна визначити аномальні коливання, які виходять за межі допустимих норм, що дозволяє своєчасно виявляти та локалізувати джерело потенційної проблеми до того, як вона приведе до серйозного пошкодження або простою. Зчитані дані можуть оброблятися в реальному часі за допомогою систем моніторингу, інтегрованих з алгоритмами машинного навчання або статистичними методами аналізу, що дає змогу проводити глибоку діагностику стану обладнання. Такі датчики є невід'ємною частиною предиктивного обслуговування, оскільки вони знижують витрати на ремонт, мінімізують час простою та підвищують ефективність роботи промислових систем.



Рисунок 3.3 Датчик вібрацій

Промислові датчики температури є ключовими інструментами для моніторингу стану електродвигунів, оскільки температура є одним із найбільш інформативних параметрів, що сигналізують про аномалії у їх роботі. Вони дозволяють виявляти підвищення температури, яке може свідчити про такі проблеми, як перегрів через надмірне навантаження, зношення підшипників, проблеми в системі охолодження чи коротке замикання в обмотках. Датчики реєструють температурні зміни в реальному часі, що дозволяє оперативно реагувати на потенційні несправності до того, як вони переростуть у серйозні поломки. Завдяки інтеграції з системами збору даних, ці датчики можуть автоматично передавати показники для аналізу аномалій, використовуючи алгоритми машинного навчання або порівнюючи їх із заданими пороговими значеннями. Таким чином, датчики температури забезпечують надійний моніторинг, запобігають аварійним відмовам і мінімізують витрати на ремонт, підвищуючи загальну ефективність обладнання.



Рисунок 3.4 Датчик температури

Використання датасету для виявлення аномалій в роботі обладнання електродвигунів полягає в аналізі зібраних даних, які представляють нормальну та аномальну поведінку двигуна. Такий підхід передбачає обробку параметрів, для створення моделі, що здатна розпізнавати відхилення від звичних режимів роботи. Датасет, що містить ці параметри, дозволяє навчити модель машинного навчання на основі розподілу даних у просторі нормальних показників і виділити ті точки, які не відповідають цим характеристикам. Аномалії, виявлені таким чином, можуть сигналізувати про потенційні несправності, як-от перегрів, зношення підшипників або коротке замикання, що дає змогу запобігти поломкам завдяки ранньому виявленню. Ефективність такого підходу залежить від якості та обсягу даних, включаючи інформацію про аномальні стани, а також від алгоритму, наприклад, Isolation Forest або DBSCAN, що використовується для аналізу. Це дозволяє мінімізувати простоту, зменшити витрати на обслуговування і покращити безпеку роботи обладнання.

Для аналізу були відібрані наступні показники. Показники переведені в діапазони від 1 до 5:

- vibration_rating – вібрація (1-5);
- current_rating – струм (1-5);
- noise_rating – акустичний шум (1-5);
- temperature_rating – температура обмоток (1-5).

Для подальших досліджень використали датасет з даними, знятыми з промислових датчиків. Для приведення даних до однієї розмірності виконали регуляризацію та привели дані до інтервалу з максимальним значенням 5 (рис. 3.5)

1	engine_id,vibration_rating,current_rating,noise_rating,temperature_rating	967	Engine 966,1.64,1.96,1.22,1.38
2	Engine 1,1.93,2.8,3.29,1.62	968	Engine 967,1.91,2.96,2.82,1.4
3	Engine 2,2.02,3.2,3.66,1.64	969	Engine 968,1.74,2.36,1.64,1.54
4	Engine 3,2.22,1.8,1.54,1.53	970	Engine 969,1.51,2.2,1.22,1.73
5	Engine 4,1.45,2.8,1.29,1.57	971	Engine 970,1.8,2.32,1.4,1.61
6	Engine 5,1.51,2.2,2.18,1.57	972	Engine 971,1.58,2.96,1.24,1.47
7	Engine 6,1.99,2.28,1.72,1.27	973	Engine 972,2.28,2.24,1.14,1.55
8	Engine 7,1.9,2.36,1.26,1.32	974	Engine 973,2.22,2.16,1.38,2.55
9	Engine 8,1.74,2.4,1.22,1.41	975	Engine 974,1.38,2.96,1.19,1.48
10	Engine 9,2.12,2.76,2.04,1.64	976	Engine 975,2.02,3.44,2.89,1.47
		977	Engine 976,1.74,2.12,1.3,1.53
		978	Engine 977,2.25,1.92,2.12,1.38
		979	Engine 978,1.61,2.32,1.67,1.43
		980	Engine 979,1.93,1.2,1.13,1.43
		981	Engine 980,1.93,1.56,2.13,1.51

Рисунок 3.5 Набір даних для досліджень

	vibration_rating	current_rating	noise_rating	temperature_rating
count	980.000000	980.000000	980.000000	980.000000
mean	1.893194	2.352612	2.013306	1.532500
std	0.326912	0.478280	0.788607	0.279731
min	1.340000	1.000000	1.130000	1.150000
25%	1.670000	2.080000	1.270000	1.410000
50%	1.830000	2.280000	1.820000	1.500000
75%	2.020000	2.560000	2.572500	1.580000
max	4.220000	4.640000	4.620000	4.440000

Рисунок 3.6 Набір даних з статистичними показниками

Виконали оцінку даних та представили візуальне відображення контрольних точок (рис. 3.7).

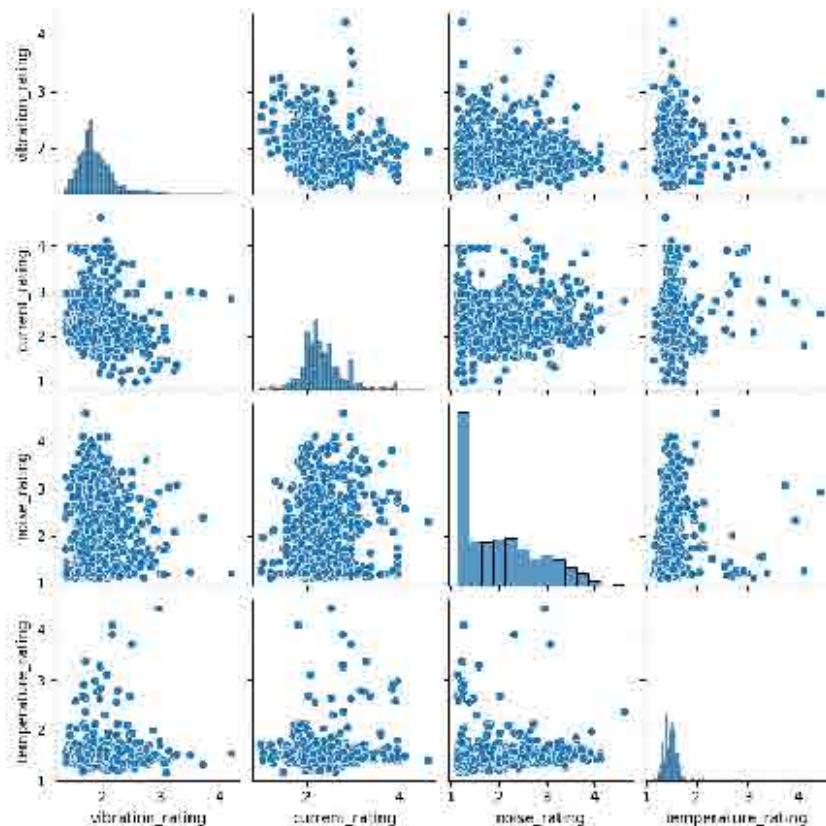


Рисунок 3.8 Гістограми та розподіли контрольних точок по виявленню аномалій в роботі обладнання

Для виявлення аномалій використовували алгоритм Isolation Forest. Цей алгоритм використовується для виявлення аномалій у роботі електродвигунів завдяки здатності ізолювати точки, які значно відрізняються від решти даних. Цей алгоритм базується на ідеї, що аномальні точки легше ізолювати через їхню віддаленість від щільних кластерів нормальних даних. У контексті електродвигунів алгоритм аналізує багатовимірні дані, такі як струм, вібрація, температура та інші показники, і визначає, які з них не відповідають звичайним режимам роботи. Isolation Forest створює дерево роздіlenь даних, де кожна точка послідовно відокремлюється; при цьому для аномалій потрібно менше "розвізів", що дозволяє ефективно їх виявляти. Це допомагає виявити потенційні несправності, як-от перегрів, короткі замикання чи зношення компонентів, задовго до їхнього критичного впливу на роботу двигуна. Завдяки своїй ефективності, алгоритм здатен обробляти великі обсяги даних та виявляти як глобальні, так і локальні аномалії, що робить його ідеальним для застосування в системах предиктивного обслуговування обладнання.

В результаті проведеного аналізу встановлено аномальні точки (рис. 3.9). Скоригували чутливість методу. Результат представлено на рис. 3.10.

	engine_id	vibration_rating	current_rating	noise_rating	temperature_rating	anomaly	anomaly2
247	Engine 248	2.50	2.96	3.08	3.73	-1	-1
903	Engine 904	1.67	3.88	1.26	2.91	-1	-1
666	Engine 667	2.95	2.52	2.94	4.44	-1	-1
728	Engine 729	1.86	3.96	1.21	2.98	-1	-1
915	Engine 916	1.70	2.80	4.62	2.37	-1	-1
668	Engine 669	1.54	2.16	1.80	1.32	1	1
644	Engine 645	1.93	3.24	2.90	1.49	1	1
645	Engine 646	1.61	2.56	1.19	1.41	1	1
646	Engine 647	1.94	1.80	1.35	1.56	1	1
647	Engine 648	1.64	2.52	1.21	1.39	1	1

Рисунок 3.9 Виявлені алгоритмом Isolation Forest точки аномалій в наборі даних

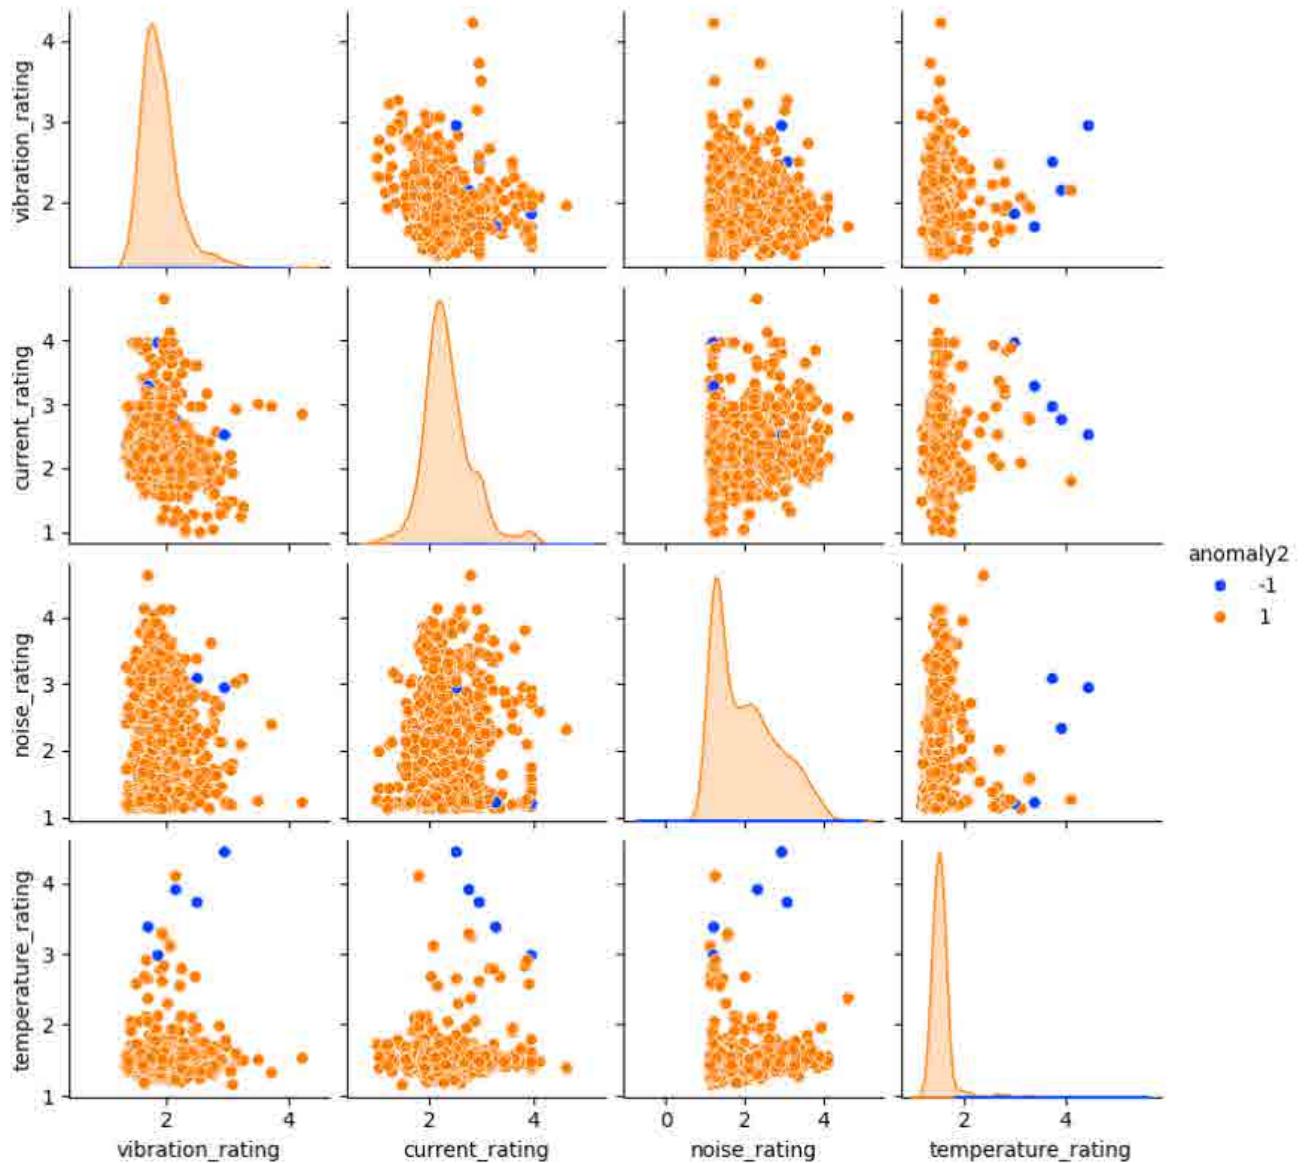


Рисунок 3.10 Результат після коригування алгоритма Isolation Forest

Для подальшої кластерізації даних використали алгоритм DBSCAN. Він використовується для виявлення аномалій у роботі електродвигунів завдяки здатності кластеризувати дані на основі щільності та ідентифікувати точки, які не входять до жодного кластера. Алгоритм аналізує багатовимірні дані, і виділяє "щільні" області, які відповідають нормальному стану роботи обладнання. Точки, що розташовані поза цими щільними регіонами, визначаються як аномалії, оскільки вони не відповідають характерному розподілу нормальних даних. DBSCAN автоматично розділяє дані на кластери без необхідності вказувати кількість кластерів заздалегідь, що робить його ідеальним для обробки нерівномірних та

складних розподілів, які часто зустрічаються в роботі обладнання. Наприклад, аномалії можуть включати різкі зміни вібрації або перевищення температури, що сигналізує про зношення підшипників чи перегрів двигуна. Такий підхід дозволяє ефективно ідентифікувати потенційні несправності, покращуючи точність і надійність систем предиктивного обслуговування.

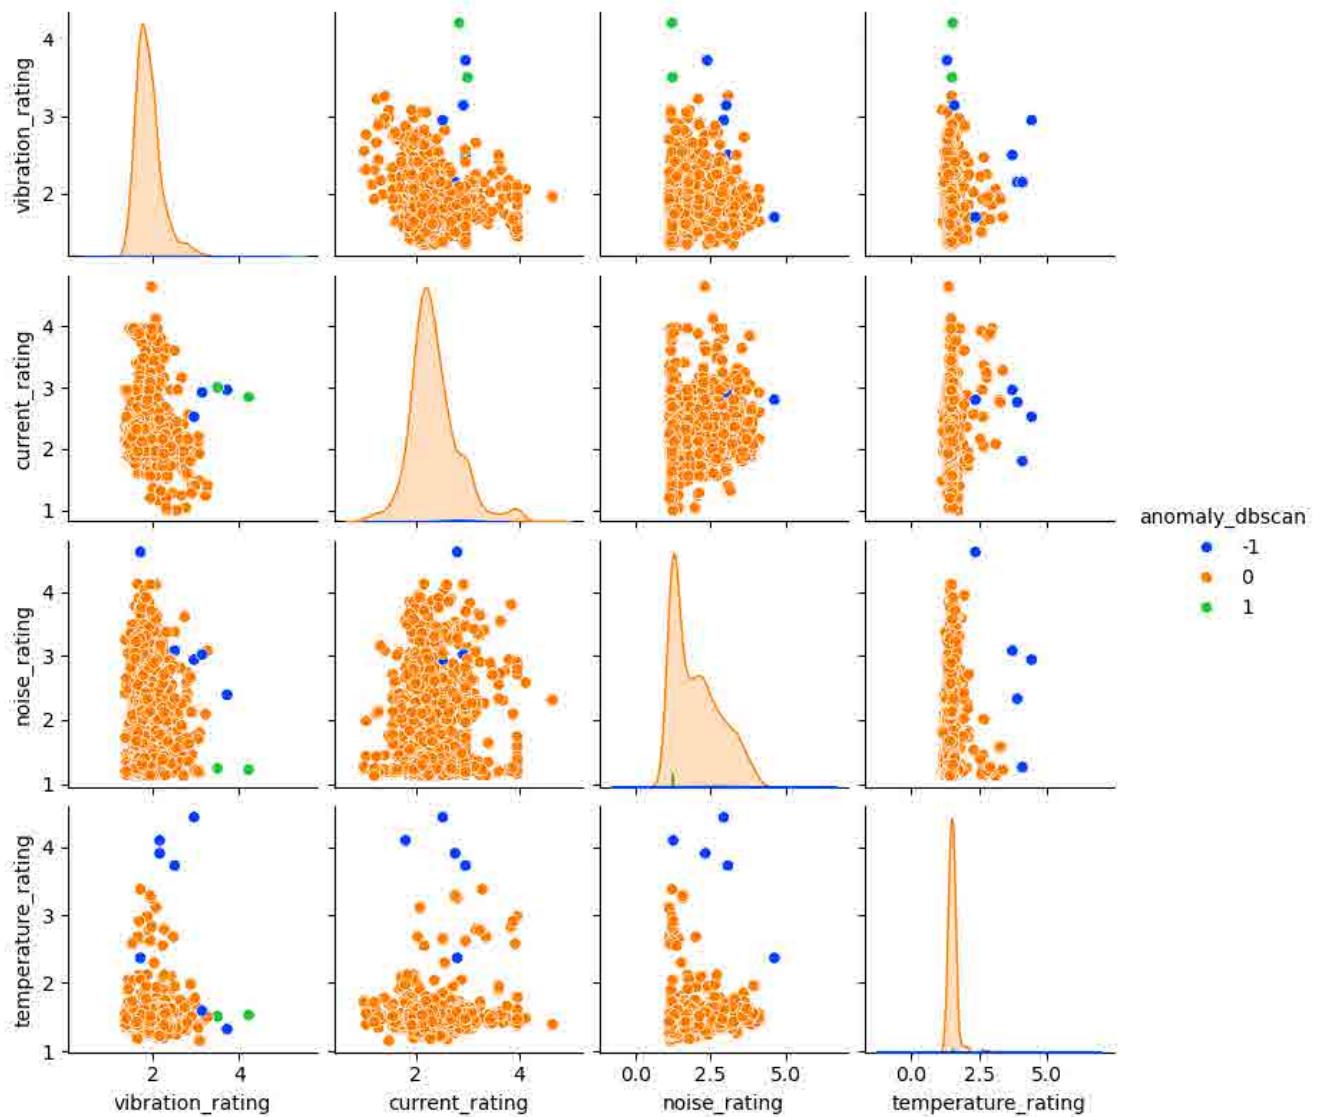


Рисунок 3.11 Виявлені алгоритмом DBScan точки аномалій в наборі даних, що не відповідають кластерам даних

	engine_id	vibration_rating	current_rating	noise_rating	temperature_rating	anomaly	anomaly2	anomaly_dbSCAN
247	Engine 248	2.50	2.96	3.08	3.73	-1	-1	-1
274	Engine 275	2.15	2.76	2.33	3.91	-1	-1	-1
501	Engine 502	3.72	2.96	2.39	1.32	1	-1	-1
601	Engine 602	2.15	1.80	1.26	4.10	-1	1	-1
666	Engine 667	2.95	2.52	2.94	4.44	-1	-1	-1
795	Engine 796	3.14	2.92	3.02	1.59	1	1	-1
915	Engine 916	1.70	2.80	4.62	2.37	-1	1	-1

Рисунок 3.12 Виявлені алгоритмом DBScan точки аномалій в наборі даних, що не відповідають кластерам даних

Таким чином використання наведених методів визначення аномалій забезпечує численні переваги для мідприємств щодо попередження несподіваних відмов обладнання та винекнення незапланованих простоїв на виробництві.

ВИСНОВКИ ТА ПРОПОЗИЦІЇ

1. У практиці промислового виробництва та системного обслуговування моніторинг несправностей деяких машин та обладнання спирається на моделі класифікації та діагностики, навчені на великих обсягах експлуатаційних даних. Однак, збирати дані про роботу обладнання, яке тривалий час перебуває в несправному стані, непрактично. Методи на основі DBScan для усунення дисбалансів на малих вибірках ефективно вирішують цю проблему. Тим не менш, різні методи відрізняються за своїм застосуванням, принципами, структурами та процесами навчання. Тому в цій статті представлено комплексний огляд цих методів з різних точок зору.

2. Проблема незбалансованих методів діагностики несправностей полягає в тому, щоб зменшити упередженість розпізнавання, притаманну традиційним моделям машинного навчання, насамперед через недостатню кількість вибірок несправностей у певних класах. Крім того, асиметричний розподіл даних ускладнює встановлення ефективних меж прийняття рішень. Незбалансований набір даних про несправності ще більше загострює проблему, враховуючи високі витрати на придбання або дефіцит зразків несправностей в умовах обмежень, що призводить до потенційного ігнорування або неправильної класифікації критичних проблем у практичних застосуваннях. Типові рішення включають підходи на рівні даних, такі як надмірна вибірка, недостатня вибірка, змішана вибірка і методи генерації даних (в тому числі VAE, GAN і дифузійні моделі). Алгоритмічні рішення включають функції втрати ваги для визначення пріоритетності зразків міноритарних класів під час навчання моделі, а також інтегроване навчання за допомогою ансамблевих методів, що поєднують кілька моделей і методів. У реальних промислових сценаріях ефективні рішення все частіше вимагають поєднання цих методів, оскільки поодинокі підходи часто виявляються недостатніми. Проста архітектура забезпечує безперешкодну інтеграцію з різними методологіями, значно покращуючи результати в структурі мережі, оптимізації функції втрат, попередній обробці даних і картографуванні функцій. Таким чином,

дослідження застосування методу для діагностики незбалансованих несправностей відкриває можливості для майбутніх досліджень і методологічної синергії.

3. В даний час метод широко використовується в галузі діагностики механічних несправностей. Він має кращу здатність витягувати більш глибокі характеристики зразка в порівнянні з традиційним методом вибірки. Застосовуючи різні мережеві структури та поєднуючи деякі класифікатори з ефективною класифікаційною здатністю, методи діагностики несправностей на основі методу відіграють ключову роль у моніторингу стану, експлуатації та технічному обслуговуванні промислового обладнання, прогнозуванні терміну служби та запобіганні нещасним випадкам на виробництві. Огляд методів діагностики несправностей на основі методу може бути корисним для багатьох сфер застосування в промисловості, обробці даних, а також для розробки моделей діагностики несправностей конкретного обладнання.

4. Існуючі методи діагностики несправностей на основі методу мають справу з одним сигналом про несправність після виконання завдання класифікації, в той час як реальні відмови механічних систем супроводжуються крайнім дисбалансом, особливо в таких випадках: дані містять велику кількість шуму, кластери даних про стан несправності мають розсіяний розподіл, перекриття класів і т.д. Зокрема, існує дефіцит досліджень щодо синхронної інтеграції наборів даних з декількох джерел, з декількома несправностями в складних умовах при діагностиці несправностей, що включають змішані дані. Це особливо актуально для вирішення складнощів, що виникають через одночасну наявність режимів з декількома відмовами, багатокласового дисбалансу і проблем багатокласового дисбалансу, як згадувалося раніше. Дослідження шляхів вирішення цих проблем має вирішальне значення для комплексного вирішення складнощів, пов'язаних зі змінними умовами, асоційованими з багатоаварійними режимами, що робить дослідження вирівнювання даних за таких обставин надзвичайно цінним.

5. Експлуатація та обслуговування високотехнологічного обладнання, особливо в екстремальних умовах, вимагає швидкої діагностики несправностей і

моніторингу аномальних станів, стикаючись з такими проблемами, як затримка реакції, високе споживання обчислювальних ресурсів, відсутність міток для короткочасних аномальних даних і шумові перешкоди, рішення можуть включати в себе використання попередньо навчених ансамблевих моделей. Ці моделі можуть використовувати онлайн-навчання і розподілені обчислення, поряд з ефективними методами апаратного прискорення, щоб забезпечити оновлення і висновок в реальному часі. Крім того, такі моделі можуть використовувати підходи до навчання з напівконтролем або самоконтролем, щоб зменшити залежність від аnotatedних даних. Аналізуючи потоки даних пристройів, моделі виявляються цінними для аналізу потоків даних обладнання, вивчення нормальних розподілів робочих станів і виявлення аномалій. Однак деяке робоче обладнання стикається з проблемами при зборі даних, а фактичні дані часто містять шум, що ускладнює навчання точних і своєчасних діагностичних моделей з обмеженим обсягом даних. Методи знаходять застосування у сфері цифрових двійників, заповнюючи прогалини в даних шляхом інтерполяції та доповнення відсутніх даних, створюючи таким чином більш точні цифрові двійники. Однак залишаються проблеми, наприклад, усунення суттєвих відмінностей між покращеними даними та вихідними даними.

6. Властива методам природа "чорної скриньки" робить процес навчання складним для точного контролю, поточні проблеми включають погану інтерпретованість, труднощі в точному з'ясуванні взаємозв'язку між латентним простором і згенерованими даними, а також розрізnenня відмінностей між реальними і згенерованими даними. Балансування якості та різноманітності згенерованих вибірок становить значну проблему. Вплив параметрів моделі на навчання є яскраво вираженим, що посилює труднощі, особливо при обмежених розмірах вибірок, коли виникають такі проблеми, як нестабільність навчання та колапс моделі. Майбутні дослідження повинні зосередитися на інноваційних методах регуляризації для стабілізації навчання, використовуючи моделі нейронних мереж з меншою кількістю параметрів для базової структури методу, щоб

зменшити обчислювальну складність. Такі методи, як навчання з підкріпленням та еволюційні обчислення, можуть ще більше покращити процес навчання та підвищити якість генерації. Враховуючи дедалі складніші контексти застосування та різноманітні модальності даних, дослідження методів умовної генерації та архітектур, здатних обробляти мультимодальні дані, є вкрай необхідним.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Морозов В. В. Використання ціннісного підходу для управління інноваційними проектами / В. В. Морозов, А. С. Коломієць // Управління розвитком складних систем. - 2021. - Вип. 48. - С. 32-38.
2. Himeur Y., Alsaifi A., Bensaali F., Amira A., Sardianos C., Varlamis I., et al. On the applicability of 2d local binary patterns for identifying electrical appliances in non-intrusive load monitoring Arai K., Kapoor S., Bhatia R. (Eds.), Springer International Publishing, Cham (2021), pp. 188-205
3. Шпак Н. О. Економічне обґрунтування управління бізнес-проектами підприємств / Н. О. Шпак, Р. З. Будинський // Бізнес Інформ. - 2020. - № 4. - С. 498-504.
4. Сметанюк О. А. Особливості системи управління проектами в it-компаніях / О. А. Сметанюк, А. В. Бондарчук // Агросвіт. - 2020. - № 10. - С. 105-111.
5. Sardianos C., Varlamis I., Dimitrakopoulos G., Anagnostopoulos D., Alsaifi A., Himeur Y., The emergence of explainability of intelligent systems: Delivering explainable and personalised recommendations for energy efficiency Int J Intell Syst (2020), pp. 1-22
6. Бушуєв С. Д. Життєвий цикл хмарних технологій управління проектами та програмами / С. Д. Бушуєв // Управління проектами та розвиток виробництва. - 2011. - № 3. - С. 9-14.
7. Бурлуцька С. В. Системний підхід до управління проектами / С. В. Бурлуцька, С. В. Бурлуцький // Часопис економічних реформ. - 2020. - № 3. - С. 65-73.
8. Згалат-Лозинська Л. О. Напрями удосконалення державного регулювання процесу управління інноваційними проектами в науковій сфері / Л. О. Згалат-Лозинська // Підприємництво та інновації. - 2020. - Вип. 13. - С. 7-13.

9. Sardianos C., Varlamis I., Dimitrakopoulos G., Anagnostopoulos D., Alsaifi A., Bensaali F., et al. Rehab-c: recommendations for energy habits change Future Gener Comput Syst, 112 (2020), pp. 394-407
10. Русанова О. В. Спосіб управління проектами на основі мережевого планування / О. В. Русанова, О. В. Корочкин, Ю. І. Медведкова // Проблеми інформатизації та управління. - 2022. - Вип. 3. - С. 51-56.
11. Varlamis I., Sardianos C., Dimitrakopoulos G., Alsaifi A., Himeur Y., Bensaali F., et al. Reshaping consumption habits by exploiting energy-related micro-moment recommendations: a case study Communications in computer and information science, Springer International Publishing, Cham (2020), pp. 1-22
12. Семенчук К. Л. Управління проектами в ланцюгах постачань / К. Л. Семенчук // Розвиток методів управління та господарювання на транспорті. - 2021. - Вип. 4. - С. 48-67.
13. Когут І. В. Методології управління проектами в інформаційних технологіях, їх переваги та недоліки / І. В. Когут, С. В. Сачук // Міжнародний науковий журнал "Інтернаука". Серія : Економічні науки. - 2022. - № 4. - С. 80-85.
14. Rau H., Moran P., Manton R., Goggins J. Changing energy cultures? household energy use before and after a building energy efficiency retrofit Sustain Cities Soc, 54 (2020), Article 101983
15. Ngarambe J., Yun G. Y., Santamouris M. The use of artificial intelligence (ai) methods in the prediction of thermal comfort in buildings: energy implications of ai-based thermal comfort controls Energy Build, 211 (2020), Article 109807
16. Himeur Y., Elsaei A., Bensaali F., Amira A. Efficient multi-descriptor fusion for non-intrusive appliance recognition The IEEE international symposium on circuits and systems (ISCAS) (2020), pp. 1-5

17. Pham A.-D., Ngo N.-T., Ha Truong T.T., Huynh N.-T., Truong N.-S. Predicting energy consumption in multiple buildings using machine learning for improving energy efficiency and sustainability *J Clean Prod*, 260 (2020), Article 121082
18. Luo X., Oyedele L.O., Ajayi A.O., Akinade O.O. Comparative study of machine learning-based multi-objective prediction framework for multiple building energy loads *Sustain Cities Soc*, 61 (2020), Article 102283
19. Himeur Y., Alsalemi A., Al-Kababji A., Bensaali F., Amira A. Data fusion strategies for energy efficiency in buildings: overview, challenges and novel orientations *Inf Fusion*, 64 (2020), pp. 99-120
20. Alsalemi A., Sardianos C., Bensaali F., Varlamis I., Amira A., Dimitrakopoulos G. The role of micro-moments: A survey of habitual behavior change and recommender systems for energy saving *IEEE Syst J*, 13 (3) (2019), pp. 3376-3387
21. Chen C., Zarazua de Rubens G., Xu X., Li J. Coronavirus comes home energy use, home energy management, and the social-psychological factors of covid-19 *Energy Res Soc Sci*, 68 (2020), Article 101688
22. Magazzino C., Mele M., Schneider N. The relationship between air pollution and covid-19-related deaths: an application to three french cities *Appl Energy*, 279 (2020), Article 115835
23. Brilisauer M., Goette L., Jiang Z., Schmitz J., Schubert R. Appliance-specific feedback and social comparisons: evidence from a field experiment on energy conservation *Energy Policy*, 145 (2020), Article 111742
24. Himeur Y., Elsalemi A., Bensaali F., Amira A. Improving in-home appliance identification using fuzzy-neighbors-preserving analysis based QR-decomposition *International congress on information and communication technology (ICICT)* (2020), pp. 1-8

25. Himeur Y., Alsalemi A., Bensaali F., Amira A. Robust event-based non-intrusive appliance recognition using multi-scale wavelet packet tree and ensemble bagging tree *Appl Energy*, 267 (2020), Article 114877
26. Elsalemi A., Himeur Y., Bensaali F., Amira A. Appliance-level monitoring with micro-moment smart plugs *The fifth international conference on smart city applications (SCA)* (2020), pp. 1-5
27. Rashid H., Singh P. Monitor: An abnormality detection approach in buildings energy consumption 2018 IEEE 4th international conference on collaboration and internet computing (CIC) (2018), pp. 16-25
28. Himeur Y., Alsalemi A., Bensaali F., Amira A. A novel approach for detecting anomalous energy consumption based on micro-moments and deep neural networks *Cogn Comput*, 12 (6) (2020), pp. 1381-1401
29. Rashid H., Singh P., Stankovic V., Stankovic L. Can non-intrusive load monitoring be used for identifying an appliance's anomalous behaviour, *Appl Energy*, 238 (2019), pp. 796-805
30. Wang A., Lam J.C., Song S., Li V.O., Guo P. Can smart energy information interventions help householders save electricity? a svr machine learning approach *Environ Sci Policy*, 112 (2020), pp. 381-393
31. Gaur M., Makonin S., Bajić I.V., Majumdar A. Performance evaluation of techniques for identifying abnormal energy consumption in buildings *IEEE Access*, 7 (2019), pp. 62721-62733
32. Rashid H., Stankovic V., Stankovic L., Singh P. Evaluation of non-intrusive load monitoring algorithms for appliance-level anomaly detection *ICASSP 2019 - 2019 IEEE international conference on acoustics, speech and signal processing (ICASSP)* (2019), pp. 8325-8329

33. Kumar K.S.A., Chacko A.M.M.O. Clustering algorithms for intrusion detection: A broad visualization, ICTCS '16, 9781450339629, Association for Computing Machinery, New York, NY, USA (2016)
34. Ariyaluran Habeeb R.A., Nasaruddin F., Gani A., Amanullah M.A., Abaker Targio Hashem I., et al. Clustering-based real-time anomaly detection—A breakthrough in big data technologies Trans Emerg Telecommun Technol (2019), pp. 1-27
35. Vanem E., Brandster A. Unsupervised anomaly detection based on clustering methods and sensor data on a marine diesel engine J Mar Eng Technol (2019), pp. 1-18
36. Verma K., Singh B., Dixit A. A review of supervised and unsupervised machine learning techniques for suspicious behavior recognition in intelligent surveillance system Int J Inf Technol (2019), pp. 1-14
37. Ahmed M., Mahmood A.N., Islam M.R. A survey of anomaly detection techniques in financial domain Future Gener Comput Syst, 55 (2016), pp. 278-288
38. Feng B., Li Q., Pan X., Zhang J., Guo D. Groupfound: An effective approach to detect suspicious accounts in online social networks Int J Distrib Sens Netw, 13 (7) (2017), Article 1550147717722499
39. Pastore V., Zimmerman T., Biswas S., Bianco S. Annotation-free learning of plankton for classification and anomaly detection Sci Rep, 10 (2020), pp. 1-15
40. Arjunan P., Khadilkar H.D., Ganu T., Charbiwala Z.M., Singh A., Singh P. Multi-user energy consumption monitoring and anomaly detection with partial context information Proceedings of the 2nd ACM international conference on embedded systems for energy-efficient built environments, BuildSys 15, 9781450339810, Association for Computing Machinery, New York, NY, USA (2015), pp. 35-44
41. Rossi B., Chren S., Buhnova B., Pitner T. Anomaly detection in smart grid data: An experience report 2016 IEEE international conference on systems, man, and cybernetics (SMC) (2016), pp. 002313-002318

42. Henriques J., Caldeira F., Cruz T., Simes P. Combining K-means and xgboost models for anomaly detection using log datasets Electronics, 9 (7) (2020), pp. 1-16
43. Izakian H., Pedrycz W. Anomaly detection in time series data using a fuzzy c-means clustering 2013 joint IFSA world congress and NAFIPS annual meeting (IFSA/NAFIPS) (2013), pp. 1513-1518
44. Yeckle J., Tang B. Detection of electricity theft in customer consumption using outlier detection algorithms 2018 1st international conference on data intelligence and security (ICDIS) (2018), pp. 135-140
45. Nychis G., Sekar V., Andersen D.G., Kim H., Zhang H. An empirical evaluation of entropy-based traffic anomaly detection IMC '08, 9781605583341, Association for Computing Machinery, New York, NY, USA (2008), pp. 151-156
46. BereziÅski P., Jasiul B., Szpyrka M. An entropy-based network anomaly detection method Entropy, 17 (4) (2015), pp. 2367-2408
47. Shi Z., Li P., Sun Y. An outlier generation approach for one-class random forests: An example in one-class classification of remote sensing imagery 2016 IEEE international geoscience and remote sensing symposium (IGARSS) (2016), pp. 5107-5110
48. Ruff L., Vandermeulen R., Goernitz N., Deecke L., Siddiqui S.A., Binder A., et al. Deep one-class classification Dy J., Krause A. (Eds.), Proceedings of Machine Learning Research, vol. 80, PMLR, Stockholm, Sweden (2018), pp. 4393-4402
49. Jakkula V.R., Cook D.J. Detecting anomalous sensor events in smart home data for enhancing the living experience. Artificial intelligence and smarter living, AAAI Workshops, WS-11-07, AAAI (2011)
50. Oza P., Patel V.M. One-class convolutional neural network IEEE Signal Process Lett, 26 (2) (2019), pp. 277-281

51. Zhang M., Wu J., Lin H., Yuan P., Song Y. The application of one-class classifier based on cnn in image defect detection Procedia Comput Sci, 114 (2017), pp. 341-348
52. Dsir C., Bernard S., Petitjean C., Heutte L. One class random forests Pattern Recognit, 46 (12) (2013), pp. 3490-3506
53. Ghori K., Imran M., Nawaz A., Abbasi R., Ullah A., Szathmary L. Performance analysis of machine learning classifiers for non-technical loss detection J Ambient Intell Humaniz Comput (2020), pp. 1-16
54. Liu F.T., Ting K.M., Zhou Z.-H. Isolation-based anomaly detection ACM Trans Knowl Discov Data (TKDD), 6 (1) (2012), pp. 1-39
55. Huang T., Sethu H., Kandasamy N. A new approach to dimensionality reduction for anomaly detection in data traffic IEEE Trans Netw Serv Manag, 13 (3) (2016), pp. 651-665
56. Valko M., Kveton B., Valizadegan H., Cooper G.F., Hauskrecht M. Conditional anomaly detection with soft harmonic functions 2011 IEEE 11th international conference on data mining (2011), pp. 735-743
57. Naveen P., Ing W.K., Danquah M.K., Sidhu A.S., Abu-Siada A. Cloud computing for energy management in smart grid - an application survey IOP Conf Ser: Mater Sci Eng, 121 (2016), Article 012010
58. Brown C.E. Multiple discriminant analysis Springer Berlin Heidelberg, Berlin, Heidelberg (1998), pp. 115-128
59. Wu J., Zhang X. A pca classifier and its application in vehicle detection IJCNN'01. international joint conference on neural networks. Proceedings (Cat. No. 01CH37222), Vol. 1, IEEE (2001), pp. 600-604
60. Kudo T., Morita T., Matsuda T., Takine T. Pca-based robust anomaly detection using periodic traffic behavior 2013 IEEE international conference on communications workshops (ICC) (2013), pp. 1330-1334, 10.1109/ICCW.2013.6649443

62. Himeur Y., Elsalemi A., Bensaali F., Amira A. Smart power consumption abnormality detection in buildings using micro-moments and improved K-nearest neighbors Int J Intell Syst (2020), pp. 1-25
63. Kamaraj K., Dezfouli B., Liu Y. Edge mining on IoT devices using anomaly detection 2019 Asia-Pacific signal and information processing association annual summit and conference (APSIPA ASC) (2019), pp. 33-40
64. Alheeti K.M., Gruebler A., McDonald-Maier K. Application of multiple discriminant analysis (mda) as a credit scoring and risk assessment model Int J Emerging Mark, 6 (2011), pp. 132-147
65. Chijoriga M. Application of multiple discriminant analysis (MDA) as a credit scoring and risk assessment model Int J Emerging Mark, 6 (2011), pp. 132-147
66. Kiran B.R., Thomas D.M., Parakkal R. An overview of deep learning based methods for unsupervised and semi-supervised anomaly detection in videos J Imaging, 4 (2) (2018), pp. 1-25
67. Wang R., Nie K., Wang T., Yang Y., Long B. Deep learning for anomaly detection, WSDM '20, Association for Computing Machinery, New York, NY, USA (2020), pp. 894-896
68. Weng Y., Zhang N., Xia C. Multi-agent-based unsupervised detection of energy consumption anomalies on smart campus IEEE Access, 7 (2019), pp. 2169-2178