

Харківський національний університет радіоелектроніки

Факультет навчально-науковий центр заочної форми навчання

Кафедра електронних обчислювальних машин

Рівень вищої освіти другий (магістерський)

Спеціальність 123 «Комп'ютерна інженерія»
(код і повна назва)

Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Системне програмування
(повна назва)

ЗАТВЕРДЖУЮ:

В.о.зав. кафедри _____
(підпис)

“ _____ ” _____ 20__ р.

ЗАВДАННЯ

НА КВАЛІФІКАЦІЙНУ РОБОТУ

студенту Гладуш Діані Борисівні
(прізвище, ім'я, по батькові)

1. Тема роботи Метод прогнозного обслуговування промислового обладнання з використанням машинного навчання

затверджена наказом по університету від “ 25 ” березня 2022 р. № 33 Стз

2. Термін подання студентом роботи до екзаменаційної комісії 18 травня 2022 р.

3. Вхідні дані до роботи _____

Промислове обладнання

Прогнозування

Машинне навчання

4. Перелік питань, що потрібно опрацювати у роботі _____

Використання промислового обладнання

Методи машинного навчання

Побудова моделей прогнозування з використанням машинного навчання

Порівняльний аналіз результатів

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (слайдів) 14

6. Консультанти розділів роботи (заповнюється за наявності консультантів згідно з наказом, зазначеним у п.1)

Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		Підпис	дата

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Аналіз матеріалів існуючих досліджень	29.03-04.04	
2	Аналіз промислового обладнання	05.05-07.04	
3	Методи машинного навчання	07.04-10.04	
4	Вибір методу тамаодельовання	10.04-15.04	
5	Формування пояснювальної записки	16.04-29.04	
6	Проходження нормоконтролю	29.04-11.05	
7	Підготовка до захисту	12.05-15.05	
8	Захист	15.05-29.05	

Дата видачі завдання 28 березня 2022 р.

Студент _____
(підпис)

Керівник роботи _____
(підпис)

доц. Ляшенко О.С..
(посада, прізвище, ініціали)

РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 71 с., 36 рис., 10 табл., 1 дод., 23 джерел.

ПРОГНОЗУВАННЯ, МАШИННЕ НАВЧАННЯ, НЕЙРОНІ МЕРЕЖІ, ГЛИБОКЕ НАВЧАННЯ, ПРОМИСЛОВЕ ОБЛАДНАННЯ.

Метою кваліфікаційної роботи є вибор метода машинного навчання для прогнозування несправностей при обслуговуванні промислового обладнання. На базі обраних методів було побудовано моделі для прогнозування несправностей коробки передач та підшипників. Проведено порівняльний аналіз сучасних методів.

ABSTRACT

Master's thesis: 71 pages, 36 figures, 10 tables, 1 appendices, 23 sources.

FORECASTING, MACHINE LEARNING, NEURAL NETWORKS, DEEP LEARNING, INDUSTRIAL EQUIPMENT.

The major goal of this thesis is to choose a method of machine learning to predict faults in the maintenance of industrial equipment. Based on the selected methods, models for predicting gearbox and bearing failures were built. A comparative analysis of modern methods.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ	8
ВСТУП	9
1 ПРОМИСЛОВЕ ОБСЛУГОВУВАННЯ ТА МАШИННЕ НАВЧАННЯ	11
1.1 Аналіз основних робіт за темою дослідження.....	11
1.2 Технічне обслуговування	12
1.2.1 Реактивне технічне обслуговування	13
1.2.2 Профілактичне обслуговування	14
1.2.3 Прогнозне обслуговування	15
1.3 Машинне навчання	16
2 НАБІР ДАНИХ І НЕСПРАВНОСТІ.....	19
2.1 Експериментальна установка.....	19
2.2 Набір даних коробки передач	19
2.3 База даних несправностей обладнання	20
2.4 Стани обертової машини.....	21
2.4.1 Нормальний	21
2.4.2 Дисбаланс.....	22
2.4.3 Зміщення по горизонталі.....	22
2.4.4 Вертикальне зміщення.....	22
2.4.5 Несправність підвісного підшипника	23
3 МЕТОДИ.....	24
3.1 Необроблені дані / Зчитування датчиків	25
3.2 Попередня обробка	26
3.3 Конвеєр машинного навчання	28
3.3.1 Дерево рішень.....	29
3.3.2 Випадковий ліс	29
3.3.3 Адаптивне підвищення.....	29

3.4 Конвеєр глибокої нейронної мережі (DNN).....	29
3.5 Оцінка ефективності	32
3.5.1 Confusion matrix.....	32
3.5.2 Точність.....	33
3.5.3 Error Rate (ERR).....	33
3.5.4 True Positive Rate (TPR)	34
3.5.5 False Positive Rate (FPR)	34
3.5.6 Precision.....	34
3.5.7 Показник AUC	34
3.5.8 Крива ROC	35
4 РЕЗУЛЬТАТИ МОДЕЛЮВАННЯ	37
4.1 Прогноз несправності коробки передач	37
4.1.1 Оцінка ефективності на вихідних даних	39
4.1.2 Оцінка продуктивності нормалізованих даних.....	41
4.2 Прогнозування несправностей обладнання.....	51
4.2.1 Оцінка ефективності моделі ML у наборі даних MFP	53
4.2.2 Оцінка продуктивності моделі DNN у наборі даних MFP	55
ВИСНОВКИ.....	59
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ	61
ДОДАТОК Графічний матеріал кваліфікаційної роботи.....	64

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ
І ТЕРМІНІВ

ML – Машинне навчання

DL – Глибоке навчання

ANN – штучні нейроні мережі

ШІ – Штучний інтелект

ВСТУП

Дослідження полягало в тому, щоб дізнатися про різні види промислового обслуговування та їх проблеми. Крім того, вивчати застосування передових методів аналітики та алгоритми машинного навчання для прогнозування несправностей промислового обладнання. Такі дослідження допомагає команді технічного обслуговування ремонтувати та планувати технічне обслуговування напередодні виникнення проблем, щоб уникнути будь-яких поломок на підприємстві або виробничій лінії.

Насьогодні машинне обладнання відіграє дуже важливу роль у нашому повсякденному житті. Ми покладаємося на машини, у подорожі, у польоті з одного місця в інше, при побудові будинків, доріг чи будувати інфраструктуру. Машини не тільки скорочують час, але й підвищують продуктивність.

Автомобільна та обробна промисловість значною мірою покладаються на різні типи машин. Деякі машини, які використовуються в цих галузях, прості у використанні та експлуатації, а деякі з них дуже складні та вимагають регулярного обслуговування для виконання своїх щоденних операцій. Таке технічне обслуговування знизило продуктивність і збільшило вартість обслуговування [1].

У зв'язку з нинішньою ситуацією, пов'язаною з пандемією COVID-19, більшість галузей промисловості перейшли до цифровізації. Також необхідно автоматизувати процес обслуговування вручну. Автомобільна промисловість також переходить від реактивного до прогнозного технічного обслуговування.

Коробка передач і ротаційні машини є найважливішими компонентами промислового обладнання та відіграють важливу роль у різних промислових застосуваннях. Деякі з застосувань цих компонентів використовуються в автомобільній промисловості, видобутку нафти та газу, вітрових турбінах,

обробній промисловості, гідроенергетиці, гірничодобувній промисловості, заводах по переробці відходів тощо. Несправності коробки передач і обертальних машин є дорогими як з точки зору ремонту, так і з точки зору втрати продукції у виробництві. Іноді ці втрати або несправності можуть призвести до повної поломки обладнання або установки. Щоб уникнути критичних пошкоджень і раптової поломки, слід виявити несправності цих компонентів якомога раніше.

1. Коробка передач – це бінарна класифікаційна задача; ми можемо уникнути втрат, передбачивши стан здоров'я коробки передач, наприклад:

- нормальний;
- зламані зуби коробки передач.

2. Ротаційні машини є проблемою мультикласифікації, ми можемо уникнути ротаційних машин збитки шляхом прогнозування нормальної роботи та несправного стану механізмів, таких як:

- нормальний;
- незбалансований;
- горизонтальне зміщення;
- вертикальне зміщення;
- несправності підшипників;
- несправності підшипників.

Популярність машинного навчання (ML) швидко зростає в промисловій автоматизації. Тепер доступно отримувати дані з датчиків або пристроїв IoT і зберігати їх у базі даних. Наявність цих історичних даних полегшує побудову та навчання моделей ML та прогнозування поточного та майбутнього стану промислових машин. Це допомагає технічній команді уникнути позапланового технічного обслуговування.

Запропоноване рішення засноване на техніці ML і глибокого навчання (DL), таких як дерево рішень, випадковий ліс і глибока нейронна мережа (DNN), щоб передбачити різні типи збоїв у цих промислових компонентах. Це допоможе команді технічного обслуговування відремонтувати або замінити компоненти до того, як виникнуть несправності.

1 ПРОМИСЛОВЕ ОБСЛУГОВУВАННЯ ТА МАШИННЕ НАВЧАННЯ

1.1 Аналіз основних робіт за темою дослідження

Раніше було опубліковано кілька досліджень щодо виявлення несправностей в коробці передач і обертових механізмах кількома групами за допомогою кількох методів, як коротко наведено нижче.

Ф. Рібейро та ін. використовували методи немашинного навчання, такі як моделі на основі подібності, щоб автоматично класифікувати несправності в обертових механізмах [4]. В результаті вони класифікують несправності з точністю 96,43 відсотка.

В іншому дослідженні, автори класифікували поворотні дефекти з точністю 97,1 відсотка за допомогою штучної нейронної мережі (ANN) [5]. Як і в нашому дослідженні, в обох дослідженнях була використана база даних машинних несправностей MAFAULDA [4-6].

Аналогічно, алгоритми попередньої обробки на основі обробки сигналів і нейронні мережі були використані для класифікації несправностей коробок передач в іншому дослідженні [7]. Ці моделі виявляють і класифікують несправності коробки передач без будь-яких помилок.

Жанг Кянг показав, що використовують самоорганізуючі моделі несправностей на основі карти для виявлення несправностей коробки передач з точністю 95 відсотків [8].

З цими новими методами та методологіями все ще залишається кілька проблем, таких як обчислювальні ресурси та методи програмування, як детально обговорюється в одному з досліджень [8].

Р. Сауфі та ін. у 2019 році [9]. У цьому дослідженні вони висвітлили проблеми виявлення несправностей машин за допомогою глибокого навчання. Основні проблеми впровадження системи на основі глибокого навчання для прогнозування несправностей машин вимагали

високопродуктивних ресурсів, таких як система на основі графічного процесора [9].

Іншою проблемою під час виконання цього типу досліджень є навчання моделі DL на рівні архітектури. Вибір функції активації та навчання моделі вимагали попередніх знань. Зараз при реалізації такого типу системи використовуються різні типи інструментів програмування. Кожне середовище програмування має різні стилі кодування. Це може вплинути на ефективність діагностики несправностей моделі. Для побудови моделі DL потрібна величезна кількість історичних даних для навчання та тестування системи [9].

У новому дослідженні, опублікованому в 2021 році С. Айвою, порівняльний аналіз та оцінка кількох алгоритмів ML було виконано Серканом Айвою та співавторами [10]. Їх результати показали, що випадковий ліс (RF) перевершує всі інші вивчені алгоритми. Це дозволило їм запровадити найкращу модель машинного навчання у виробничу систему на заводі [10].

1.2 Технічне обслуговування

Витрати на технічне обслуговування в багатьох галузях промисловості вищі за експлуатаційні та виробничі витрати через передчасний вихід з ладу обладнання [9]. Прибутковість будь-якої галузі загалом залежить від процесу обслуговування.

Зазвичай технічне обслуговування в промисловості відбувається, коли обладнання досягає певного віку або перестає працювати [10]. Добре проводити планове технічне обслуговування, але воно не надає жодної інформації про стан обладнання в майбутньому. Для оптимізації надійності виробничих ліній та обладнання можна виконувати різні види технічного обслуговування залежно від ресурсу. Найпоширеніші види промислового обслуговування наведені на рисунку 1.1

- 1 Реактивне обслуговування
- 2 Профілактичне обслуговування
- 3 Прогнозне обслуговування

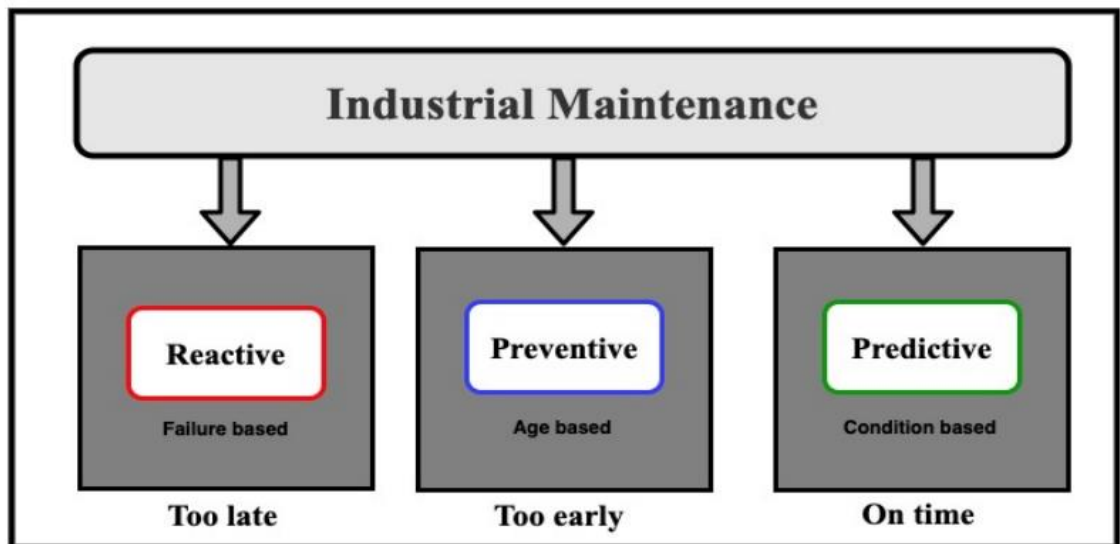


Рисунок 1.1 – Види промислового обслуговування

1.2.1 Реактивне технічне обслуговування

У такому підході технічне обслуговування може виконуватися, коли компоненти або механізми мають проблему або перестають працювати. Зазвичай технічне обслуговування виконується після відмови обладнання, як показано на рисунку 1.2. Хоча компонент або машина використовується на весь термін служби, недоліки цього підходу є:

- позапланове технічне обслуговування;
- збільшується час простою.

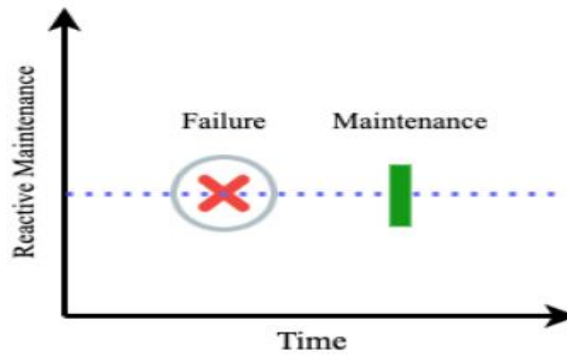


Рисунок 1.2 – Огляд реактивного технічного обслуговування

1.2.2 Профілактичне обслуговування

При такому підході машину або компонент замінюють заздалегідь, перш ніж вони вийдуть з ладу. Це допомагає уникнути позапланового технічного обслуговування. Технічне обслуговування буде виконуватися протягом регулярного інтервалу, як показано на рисунку 1.3. Недоліком цього підходу є [11,12,13]:

- компонент або машина використовуються не повністю;
- виконується надмірне обслуговування.

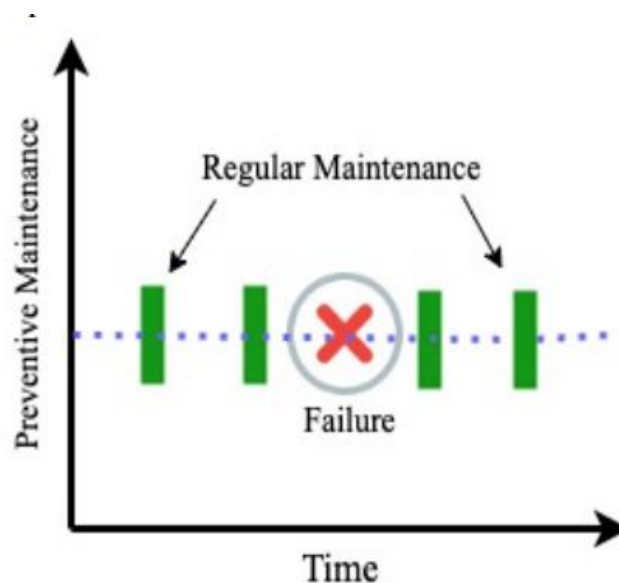


Рисунок 1.3 – Огляд профілактичного обслуговування

Недоліками регулярного технічного обслуговування є:

- час поломки збільшується;
- продуктивність знижується через регулярне технічне обслуговування;
- надмірне технічне обслуговування деякого обладнання або механізмів;
- вартість експлуатації збільшується;
- зменшується термін служби машини;
- для обслуговування обладнання потрібна більш кваліфікована робоча сила.

1.2.3 Прогнозне обслуговування

Він прогнозує несправність і виконує технічне обслуговування машини або обладнання до того, як сталася несправність або збій, як показано на рисунку 1.4. Замінити можуть лише компоненти або машини, які незабаром вийдуть з ладу. Це подовжує термін служби обладнання. Прогнозне обслуговування має декілька переваг [13,14,15], наприклад:

- це може зменшити незаплановані простой;
- це може допомогти виявити несправність або стан обладнання за допомогою моніторингу стану, щоб уникнути дорогого виходу обладнання з ладу;
- це зменшило запланований час простою за рахунок скорочення перевірок та передчасного ремонту. Недоліком такого підходу є дуже висока початкова вартість побудови такої системи.

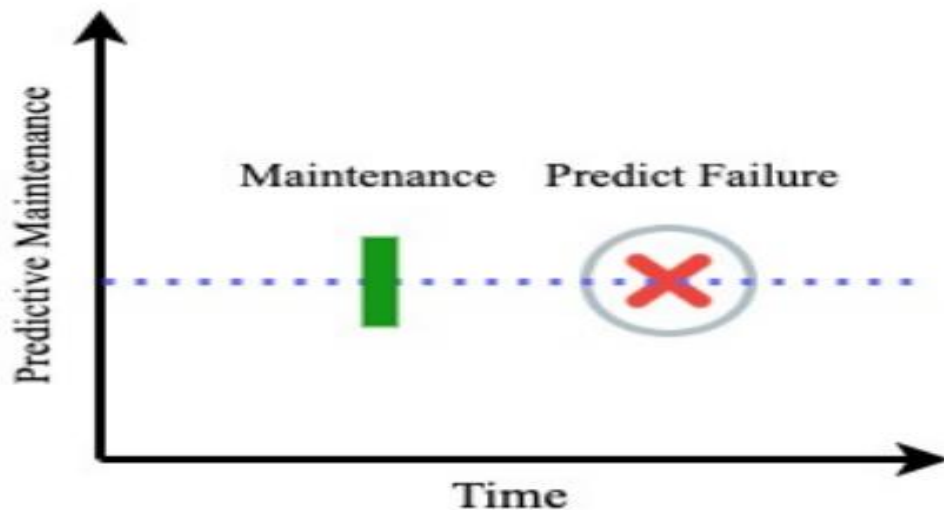


Рисунок 1.4 – Огляд прогнозного технічного обслуговування

1.3 Машинне навчання

Інтернет речей і хмарні обчислення роблять машинне навчання можливим у виробництві та інших галузях.

Тепер набагато простіше отримати дані з промислового обладнання з пристроями IoT. Ці дані з промислового обладнання допоможуть нам побудувати моделі ML для прогнозування несправностей. ML перетворює деякі завдання на машину, яка раніше була неможлива для людей [16].

1.3.1 Типи машинного навчання

ML буває трьох типів:

- навчання під керівництвом;
- навчання без нагляду;
- навчання з підкріпленням (RL).

1 Навчання під керівництвом.

Методи навчання під керівництвом легко зрозуміти та застосувати. Марковані дані надаються моделям ML [17,18]. Це означає, що дані навчання та перевірки позначено.

Набори навчальних даних містять як вхідні дані, так і цільові вихідні дані в контрольованому навчанні, як показано на рисунку 1.5, що дає змогу моделі вивчатися та вдосконалюватися з часом. Коли модель повністю навчена, вона передбачатиме нові або невидимі дані з хорошою міткою. Його можна використовувати як для задач класифікації, так і для задач регресії. Алгоритми навчання з учителем є дерева рішень, випадковий ліс, машина опорних векторів, флот до побачення, лінійна регресія, логістична регресія тощо.




Рисунок 1.5 – Навчання під наглядом

2 Навчання без нагляду.

При цьому підході користувачеві не потрібно надавати дані мітки моделі, він працює з нерозміченими даними [19]. Це дозволяє моделі самостійно виявляти закономірності та інформацію. Рисунок 1.6. Корисно знайти невідомі закономірності в даних. Алгоритмами навчання без нагляду є кластеризація, К-найближчі сусіди (KNN), виявлення аномалій, аналіз основних компонентів (PCA) тощо.

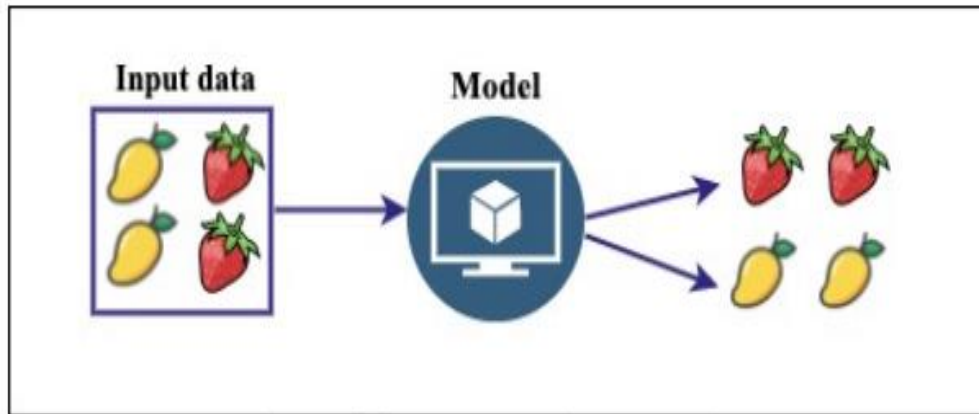


Рисунок 1.6 – Навчання без нагляду

3 Навчання з підкріпленням.

RL є різновидом ML і не вимагає великої кількості навчальних даних. Замість середовищ, що надаються моделям RL, агент навчається у своєму середовищі методом проб і помилок для досягнення цілей та отримання винагород (рисунок 1.7).

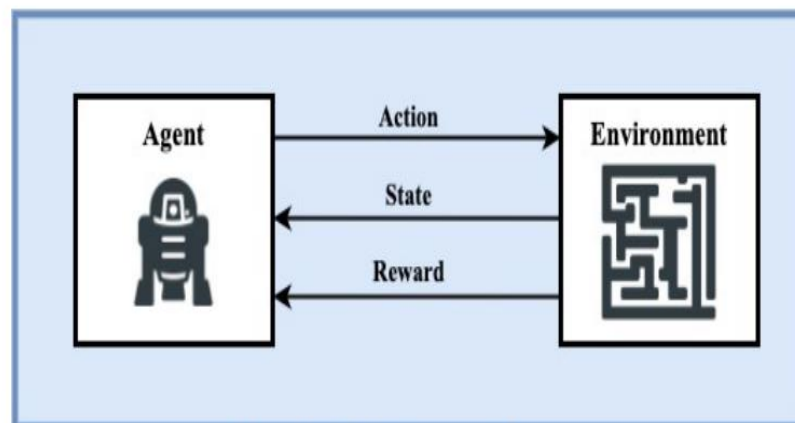


Рисунок 1.7 – Навчання з підкріпленням

2 НАБІР ДАНИХ І НЕСПРАВНОСТІ

Дані є основним компонентом будь-якої моделі ML/DL. Для ефективної роботи цих моделей необхідні якісні дані. Продуктивність моделі ML/DL можна покращити, інтегруючи більше даних у систему ML/DL. Дані можуть бути різних форм, але в основному спирається модель ML:

- числові дані;
- текстові дані;
- категоричні дані;
- дані часових рядів.

2.1 Експериментальна установка

SpectraQuest надає різні типи тренажерів для навчання та вивчення поведінки промислових машин. Ці тренажери прискорюють навчання та допомагають зрозуміти різні типи несправностей промислового обладнання [20]. Дані, які ми використовували для навчання та тестування моделі ML, були взяті з цих симуляторів:

- симулятор діагностики несправностей коробки передач SpectraQuest;
- симулятор несправності обладнання SpectraQuest.

2.2 Набір даних коробки передач

Набір даних коробки передач, використаний у цьому дослідженні, є загальнодоступним у OpenEi [21]. Дані були записані OpenEi [21] з чотирма вібраційними датчиками, розміщеними в різних напрямках на симуляторі діагностики несправностей коробки передач спектральних квестів [20]. Набір даних записується з різним навантаженням від 0 до 90 відсотків і містить інформацію про стан справності коробки передач на основі показань

вібраційних датчиків. Набір даних коробки передач описує лише два стани коробки передач, наприклад:

- нормальний;
- виламані зуби.

2.3 База даних несправностей обладнання

Дані від SpectraQuest Machinery Fault Simulator (MFS) збираються датчиками та зберігаються в базі даних машинних несправностей [6]. База даних містить 1951 багатовимірний часових рядів даних, що складається з шести різних змодельованих станів, таких як:

- звичайний;
- горизонтальне зміщення;
- вертикальне зміщення;
- несправності дисбалансу;
- несправність підшипника;
- несправності зовнішніх підшипників.

База даних несправностей обертових машин містить наступний відсоток кожної категорії даних, як показано на рисунку 2.1.




Рисунок 2.1 – Відсоток даних про обертові машини в базі даних несправностей машини

База даних обертальних машин містить найменшу кількість нормальних даних класу та максимальних даних про несправності підшипників. Підсумок вимірювань показано на рисунку 2.2

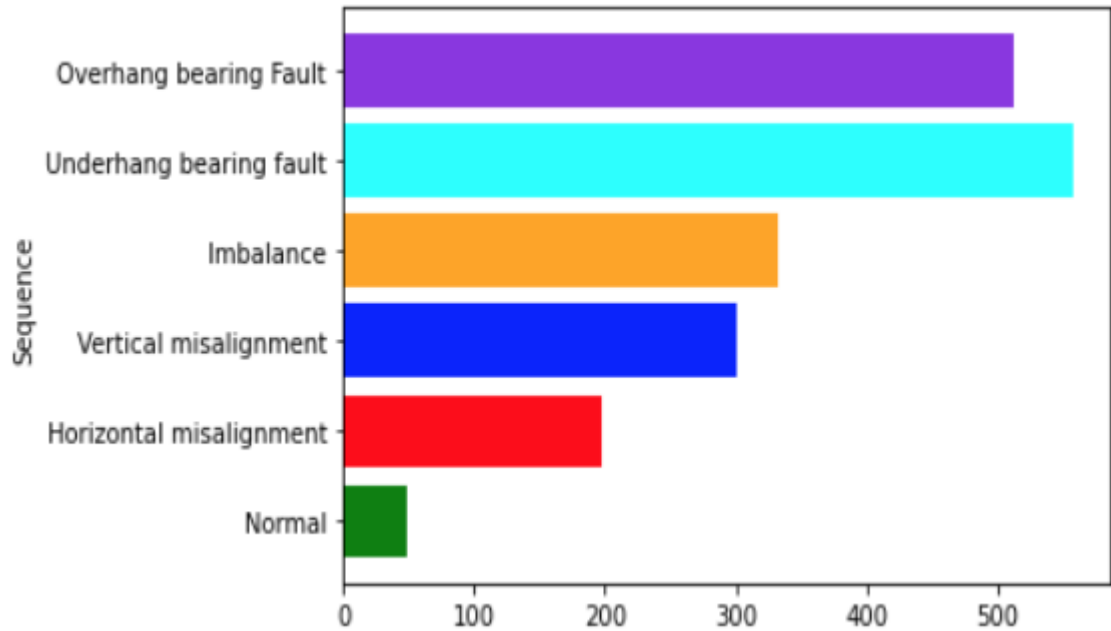


Рисунок 2.2 – Підсумок шести станів вимірювання ротаційних машин

2.4 Стани обертальної машини

Дані, що зберігаються в базі даних несправностей машини, збираються за допомогою шести акселерометрів, мікрофона та тахометра, приєднаних до імітатора несправностей машини [4]. Він містить загалом 1951 сценарій, як показано на рисунку 2.2. Дані описують нормальний і п'ять несправних станів ротаційної машини.

2.4.1 Нормальний

Нормальна послідовність означає без помилок. У цьому дослідженні було використано 49 вимірювань нормальної послідовності, як показано на рисунку 2.2. Ці послідовності були записані з фіксованою швидкістю

обертання (діапазон 737-3686 об/хв) [6].

2.4.2 Дисбаланс

Загальна кількість несправностей дисбалансу склала 333 вимірювання [6]. Дані були записані зі значеннями навантаження (6 г до 35 г), як показано в таблиці 2.1

Таблиця 2.1 – Підсумок вимірювань дисбалансу з різними значеннями навантаження

Вага (г)	6	10	15	20	25	30	35	Всього
Вимірювання	49	48	48	49	47	47	45	333

2.4.3 Зміщення по горизонталі

Кількість горизонтальних паралельних зсувів становила 197, що викликано кожним горизонтальним зсувом, коли вал двигуна зміщував по горизонталі на 0,5 мм, 1,0 мм, 1,5 мм і 2,0 мм у таблиці 2.2 MFS.

Таблиця 2.2 – Підсумок вимірювань горизонтального зсуву з різними значеннями

Зміщення (мм)	0.50	1.00	1.50	2.00	Всього
Вимірювання	50	49	49	49	197

2.4.4 Вертикальне зміщення

Кількість вертикальних паралельних зсувів становила 301, що викликано кожним вертикальним зсувом, коли вал двигуна зміщував по горизонталі на 0,51 мм, 0,63 мм, 1,27 мм, 1,40 мм, 17,8 мм і 1,90 мм в таблиці 2.3 MFS.

Таблиця 2.3 – Підсумок вимірювань вертикального зміщення з різними значеннями

Зміщення (мм)	0.51	0.61	1.27	1.40	1.78	1.9	Всього
Вимірювання	51	50	50	50	50	50	301

2.4.5 Несправність підвісного підшипника

У обертових механізмах підшипник є одним із найскладніших елементів. Несправності підшипників в першу чергу спричиняють поломки обертових машин. Коли підшипник розміщений між ротором і двигуном в MFS. Несправність підшипника має 558 загальних послідовностей із різною вагою (0 г, 6 г, 20 г, 25 г).

Коли ротор розміщений між підшипником і двигуном в MFS. Розлом звисання має 513 загальних послідовностей з різною вагою (0г, 6г, 20г, 25г).

3 МЕТОДИ

Сьогодні штучний інтелект (AI) став популярним у багатьох інших галузях, таких як виробництво та розумні фабрики. Інтернет речей (IoT), великі дані (BD) і хмарні обчислення роблять його доступнішим і для малих галузей. Машини у виробничих галузях стали розумнішими, ніж раніше, завдяки Інтернету речей, III та великим обсягам даних.

Останнім часом більшість галузей обробної промисловості переведено з профілактичного обслуговування на планове обслуговування. Це не тільки підвищує їх продуктивність, але і знижує вартість. ML відіграє значну роль у таких інноваціях. Це також допомагає їм покращувати прийняття рішень і прискорювати процеси відкриття у виробничих секторах. У минулому для промислового обслуговування використовувалися різні методики [4,5,7,8,22,23].

У нашому дослідженні ми використовували як класичне машинне навчання, так і підходи глибокого навчання, щоб передбачити несправність промислових машин, як показано на рисунку 3.1. Ми дотримувались розробки моделі міжгалузевого стандартного процесу для інтелекту даних (CRISP-DM), яка включає наступні кроки/процеси:

- 1) розуміння бізнесу: яке включає розуміння промислового обслуговування та їхніх проблем та запропонованих рішень;
- 2) розуміння даних: включає інформацію/знання про наші набори даних;
- 3) підготовка даних включає етапи попередньої обробки, які допомогли підготувати дані для подальшого аналізу;
- 4) моделювання включає етапи, на яких були застосовані різні моделі аналізу та алгоритми;
- 5) оцінка включає етап, на якому ми оцінювали ефективність різних моделей;

б) Розгортання включає нашу остаточну модель, яка була вибрана та застосована до даних для рішення.

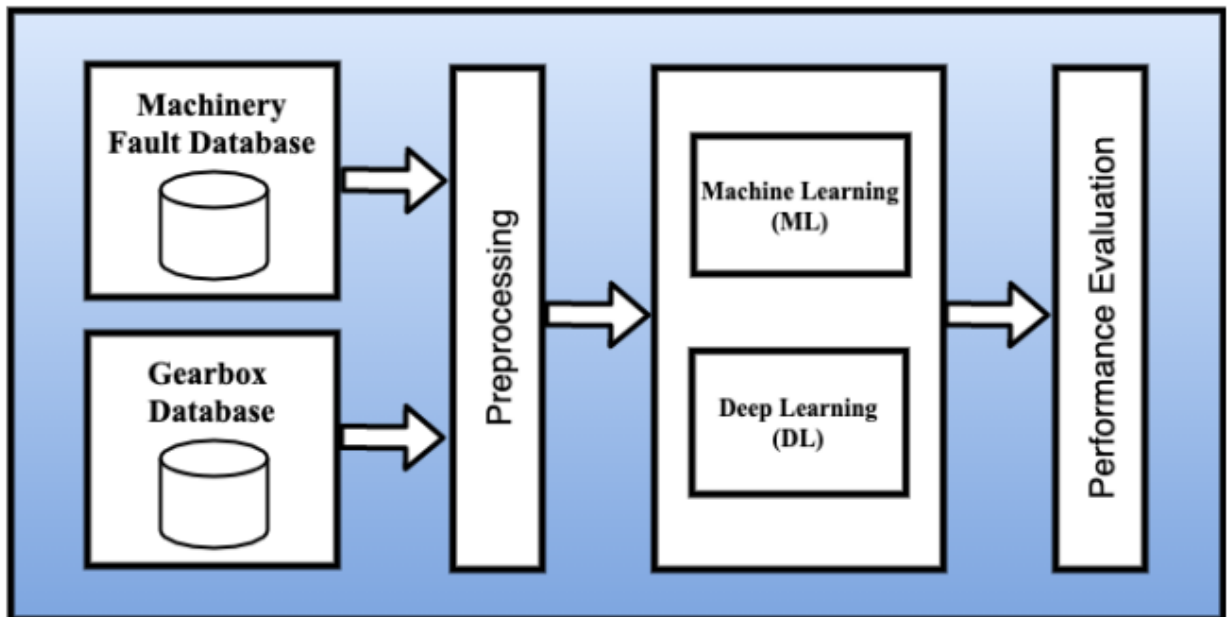


Рисунок 3.1 – Конверс машинного навчання та глибокої нейронної мережі для коробки передач і обертальних машин.

3.1 Необроблені дані / Зчитування датчиків

Дані від коробки передач були зібрані за допомогою чотирьох датчиків вібрації, як показано на рисунку 3.2. Робоча частота, яку використовують датчики, становить 30 Гц. Ці показання з датчиків знімаються шляхом зміни навантаження від 0 до 90 відсотків і зберігаються в базі даних. База даних коробки передач містить інформацію про стан здоров'я коробки передач, наприклад:

- виламані зуби;
- звичайний.




Рисунок 3.2 – Збір даних про коробку передач

Дані, що зберігаються в базі даних несправностей машини, отримуються за допомогою шести акселерометрів, мікрофона та тахометра, приєднаних до імітатора несправностей машини [4], як показано на рисунку 3.3. Всього він містить 1951 сценарій з різними умовами експлуатації та навантаженнями. Дані описують нормальний і п'ять несправних станів ротаційної машини.

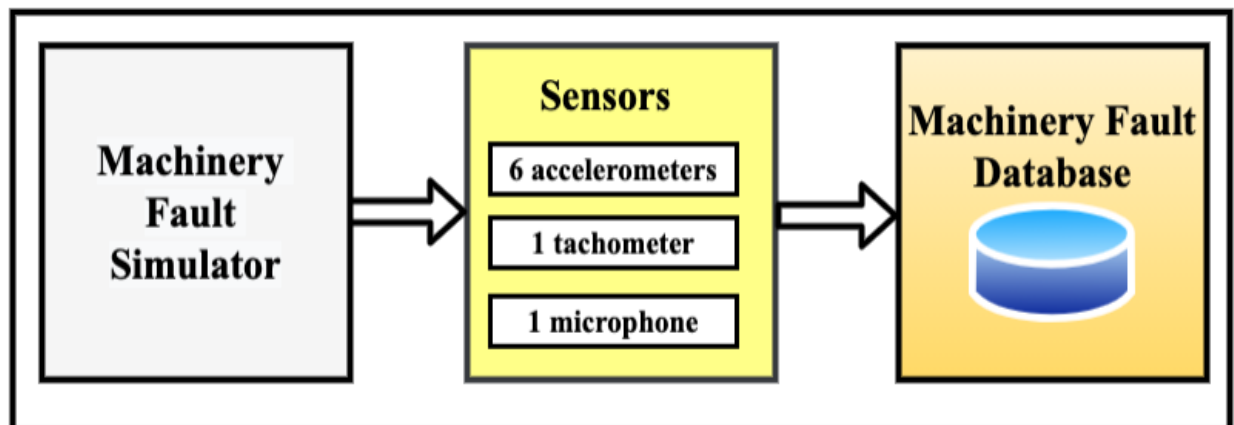


Рисунок 3.3 – Збір даних про обертальні машини

3.2 Попередня обробка

Це важливий крок у будь-якому аналізі. Під час етапу попередньої обробки необроблені дані перевіряються, обрізаються або очищаються, щоб усунути будь-яку зміщення в даних. Дані, що надходять з баз даних,

попередньо обробляються шляхом перевірки якості, де ми перевіряємо відсутні значення (NaN) (рисунок 3.4). Якщо знаходять пропущені значення, їм приписується середнє значення. На наступному кроці виконується стандартне відхилення набору даних, а потім дані позначаються категоріями (бінарними або багатокласовими), характерними для цього набору даних. Нарешті, позначений набір даних об'єднується в один файл містить всю необхідну інформацію. Попередня обробка даних допомагає нам:

- покращення якості даних;
- перевірка відсутніх значень;
- очистити дані;
- нормалізував дані;
- перетворення даних у необхідний формат;
- перед застосуванням будь-якої моделі ML або DNN знайдіть дані, що виділяються або зашумлені.

Стандартне відхилення. Воно показує поширення розподілу даних шляхом розрахунку відстані між кожною точкою даних і середнім. Зазвичай він має дві форми:

- стандартне відхилення населення;
- вибіркоче стандартне відхилення.

Єдина різниця між ними полягає в тому, що стосується сукупності, стандартне відхилення для всієї сукупності розраховується шляхом ділення точок даних на N , а у випадку вибірки стандартне відхилення від кількості вибірок розраховується шляхом ділення числа точок даних у вибірці, тобто $N-1$ [26].

$$S_x = \sqrt{\frac{\sum (X_i - X)^2}{N - 1}}$$

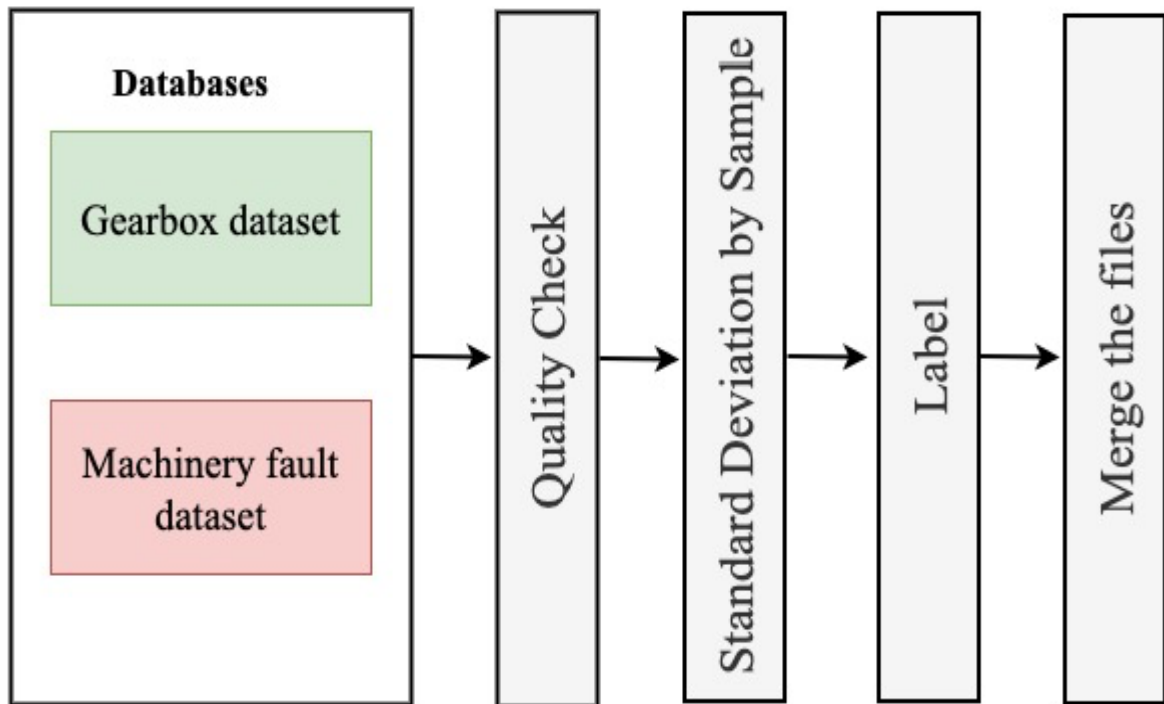


Рисунок 3.4 – Конвеєр попередньої обробки

3.3 Конвеєр машинного навчання

В дослідженні ми маємо справу з проблемою класифікації, і наші дані позначені, тому ми використовували методи навчання з наглядом. Існує багато алгоритмів навчання з наглядом, які використовуються для вирішення проблем класифікації, але ми використовували ці алгоритми:

- дерево рішень;
- випадковий ліс;
- адаптивне підвищення.

Коли ми застосували модель ML до дослідження несправностей коробки передач і механізмів, нашою початковою метою було вивчити та перевірити різні типи алгоритмів ML. Тому ми вибрали лише ті алгоритми, які мінімізували помилки типу 1 і типу 2 якнайменше. Іншою причиною використання дерев рішень і випадкових лісів було те, що їх можна використовувати для задач класифікації та регресії.

3.3.1 Дерево рішень

Дерево рішень має низький зсув і високу дисперсію. Це означає, що модель дуже добре працює з навчальним набором даних, а її продуктивність була розкривною в наборі тестових даних. Іноді це призводить до проблеми переобладнання. Хоча це просто і легко реалізувати.

3.3.2 Випадковий ліс

Його можна використовувати як для задач класифікації, так і для задач регресії. Щоб подолати проблему високої дисперсії в дереві рішень, було б добре використовувати кілька дерев рішень замість одного дерева.

Ось чому випадковий ліс використовується для подолання проблеми переобладнання в дереві рішень.

Також легко налаштувати його гіперпараметр, наприклад кількість дерев у лісі тощо. Дерево в лісі створено на всю його глибину.

3.3.3 Адаптивне підвищення

Це комплексна техніка, яка використовує ітераційний підхід до навчання, щоб перетворити слабкий класифікатор навчання в сильний, вивчаючи помилки попередньої моделі. Він використовував послідовний підхід до навчання замість підходу паралельного навчання у випадковому лісі. Для створення дерева рішень використовуються штампи (дерево з єдиною глибиною).

3.4 Конвеєр глибокої нейронної мережі (DNN).

Метою використання конвеєра DNN є підвищення ефективності моделі для заданих наборів даних. На вході використовується функція активації

Relu, а на вихідному — приховані шари та сигмовидна оболонка, як показано на рисунку 3.5. У кожному шарі використовувалися різні нейрони. Ця комбінація нейронів дала нам бажані результати.

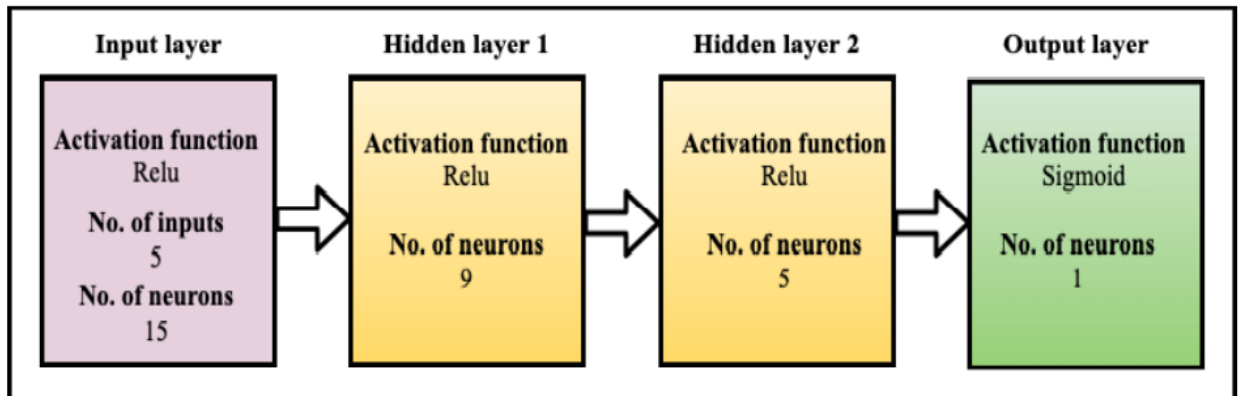


Рисунок 3.5 – Архітектура DNN для коробки передач

Модель DNN обертальних машин містить два прихованих шари, один вхідний і вихідний. Функція активації Relu використовується на вході, а приховані шари та softmax використовуються на вихідному шарі, як показано на рисунку 3.6.

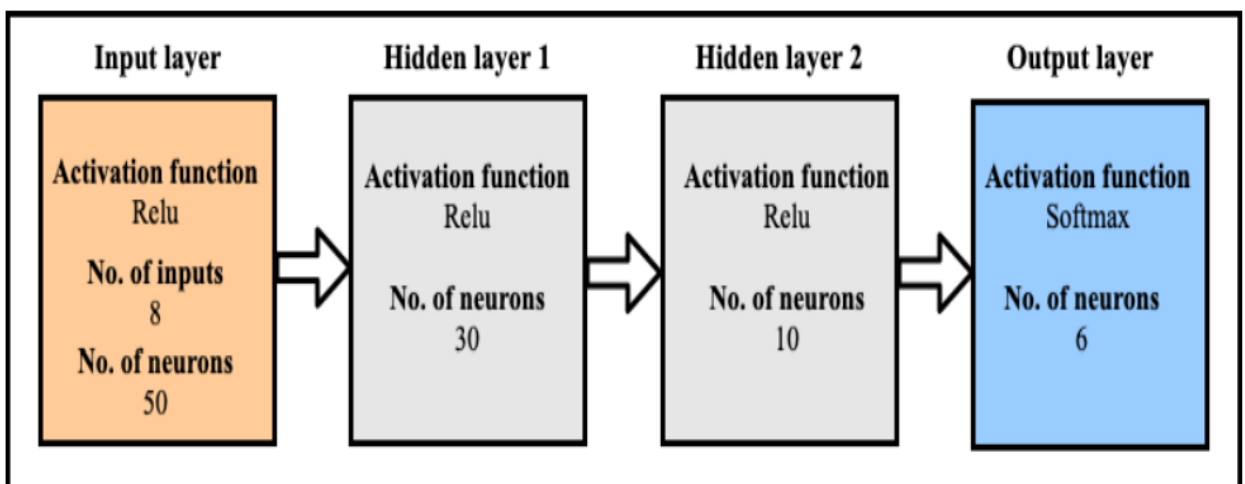


Рисунок 3.6 – Архітектура DNN для обертової машини

Функція активації є ключовим елементом нейронних мереж; він визначає, активувати чи ні нейрон. Усі приховані шари нейронної мережі

поводяться як лінійна функція без функції активації. У цьому дослідженні використовуються такі функції активації:

- ReLU;
- сигмовидна;
- Softmax.

Причина використання функції активації ReLU полягала в тому, щоб уникнути проблеми зникаючого та вибухаючого градієнта під час зворотного поширення. Дослідження коробки передач є проблемою бінарної класифікації, тому ми використовували сигмовидну функцію активації на вихідному шарі та дослідження несправностей ротаційної машини, у нас є проблема мультикласифікації, на вихідному шарі використовувався Softmax.

ReLU це найпопулярніша функція нелінійної активації в MLP і DL. Він перетворює всі негативні значення в нуль, а позитивні значення залишаються незмінними.

$$f(x) = \begin{cases} 0, & \text{if } x \leq 0 \\ 1, & \text{if } x > 0 \end{cases}$$

Сигмовидна – вона перетворює вхідні дані між 0 і 1 і є хорошим вибором для задач бінарної класифікації.

$$f(x) = \frac{1}{1 + e^{-x}}$$

Softmax використовується для задач з кількома класифікаціями. Softmax запевняє, що загальні ймовірності всіх наших результатів дорівнюють одиниці.

$$\sigma(x_j) = \frac{e^{x_j}}{\sum_i e^{x_i}}$$

3.5 Оцінка ефективності

Ефективність моделей оцінюється за допомогою наступних методик:

- матриця плутанини;
- точність;
- частота помилок (ERR);
- оцінка F1;
- істинний позитивний коефіцієнт (TPR);
- коефіцієнт хибних позитивних результатів (FNR);
- оцінка площі під кривою (AUC);
- крива робочих характеристик приймача (ROC);
- середня квадратична помилка.

3.5.1 Confusion matrix

Це простий метод оцінки ефективності моделей класифікації. Матриця описує, скільки класів було передбачено правильно і неправильно. Він використовується для оцінки результату передбаченої моделі з результатом класу, щоб побачити кількість класів, які були правильно класифіковані [27, 28]. Це ключовий термін, який використовується в матриці плутанини, рисунку 3.7.

- True Positive (TP): правильний прогноз класу як «позитивний», якщо фактичний клас також позитивний.
- False Positive (FP): неправильний прогноз класу як «позитивний», коли фактичний клас негативний. Її також називають помилкою I типу
- True Negative (TN): правильний прогноз класу як «негативний», якщо фактичний клас також негативний
- False Negative (FN): неправильний прогноз класу як «негативний», якщо фактичний клас позитивний. Її також називають помилкою II типу.




Рисунок 3.7 – Confusion matrix

3.5.2 Точність

Точність розраховується як кількість правильних прогнозів, поділена на загальну кількість набору даних. Чим вище значення точності, тим краще продуктивність моделі.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

3.5.3 Error Rate (ERR)

Він розраховується як кількість неправильних прогнозів, поділена на загальну кількість набору даних. Значення ERR знаходиться в межах від 0 до 1. «0» означає, що модель не має помилок, а «1» означає гіршу модель.

$$ERR = \frac{FP + FN}{TP + TN + FP + FN}$$

Ми можемо розрахувати коефіцієнт помилок також як:

$$ERR = 1 - Accuracy.$$

3.5.4 True Positive Rate (TPR)

Він використовується для вимірювання здатності моделі виявляти справжні значення. Його також називають відкликанням або чутливістю.

$$TPR = \frac{TP}{FN + TP}.$$

3.5.5 False Positive Rate (FPR)

Негативні випадки були неправильно ідентифіковані як позитивні випадки в FPR. Хороша модель має дуже низький FPR.

$$FPR = \frac{FP}{TN + FP}$$

3.5.6 Precision

Це відношення прогнозного позитиву до справжнього позитивного.

$$Precision = \frac{TP}{FP + TP}$$

3.5.7 Показник AUC

Чим вище значення AUC, тим краще модель має роздільність.

Мінімальне значення показника AUC дорівнює 0, а максимальне – 1. Ідеальна умова – це коли TP і TN відокремлені один від одного, а показник AUC дорівнює 1, як показано на рисунку 3.7.




Рисунок 3.7 – Показник AUC

3.5.8 Крива ROC

Крива ROC була побудована за допомогою FPR і TPR. Чим приглушена крива, тим краще модель.

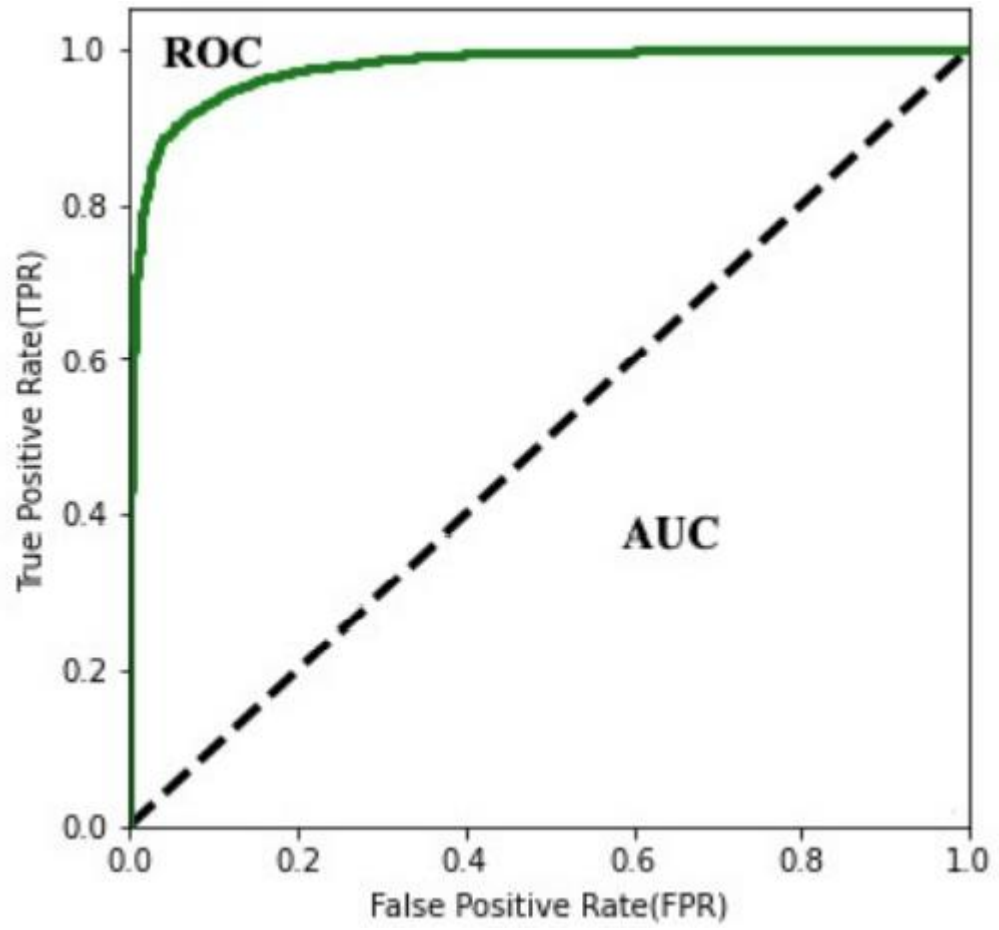


Рисунок 3.8 – Крива ROC

4 РЕЗУЛЬТАТИ МОДЕЛЮВАННЯ

Дані навчання та тестування необхідні для створення та перевірки результатів моделі машинного навчання (ML) та глибокої нейронної мережі (DNN). Тут ми проаналізували два набори даних, тобто дослідження несправностей коробки передач і механізмів, які далі розділені на навчальні та тестові набори даних для побудови та оцінки продуктивності моделей ML і DNN. Моделі вивчаються з навчального набору, а ефективність оцінюється на основі тестових або невидимих даних. В обох дослідженнях сімдесят відсотків даних використовуються для навчання, а тридцять відсотків використовуються для тестування моделей, як показано на рисунку 4.1.




Рисунок 4.1 – Співвідношення навчальних і тестових даних для навчання та оцінки ефективності моделі ML і DNN

4.1 Прогноз несправності коробки передач

Набір даних прогнозування несправностей коробки передач ($n=4000000$) складається лише з двох класів: нормальні та зламані зуби. Це

проблема бінарної класифікації. Навчальні дані містять 2800000 записів (70%), а дані тесту містять 120000 записів (30%). Записи розподіляються між класами порівну. Це означає, що ми маємо проблему збалансованої класифікації, рисунок 4.2.

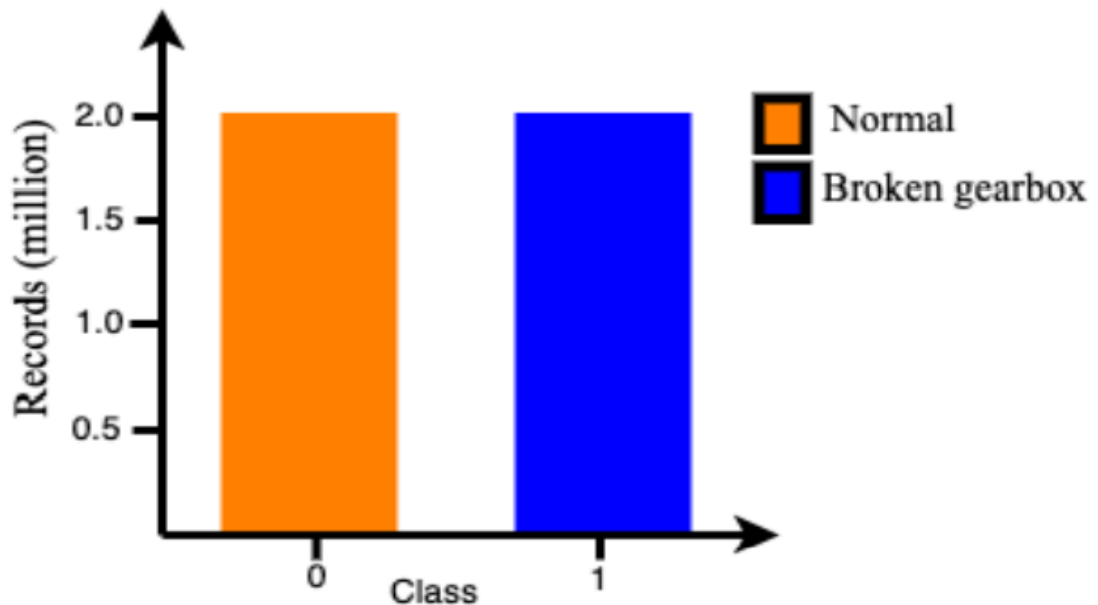


Рисунок 4.2 – Розподіл даних між нормальними та зламаними класами коробок передач

Інформація з описових ознак була отримана за допомогою датчиків. Всі показання датчиків були числовими. Це проблема бінарної класифікації, де 0 означає нормальний клас, а 1 означає клас зламаних зубів коробки передач. У нас є 5 описових і одна цільова ознаки, показані в таблиці 4.1.

Таблиця 4.1 – Описові та цільові ознаки

Описові особливості					Цільова ознака
Показання датчика вібрації 1 (S1)	Показання датчика вібрації 2 (S2)	Показання датчика вібрації 3 (S3)	Показання датчика вібрації 4 (S4)	Зміна навантаження (0 – 90) відсотків	Бінарна класифікація Нормальний: 0 Зламано: 1

4.1.1 Оцінка ефективності на вихідних даних

У таблиці 4.2 і на рисунку 4.3 описані результати моделей ML і DLL на вихідних даних набору даних коробки передач. Спочатку ми оцінили та порівняли продуктивність різних моделей машинного навчання ML (Рисунок 4.3 (a-c)) та моделі DL (Рисунок 4.3d), використовуючи вихідні дані коробки передач, тобто без застосування будь-яких методів нормалізації. Це означає, що моделі вперше були розгорнуті безпосередньо на необроблених даних.

Наші результати показали, що помилка типу 1 була найвищою у випадковому лісі (РЧ) (Рисунок 4.3c), а тип II — найнижчим. Модель DNN показала, що помилка типу 1 була найнижчою, тоді як помилка типу II була найвищою (Рисунок 4.3d).

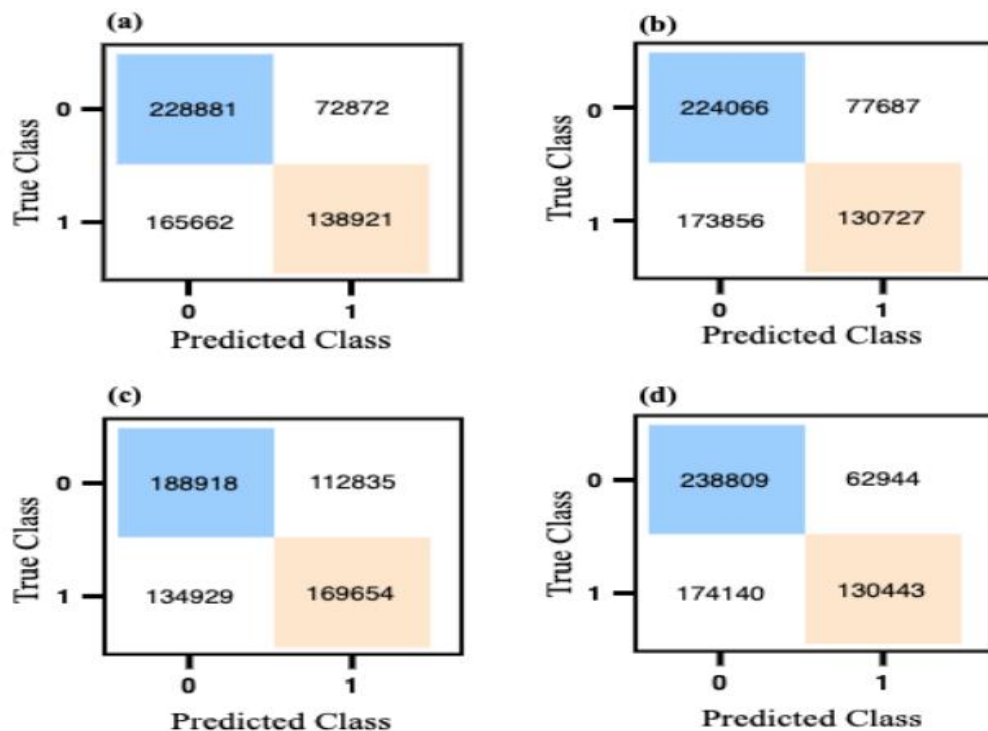


Рисунок 4.3 – Оцінка продуктивності моделей ML і DLL на необроблених даних

У кожній матриці похибок передбачений клас (вісь x) і справжній клас

(вісь у), що представляє звичайний клас з «0» і зламаний клас зубця коробки передач «1». Матриця похибок (а) дерева рішень (b) AdaBoost (c) випадкового лісу (d) глибокої нейронної мережі.

Загальна продуктивність DNN і дерева рішень краща на основі найвищого коефіцієнта точності/швидкості точності та найнижчої частоти помилок, ніж випадковий ліс і AdaBoost (Таблиця 4.2). Тим не менш, F1-оцінка була найкращою для моделі RF.

Таблиця 4.2 – Зведена статистика продуктивності моделей ML і DLL на необроблених даних

Модель	Відсотки %	Точність	Відкликання	F1- оцінка	Частота помилок (%)	MSE
Дерево рішень	60.06	0.6559	0.456	0.5380	39.94	0.229
Випадковий ліс	59.13	0.6005	0.557	0.5779	40.87	0.241
AdaBoost	58.51	0.6272	0.421	0.5096	41.49	0.416
DNN	60.57	0.6574	0.444	0.5336	39.43	0.386

Далі ми порівняли графічний опис продуктивності класифікатора ML і DNN на необроблених даних за допомогою ROC. Наші результати показують, що площа під кривою ROC моделі DNN вища, ніж у моделі ML (RF, DT і AdaBoost) (Рисунок 4.4). На основі кривої ROC і показника AUC продуктивність DNN і Random Forest набагато краща, ніж дерево рішень і AdaBoost (Рисунок 4.4 a-d).

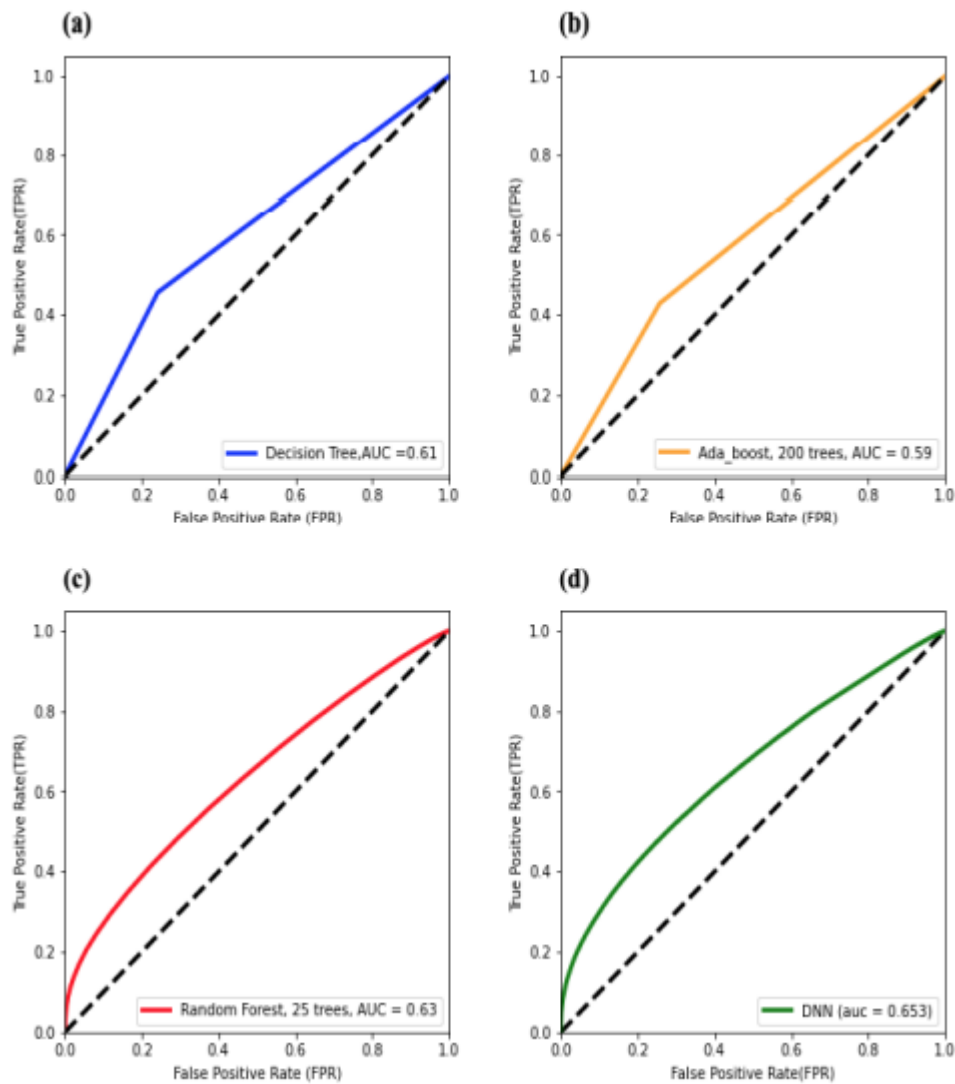


Рисунок 4.4 – Крива ROC і відповідний показник AUC моделі ML і DNN на необроблених даних (а) дерево рішень (б) AdaBoost (с) випадковий ліс (д) DNN

4.1.2 Оцінка продуктивності нормалізованих даних

Стандартне відхилення з розміром вибірки ($N=10,25,50,100$ і 500), використане для нормалізації наборів даних про несправності коробки передач і механізмів. Мотивація використання цих значень вибірки полягала в тому, щоб зменшити частоту помилок і підвищити продуктивність моделі ML і DNN.

Нормовані дані з розміром вибірки $N=10$. Далі ми оцінили продуктивність різних моделей, використовуючи нормалізовані дані, взявши

розмір вибірки $N=10$. Тут замість того, щоб безпосередньо брати вихідні дані з показань датчика, ми спочатку беремо стандартні відхилення для кожного з розмірів вибірки « $N=10$ », а потім моделі були розгорнуті на цьому нормалізованому наборі даних.

На основі цього підходу наші результати показали, що загальна продуктивність усіх моделей, як ML, так і DNN, була покращена приблизно на 10% порівняно з вихідними даними (Рисунок 4.5 (a-d), таблиця 4.3). Рівень точності моделі DNN було покращено з 60% у вихідних даних до 73% у нормалізованих даних (Таблиця 4.3).




Рисунок 4.5 – Оцінка продуктивності моделей ML і DNN з $N=10$

У кожній матриці похибок передбачений клас (вісь x) і справжній клас

(вісь у), що представляє звичайний клас з «0» і зламаний клас зубця коробки передач «1». Матриця похибок (а) дерева рішень (b) AdaBoost (c) випадкового лісу (d) DNN.

Таблиця 4.3 – Зведена статистика продуктивності моделей ML і DLL на нормалізованих даних з N=10

Модель	Відсотки %	Точність	Відкликання	F1- оцінка	Частота помилки (%)	MSE
Дерево рішень	72.23	0.7215	0.7142	0.7178	27.76	0.182
Випадковий ліс	71.88	0.7108	0.7272	0.7189	28.12	0.182
AdaBoost	72.40	0.7056	0.7580	0.7309	27.60	0.276
DNN	73.44	0.7215	0.7553	0.7380	26.56	0.265

ROC і AUC були значно покращені для всіх моделей з використанням нормалізованих даних з розміром вибірки N=10 порівняно з вихідними даними (рис. 4.6(a-d)). Цікаво, що ми помітили, що AUC для моделі DNN покращився до 0,82 у нормалізованих даних порівняно з вихідними, які становили 0,65.

Нормовані дані з розміром вибірки N=25. Ефективність моделей ML і DNN оцінювали шляхом взяття нормалізованих даних з розміром вибірки N=25. Тип I і тип II були значно зменшені (рисунок 4.7(a-d)) у порівнянні з вихідними даними та нормалізували N=10. Продуктивність моделі DNN і RF набагато краща в порівнянні з необробленими даними і N=10 з точністю, що наближається до 81% у моделі DNN.

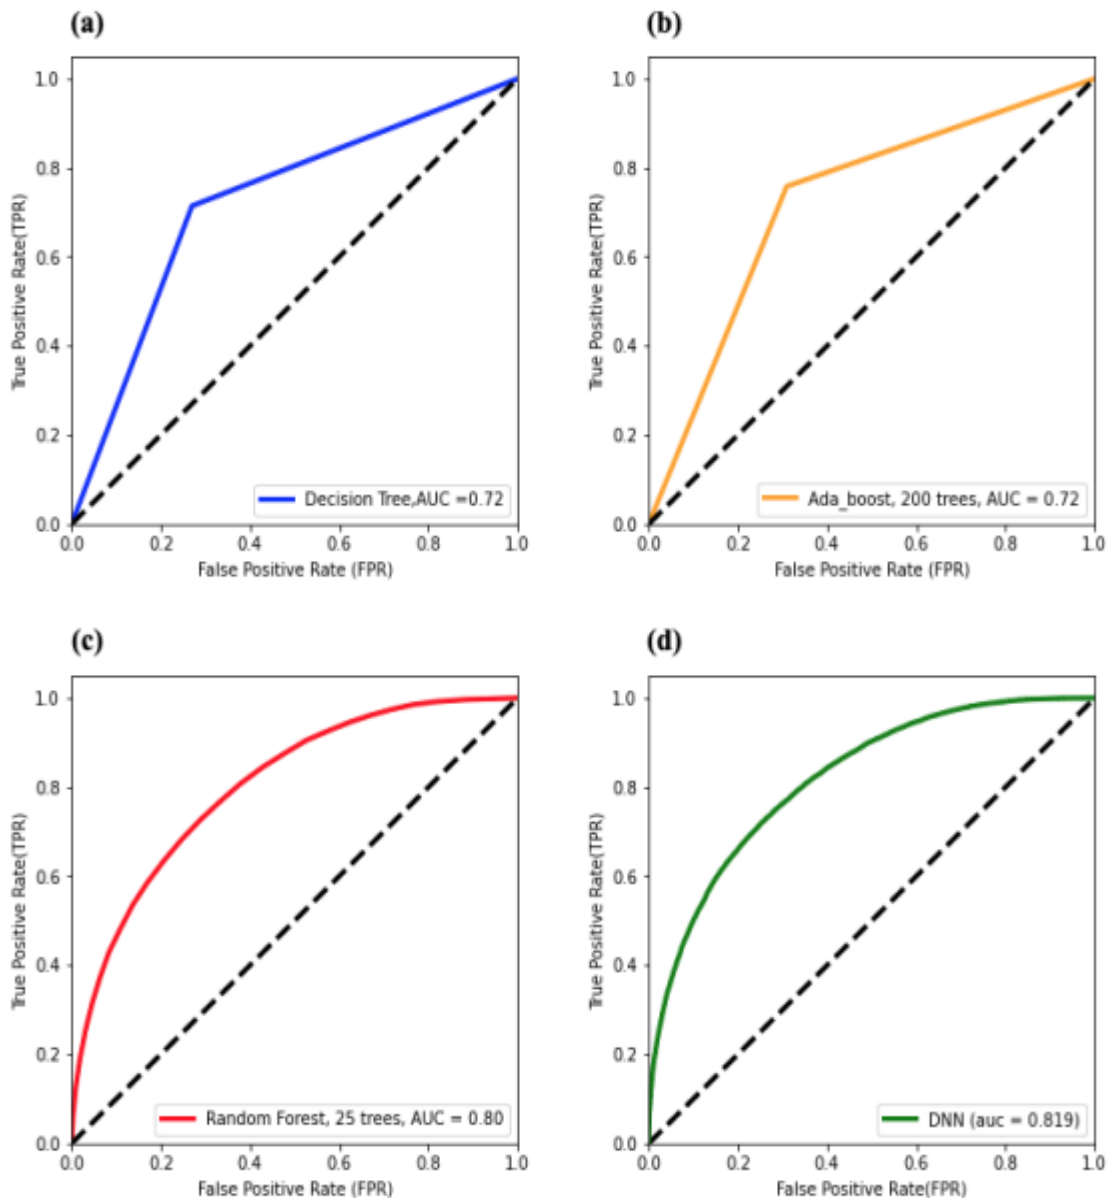


Рисунок 4.6 – Крива ROC і відповідний показник AUC моделі ML і DNN з N=10 (a) дерево рішень (b) AdaBoost (c) випадковий ліс (d) DNN

У кожній матриці похибок передбачений клас (вісь x) і справжній клас (вісь y), що представляє звичайний клас з «0» і зламаний клас зубця коробки передач «1». Матриця похибок (a) дерева рішень (b) AdaBoost (c) випадкового лісу (d) DNN.

Таблиця 4.4 – Зведена статистика продуктивності моделей ML і DLL на нормалізованих даних з N=25

Модель	Відсотки %	Точність	Відкликання	F1- оцінка	Частота помилوک (%)	MSE
Дерево рішень	79.36	0.7897	0.7955	0.7926	20.64	0.144
Випадковий ліс	80.35	0.8021	0.8017	0.7189	19.65	0.134
AdaBoost	79.98	0.7888	0.8142	0.8013	20.02	0.200
DNN	80.55	0.7936	0.8212	0.8072	19.45	0.192




Рисунок 4.7 – Оцінка продуктивності моделей ML і DLL з N=25

AUC моделі RF і DNN додатково покращився до 0,89 порівняно з попереднім розміром вибірки ($N=10$). Це означає, що продуктивність моделей RF та DNN була дуже схожою з використанням цього розміру вибірки $N=25$ (Рисунок 4.8).

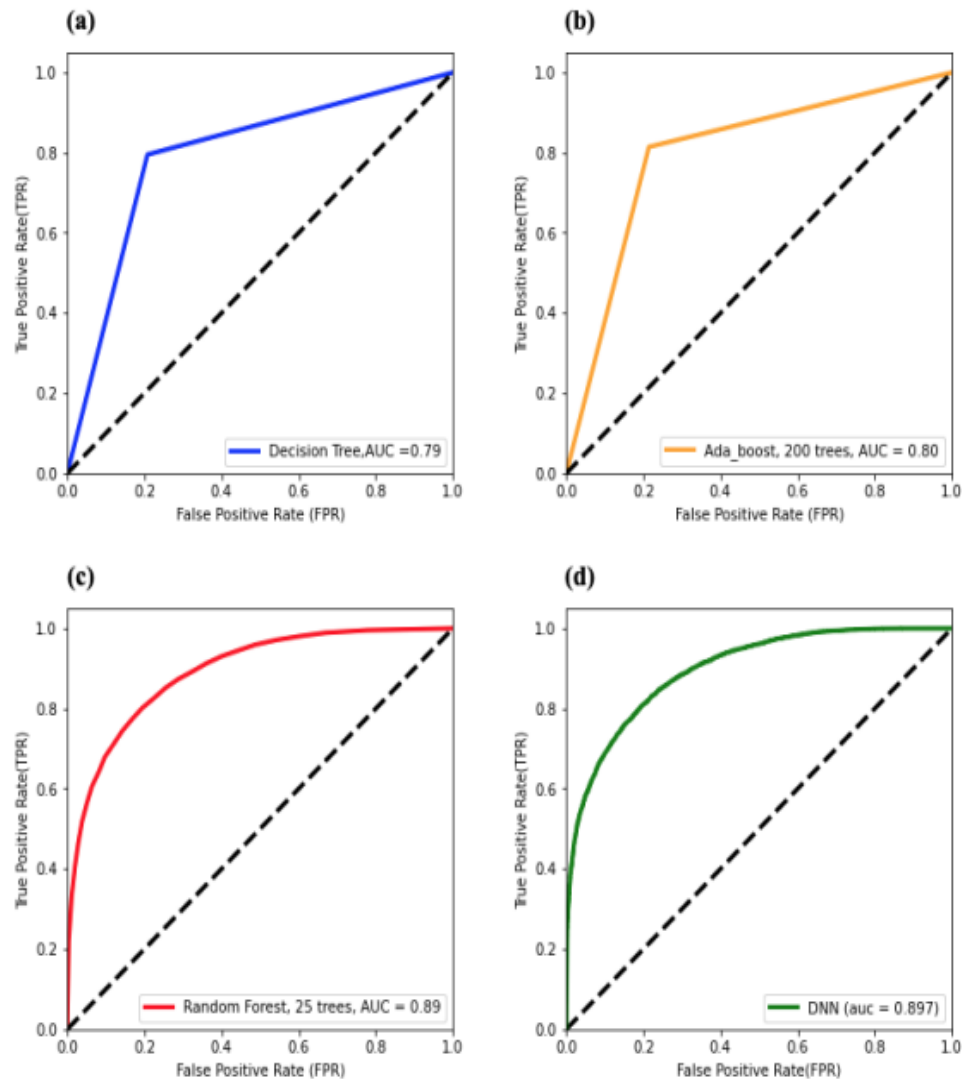


Рисунок 4.8 – Крива ROC і відповідний показник AUC моделі ML і DNN з $N=25$ (a) дерево рішень (b) AdaBoost (c) випадковий ліс (d) DNN

Нормовані дані з розміром вибірки $N=50$. Ефективність моделей ML і DNN була додатково оцінена шляхом взяття нормалізованих даних з розміром вибірки $N=50$. На рисунку 4.8 і в таблиці 4.5 описані результати моделей ML і DLL в наборі даних коробки передач. Загальна продуктивність DNN і Random Forest для цього набагато краща, ніж дерево рішень і

AdaBoost, які розглядають матрицю плутанини. Показник точності моделі DNN і RF становив прибіл. 86% з найвищою точністю та F1-оцінка та найнижчим рівнем помилок близько 13 % (Таблиця 4.5).

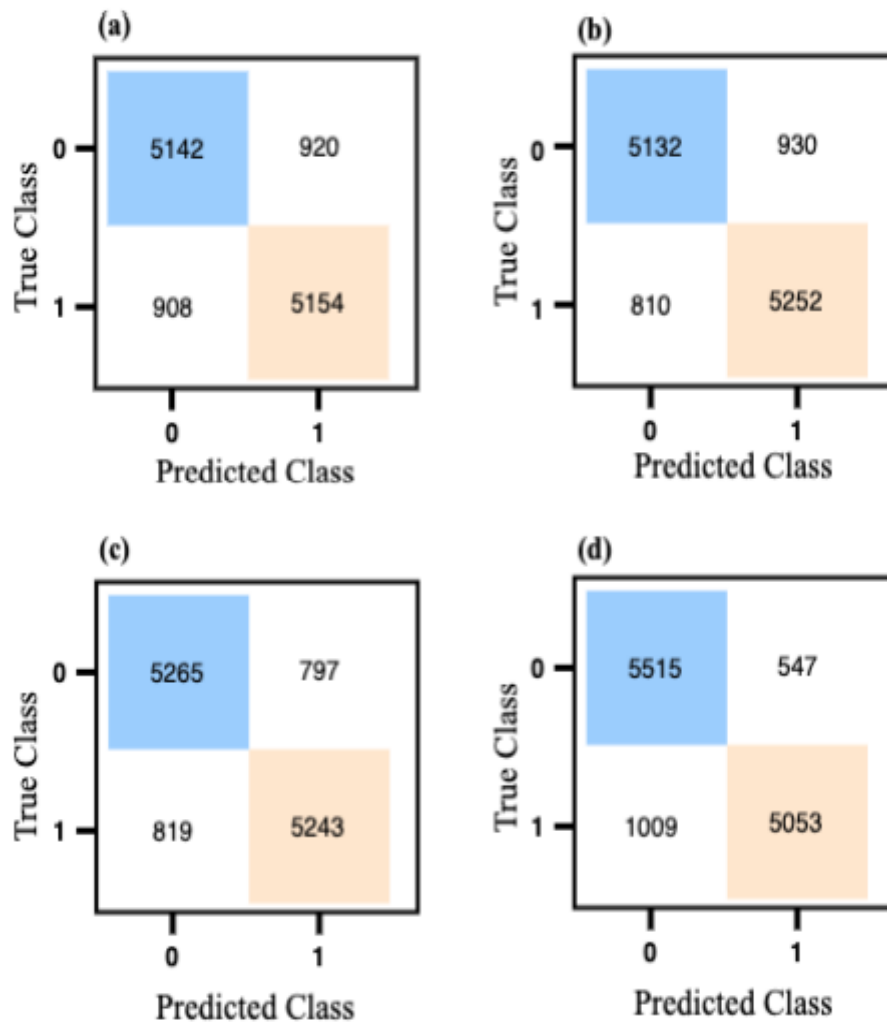


Рисунок 4.9 – Оцінка продуктивності моделей ML і DLL з N=50

У кожній матриці похибок передбачений клас (вісь x) і справжній клас (вісь y), що представляє звичайний клас з «0» і зламаний клас зубця коробки передач «1». Матриця похибок (a) дерева рішень (b) AdaBoost (c) випадкового лісу (d) DNN.

Таблиця 4.5 – Зведена статистика продуктивності моделей ML і DLL на нормалізованих даних з N=50

Модель	Відсотки %	Точність	Відкликання	F1- оцінка	Частота помилوک (%)	MSE
Дерево рішень	84.93	0.8482	0.8508	0.8495	15.07	0.112
Випадковий ліс	86.67	0.8680	0.8648	0.8664	13.33	0.093
AdaBoost	85.64	0.8495	0.8663	0.8578	14.35	0.144
DNN	86.54	0.8908	0.8485	0.8692	13.46	0.131

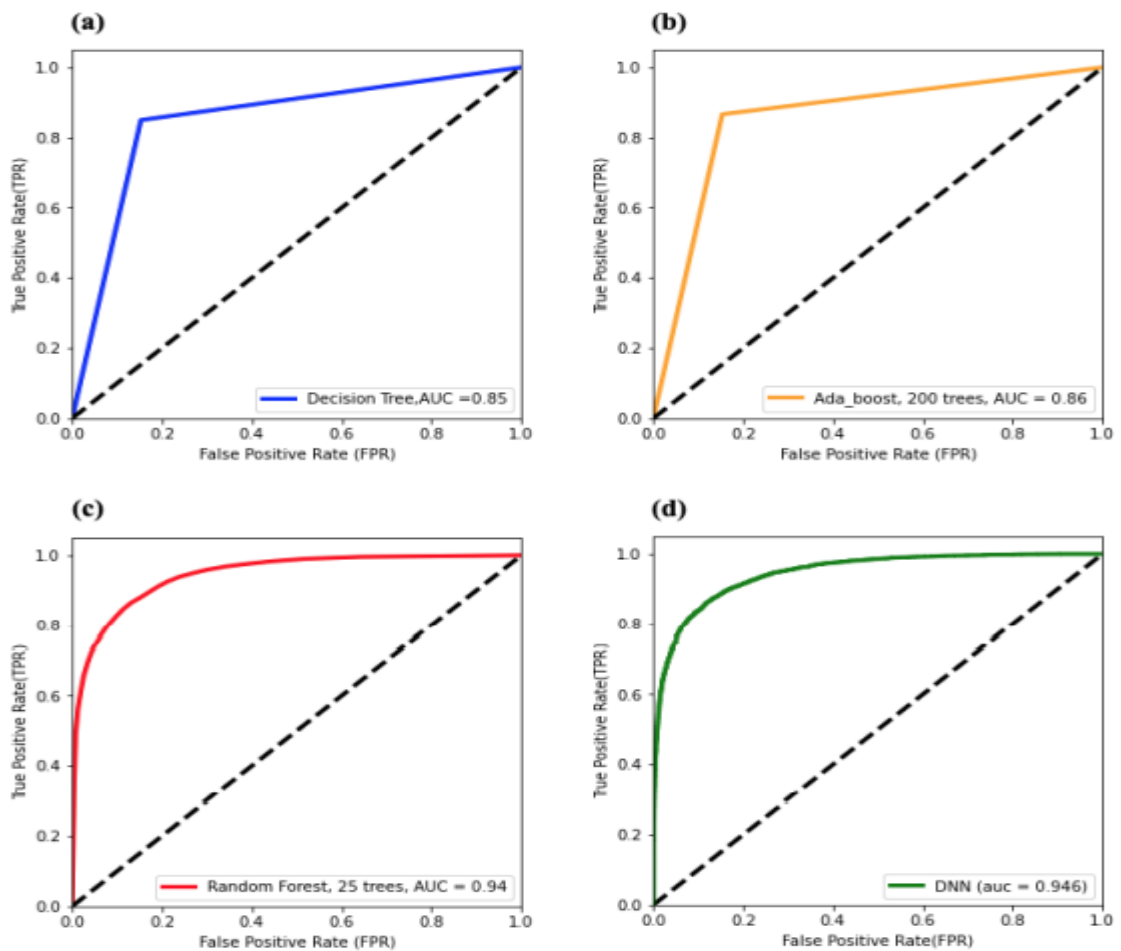


Рисунок 4.10 – Крива ROC і відповідний показник AUC моделі ML і DNN з N=50 (a) дерево рішень (b) AdaBoost (c) випадковий ліс (d) DNN

AUC моделей RF і DNN додатково покращився до 0,94 порівняно з попереднім значенням, який становив 0,89. Як і раніше, продуктивність моделей RF і DNN була дуже схожою з використанням розміру вибірки $N=50$ (Рисунок 4.10).

Нормовані дані з розміром вибірки $N=100$. Продуктивність моделей ML і DNN була додатково оцінена шляхом взяття нормалізованих даних з розміром вибірки $N=100$. Загальна продуктивність усіх моделей помітно покращилася, причому моделі DNN і RF показали найкращі результати, як можна побачити на матрицях плутанини (Рисунок 4.11). Показник точності моделі DNN і RF досяг прибіл. 93% з найвищою точністю та F1-балами та найнижчим рівнем помилок близько 7% (Таблиця 4.6).

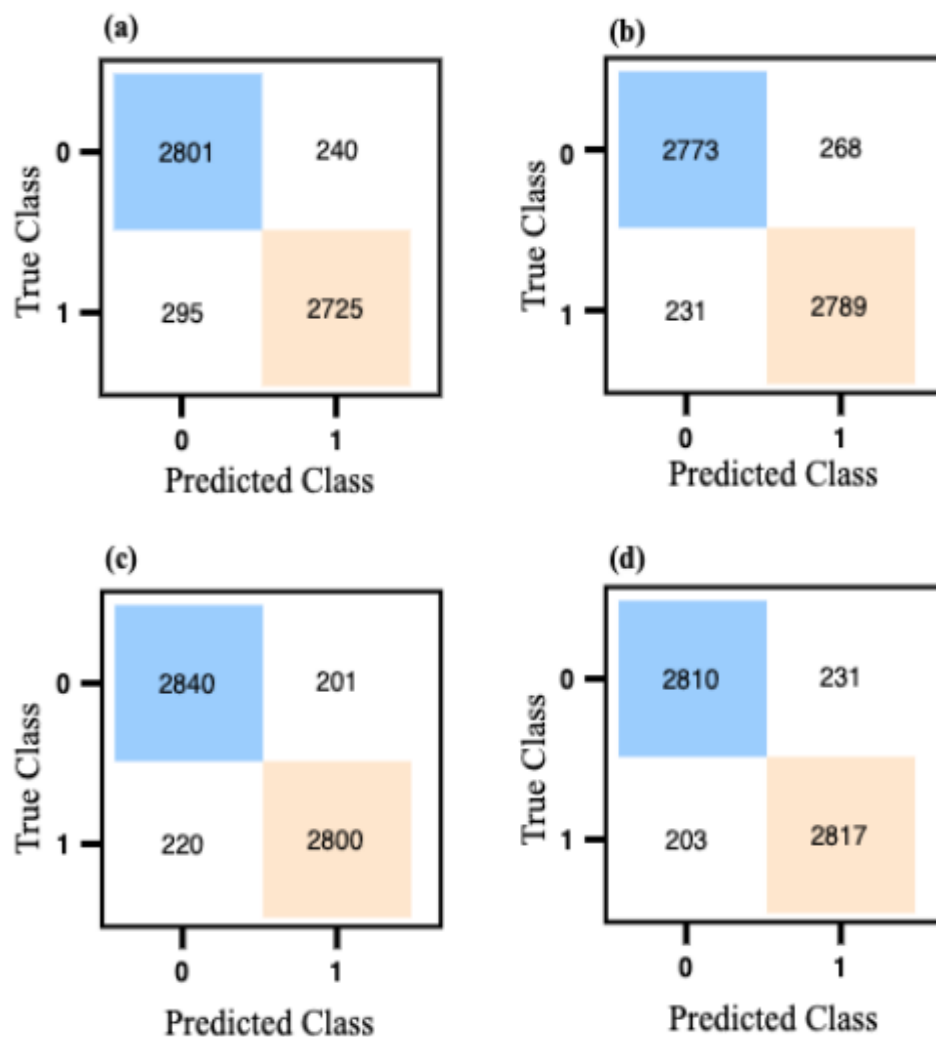


Рисунок 4.11 – Оцінка продуктивності моделей ML і DLL з $N=100$

У кожній матриці плутанини передбачений клас (вісь x) і справжній клас (вісь y), що представляє звичайний клас з «0» і зламаний клас зубця коробки передач «1». Матриця плутанини (a) дерева рішень (b) AdaBoost (c) випадкового лісу (d) DNN.

Таблиця 4.6 – Зведена статистика продуктивності моделей ML і DLL на нормалізованих даних з $N=100$

Модель	Відсотки %	Точність	Відкликання	F1- оцінка	Частота помилки (%)	MSE
Дерево рішень	91.11	0.9181	0.9023	0.910	8.89	0.074
Випадковий ліс	93.05	0.9331	0.9271	0.930	6.95	0.051
AdaBoost	91.76	0.9123	0.9235	0.917	8.24	0.082
DNN	93.21	0.9424	0.9168	0.925	6.79	0.072

ROC додатково покращився для всіх моделей у цьому випадку, а AUC для моделей RF і DNN становив приблизно 0,98. Як і раніше, продуктивність моделей RF та DNN була дуже схожою з використанням розміру вибірки $N=100$ (Рисунок 4.12).

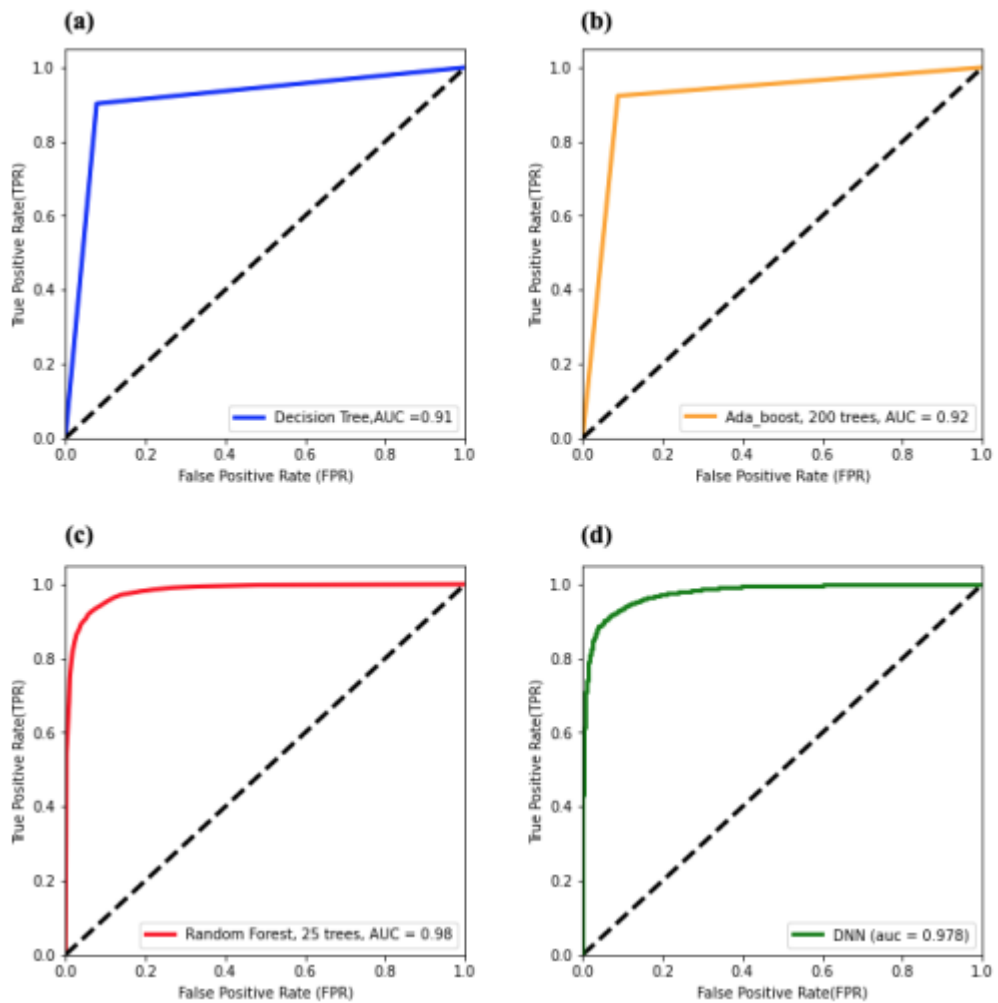


Рисунок 4.12 – Крива ROC і відповідний показник AUC моделі ML і DNN з $N=100$ (a) дерево рішень (b) AdaBoost (c) випадковий ліс (d) DNN

4.2 Прогнозування несправностей обладнання

Другим набором даних, який ми проаналізували тут, був набір даних прогнозування несправностей механізмів (MFP), який є проблемою кількох класифікацій. У цьому дослідженні ми маємо шість класів, таких як нормальний, дисбаланс, горизонтальне зміщення, вертикальне зміщення, підшипники та несправності підшипника. Дані навчання містять 6828550 записів (70%), а дані тестів містять 292650 записів (30%). Розподіл записів між кількома класами в наборі даних MFP показано на рисунку 4.13.




Рисунок 4.13 – Кількість записів у кожному з шести класів MFP

Записи описових ознак були отримані за допомогою датчиків. Всі показання датчиків є числовими. Це проблема з кількома класифікаціями, де «0» представляє нормальний клас, «1» представляє клас несправності дисбалансу, «2» представляє горизонтальне зміщення, «3» представляє вертикальне зміщення, «4» представляє несправність підшипника, а «5» являє собою класи несправностей підшипників. Маємо 8 описових і одну цільову ознаки (таблиця 4.7).

S1 представляє показання з тахометра, S2-S4 представляє показання з акселерометрів підшипника, S5-S7 представляють показання з акселерометрів верхнього підшипника, а S8 - з мікрофона.

Результати моделей ML і DNN були оцінені та порівняні один з одним. Ефективність моделей оцінюється матрицею плутанини, точністю, F1 оцінкою, показником AUC та ROC крива. Похибка була розрахована за допомогою MSE.

Таблиця 4.7: Описові та цільові характеристики набору даних ротаційного обладнання

Описові особливості								Цільові особливості
S1	S2	S3	S4	S5	S6	S7	S8	Мульти класифікація Нормальний: 0 Дисбаланс: 1 Горизонтальне зміщення: 2 Вертикальне зміщення: 3 Несправність підшипника: 4 Несправність підшипника: 5

4.2.1 Оцінка ефективності моделі ML у наборі даних MFP

У цьому розділі описується продуктивність моделі ML для заданих наборів даних. Алгоритм, який ми використовували в ML, — це випадковий ліс. Матриця плутанини показана на (рисунок 4.14). підведення підсумків продуктивності моделі. Правильно класифіковані класи з використанням цієї моделі були показані по діагоналі в матриці плутанини (рисунок 4.14). Тоді як інші елементи (недіагональні) матриці плутанини вказують на неправильно класифіковані записи. Наші результати показали, що 153 випадки нормального класу були неправильно класифіковані в інші класи, наприклад, 11 записів були класифіковані як дисбаланс класу, 90 записів у горизонтальному зміщенні, 22 записи у вертикальному зміщенні, 13 записів у несправності підшипника та 17 записів у звисанні. несправність (рисунок

4.14). Матриця плутанини допомагає аналізувати різні типи помилок у класифікації.




Рисунок 4.14 – Оцінка продуктивності RF MFP за допомогою матриці плутанини

У матриці плутанини передбачений клас (вісь x) і справжній клас (вісь y), що представляють класи: нормальний з '0', дисбаланс з '1', горизонтальне зміщення з '2', вертикальне зміщення з '3', несправність підшипника з «4» та несправністю підшипника «5».

Рисунок 4.15 ілюструє прогнозу продуктивність RF-моделей щодо проблем з кількома класифікаціями за допомогою кривої ROC з побудовою графіка хибнопозитивної частоти проти справжньої позитивної ставки. Площа під кривою ROC для нормального класу становила 0,98 відсотка, що означає, що модель ML розрізняє нормальний клас з іншими класами з точністю 98 відсотків.




Рисунок 4.15 – Крива ROC і відповідний показник AUC моделі RF в наборі даних MFP

4.2.2 Оцінка продуктивності моделі DNN у наборі даних MFP

У цьому розділі описується продуктивність моделі DNN з використанням набору даних MFP. Модель правильно класифікувала мультиклас, використовуючи цей підхід, як показано діагональними числами на рисунку 4.16. Наші результати показують, що кількість правильно класифікованих записів за моделлю DNN дещо зменшилася порівняно з моделлю RF, як показано на рисунку 4.16.




Рисунок 4.16 – Оцінка продуктивності моделі DNN у наборі даних MFP

У матриці плутанини передбачений клас (вісь x) і справжній клас (вісь y), що представляють кілька класів: нормальний з '0', дисбаланс з '1', горизонтальне зміщення з '2', вертикальне зміщення з '3', підшипник несправність «4» і несправність підшипника «5».




Рисунок 4.17 – Крива ROC та відповідний показник AUC моделі DNN у наборі даних MFP

Показник AUC для несправності підшипника 0,99 залишився таким же, як і в моделі RF. У той час як для всіх інших класів AUC дещо знизився порівняно з моделлю RF, показуючи, що модель RF працювала краще, ніж модель DNN для набору даних MFP (Рисунок 4.17).

У моделі DNN ми також порівняли прогнозований вихід із фактичним. Тут була обчислена похибка між фактичним і прогнозованим результатом. Під час зворотного поширення моделі DNN ваги оновлюються з кожною ітерацією або епохами. Похибка зменшується, а точність збільшується з кожною ітерацією, як показано на рисунку 4.18.




Рисунок 4.18 – Епоха проти точності з використанням моделі DNN у наборі даних MFP. Набір навчальних даних «Train» показаний синім кольором, а дані перевірки – оранжевим як «Val»

Втрата тесту була зменшена, а точність підвищилася при збільшенні кількості епох (рис. 4.19).




Рисунок 4.19: Епоха проти втрат за допомогою моделі DNN у наборі даних MFP. Набір навчальних даних «Train» показаний синім кольором, а дані перевірки – оранжевим як «Val»

ВИСНОВКИ

У цьому дослідженні продуктивність машинного навчання (ML) і глибокої нейронної мережі (DNN) порівнювалися та оцінювалися на наборах даних про несправності коробки передач і механізмів. У ML ми використовували різні алгоритми, такі як дерево рішень, випадковий ліс (RF) і AdaBoost для побудови моделі. Загалом, продуктивність випадкового лісу дуже хороша в порівнянні з деревом рішень і AdaBoost.

Модель DNN також добре працює на обох наборах даних, але найбільшими проблемами, які виникли при побудові цих моделей, був вибір гіперпараметрів, кількох прихованих шарів, функцій активації та функцій втрат для отримання бажаних результатів.

Перевірено ефективність класифікації ML та DNN. Наші результати показують, що моделі RF і DNN мають кращу здатність прогнозування несправностей для визначення різних типів несправностей механізмів і коробок передач у порівнянні з деревом рішень і AdaBoost.

У майбутньому нам також потрібно буде досліджувати статистичні та рекурентні нейромережі. Особливо нам потрібно вивчити моделі авторегресійної інтегрованої ковзної середньої (ARIMA) і довгострокової пам'яті (LSTM). Гібридний підхід, який являє собою комбінацію статистичних моделей з моделями ML, DL, LSTM, RNN, буде дуже корисним для прогнозування відсутніх даних із датчиків.

Однією з проблем прогнозування несправностей у промисловому обладнанні є те, що для побудови моделей ML вам потрібно багато історичних даних. Промислові машини експлуатуються в різних умовах, і отримати дані від кожного компонента машини також складно, вам потрібен ресурс для запису даних з обладнання та зберігання їх у хмарі або в певному місці.

Найбільша проблема впровадження цих підходів у галузях полягає в

тому, що пристрої на основі IoT доступні лише для великих компаній і виробничих підрозділів для моніторингу свого обладнання.

Нам потрібно дослідити, як ці підходи прогнозування, засновані на ML, також можуть бути перенесені на невеликі компанії. Щоб вони могли отримати вигоду від штучного інтелекту.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. “Machine Learning Techniques for Smart Manufacturing: Applications and Challenges in Industry 4.0,” Intellectyx, Jul. 09, 2019. <https://www.intellectyx.com/blog/machine-learning-for-smartmanufacturing>.
2. “What are the types of industrial maintenance and how can IIoT help?,” Netilion Blog, Sep. 02, 2019. <https://netilion.endress.com/blog/types-industrial-maintenance-iiot/>.
3. F. Ribeiro, M. Marins, S. Netto, and E. Silva, “Rotating machinery fault diagnosis using similarity based models,” presented at the XXXV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais, 2017. doi: 10.14209/sbrt.2017.133.
4. A. Alzghoul, A. Jarndal, I. Alsayouf, A. A. Bingamil, M. A. Ali, and S. AlBaiti, “On the Usefulness of Pre-processing Methods in Rotating Machines Faults Classification using Artificial Neural Network,” Journal of Applied and Computational Mechanics, Jan. 2021, doi: 10.22055/jacm.2020.35354.2639.
5. “MAFAULDA :: Machinery Fault Database [Online].” http://www02.smt.ufrj.br/~offshore/mfs/page_01.html
6. “Classification of faults in gearboxes — pre-processing algorithms and neural networks | SpringerLink.” <https://link.springer.com/article/10.1007/BF01413861>.
7. “Gearbox fault diagnosis using data fusion based on self-organizing map neural network - Zhang Qiang, Gu Jieying, Liu Junming, Tian Ying, Zhang Shilei, 2020.” <https://journals.sagepub.com/doi/full/10.1177/1550147720923476>.
8. “5 Types Of Industrial Maintenance Programs,” Quality Millwright, Jun. 19, 2019. <https://www.qmillwright.com/5-types-of-industrial-maintenance-programs/>.
9. M. Bentley, “Machine Learning for Predictive Maintenance - Top Opportunities for 2020-2021 | The Ritz Herald,” <https://ritzherald.com/>.

<https://ritzherald.com/machine-learning-for-predictive-maintenance/> (accessed May. 17, 2021).

10. “Disadvantages of doing Preventive Maintenance,” Bayt.com. <https://specialties.bayt.com/en/specialties/q/95601/disadvantages-of-doing-preventive-maintenance/>.

11. [12] “Predictive Maintenance – What you need to know | IoT Now News & Reports,” IoT Now News - How to run an IoT enabled business, May 02, 2018. <https://www.iot-now.com/2018/05/02/81526-predictive-maintenance-need-know/>.

12. “What Are Benefits and Drawbacks of Preventive Maintenance?” <https://www.onupkeep.com/answers/preventive-maintenance/benefits-of-preventive-maintenance>.

13. “What is Predictive Maintenance? [Benefits & Examples],” Fiix. <https://www.fiixsoftware.com/maintenance-strategies/predictive-maintenance/> (accessed Apr. 7, 2021).

14. Y. Ageeva, “Predictive Maintenance Scheduling with AI and Decision Optimization,” Medium, May 15, 2020.

15. Zhong, Y. I2oT: Advanced Direction of the Internet of Things. ZTECOMMUNICATIONS, 2015, 3, P. 102.

16. Liashenko O., Barkovska O., Al-Atroshi C., Datsok O., Liashenko S. Model of the work of the neurocontroller to control fuzzy data from the sensors of the climate control subsystem “smart house”. International Journal of Advanced Trends in Computer Science and Engineering. Volume 8, Issue 1, 2019, pp. 70-74

17. Li, J., Huang, Z., & Wang, X. (2011, May). Notice of Retraction Countermeasure research about developing Internet of Things economy: A case of Hangzhou city. 2011 International Conference on E-Business and E-Government (ICEE).

18. Al-Fuqaha, A., Guizani, M., Mohammadi, M., Aledhari, M., & Ayyash, M. Internet of things: A survey on enabling technologies, protocols, and applications. Communications Surveys & Tutorials, IEEE, 2015, 17(4), 2347-2376.

19.EVANS, D. The internet of things. How the Next Evolution of the Internet is Changing Everything, Whitepaper, Cisco Internet Business Solutions Group (IBSG).

http://www.cisco.com/c/dam/en_us/about/ac79/docs/innov/IoT_IBSG_0411FINA_L.pdf

20.Montano, C., Lundmark, M., & Mähr, W. Control vs convenience: critical factors of smart homes. In 2nd Scandinavian Student Interaction Design Research Conference. 2006. pp. 296.

21.Madakam, S., Ramaswamy, R., & Tripathi, S. Internet of Things (IoT): A Literature Review. Journal of Computer and Communications, 2015. 3(05), P. 164.

22.Essaaidi, M., Maugeri, M., & Badica, C. (Eds.). Intelligent Distributed Computing IV: Proceedings of the 4th International Symposium on Intelligent Distributed Computing-IDC, Tangier, Morocco, September 2010 (Vol. 315). Springer.

23.Ляшенко О.С. Метод прогнозного обслуговування промислового обладнання з використанням машинного навчання / О.С. Ляшенко, Д.Д.Щербак, Д.Б. Гладуш // Дванадцята міжнародна науково-технічна конференція “Сучасні напрями розвитку інформаційно-комунікаційних технологій та засобів управління” проводиться 27 та 28 квітня 2022 року, Т.1, С. 78.