

Міністерство освіти і науки України
Тернопільський національний технічний університет імені Івана Пулюя

Прикладних інформаційних технологій та електроінженерії

(повна назва факультету)

Комп'ютерно-інтегрованих технологій

(повна назва кафедри)

КВАЛІФІКАЦІЙНА РОБОТА

на здобуття освітнього ступеня

магістр

(назва освітнього ступеня)

на тему: **Інтеграція алгоритмів машинного навчання для оптимізації процесів автоматизованого керування в промислових системах**

Виконав: студент 6 курсу, групи КТм-62

спеціальності 174 – «Автоматизація, комп'ютерно-

інтегровані технології та робототехніка»

(шифр і назва спеціальності)

Ясіновський П.А.

(підпис)

(прізвище та ініціали)

Керівник

Дідич І.С.

(підпис)

(прізвище та ініціали)

Нормоконтроль

Левицький В.В.

(підпис)

(прізвище та ініціали)

Завідувач кафедри

Микитишин А.Г.

(підпис)

(прізвище та ініціали)

Рецензент

Дмитрів О.Р.

(підпис)

(прізвище та ініціали)

м. Тернопіль – 2024

Міністерство освіти і науки України
Тернопільський національний технічний університет імені Івана Пулюя

Факультет прикладних інформаційних технологій та електроінженерії
(повна назва факультету)

Кафедра комп'ютерно-інтегрованих технологій
(повна назва кафедри)

ЗАТВЕРДЖУЮ

Завідувач кафедри

Микитишин А.Г

(підпис)

(прізвище та ініціали)

« 29 » жовтня 2024 р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

на здобуття освітнього ступеня магістр
(назва освітнього ступеня)

за спеціальністю 174 – «Автоматизація, комп'ютерно-інтегровані технології та
робототехніка»
(шифр і назва спеціальності)

студенту Ясіновському Павлу Андрійовичу
(прізвище, ім'я, по батькові)

1. Тема роботи Інтеграція алгоритмів машинного навчання для оптимізації
процесів автоматизованого керування в промислових системах

Керівник роботи Дідич Ірина Степанівна, доктор філософії
(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

Затверджені наказом ректора від « 29 » жовтня 2024 року № 4/7-1030

2. Термін подання студентом завершеної роботи 22.12.2024 р.

3. Вихідні дані до роботи Регресійні методи прогнозування, критерії їх оцінки, нейронні
мережі, підсилені дерева, випадкові ліси, метод k-найближчих сусідів, опорно-векторних
машин, датасет

4. Зміст роботи (перелік питань, які потрібно розробити)

Аналітична частина. 2. Технологічна частина. 3. Конструкторська частина. 4. Науково-
дослідна частина. 5. Спеціальна частина. 6. Охорона праці та безпека в надзвичайних
ситуаціях.

5. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень, слайдів)

1, 2. Актуальність теми та мета роботи. 3,4,5. Архітектура нейронних мереж. 6. Алгоритм
підсилених дерев. 7. Метод випадкових лісів. 8. Метод k-найближчих сусідів. 9. Алгоритм
опорно-векторних машин. 10. Втомне руйнування. 11. Діаграма втомного руйнування.
12. Процес збору, обробки та підготовки даних для моделювання. 13-18. Отримані
результати прогнозування швидкості РВТ. 19. Аналіз результатів якості прогнозування.
20. Висновки.

6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
<i>Охорона праці та безпека в надзвичайних ситуаціях</i>	<i>кандидат технічних наук, доцент кафедри КТ Тотосько Олег Васильович</i>		
	<i>проректор з адміністративно-господарської роботи та будівництва</i>		
	<i>Клепчик Василь Михайлович</i>		

7. Дата видачі завдання 29 жовтня 2024 р.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1.	<i>Аналіз існуючих методів автоматизованого керування в промислових системах</i>	<i>02.11.2024</i>	<i>Виконано</i>
2.	<i>Аналіз алгоритмів машинного навчання</i>	<i>04.11.2024</i>	<i>Виконано</i>
3.	<i>Кінетична діаграма втомного руйнування матеріалів</i>	<i>16.11.2024</i>	<i>Виконано</i>
4.	<i>Інтеграція алгоритмів МН у промислові процеси</i>	<i>30.11.2024</i>	<i>Виконано</i>
5.	<i>Проектування архітектури автоматизованої системи з інтегрованими алгоритмами машинного навчання</i>	<i>05.12.2024</i>	<i>Виконано</i>
6.	<i>Науково-дослідна частина</i>	<i>08.12.2024</i>	<i>Виконано</i>
7.	<i>Спеціальна частина</i>	<i>12.12.2024</i>	<i>Виконано</i>
8.	<i>Охорона праці та безпека в надзвичайних ситуаціях</i>	<i>15.12.2024</i>	<i>Виконано</i>
9.	<i>Оформлення графічної частини</i>	<i>18.12.2024</i>	<i>Виконано</i>
10.	<i>Захист кваліфікаційної роботи</i>	<i>24.12.2023</i>	<i>Виконано</i>

Студент

(підпис)

Ясіновський П.А.

(прізвище та ініціали)

Керівник роботи

(підпис)

Дідич І.С.

(прізвище та ініціали)

АНОТАЦІЯ

Інтеграція алгоритмів машинного навчання для оптимізації процесів автоматизованого керування в промислових системах // Кваліфікаційна робота освітнього рівня «Магістр» // Ясіновський Павло Андрійович // Тернопільський національний технічний університет імені Івана Пулюя, факультет прикладних інформаційних технологій та електроінженерії, кафедра комп'ютерно-інтегрованих технологій, група КТМ-62 // Тернопіль, 2024 // С. 83, рис. – 32, табл. – 0, додат. – 1, бібліогр. – 20.

Ключові слова: алгоритми машинного навчання, нейронні мережі, випадкові ліси, підсилені дерева, метод k -найближчих сусідів, метод опорно-векторних машин, діаграма втомного руйнування, швидкість росту втомної тріщини.

Кваліфікаційна робота стосується інтеграції алгоритмів машинного навчання для оптимізації процесів автоматизованого керування в промислових системах. Основна мета дослідження полягає у розробці та впровадженні сучасних алгоритмів МН для підвищення ефективності, точності та надійності автоматизованих систем керування.

Метою роботи є:

У першому розділі проаналізовано існуючі методи автоматизованого керування, зокрема, розглянуто поточний стан технологій та методів автоматизованого керування, а також проаналізовано алгоритми машинного навчання, такі як нейронні мережі, випадкові ліси, підсилені дерева, опорно-векторні машини та алгоритм k -найближчих сусідів. Описано основні виклики та проблеми, які виникають при впровадженні алгоритмів машинного навчання.

У другому розділі кваліфікаційної роботи детально описано промислові процеси, котрі потребують оптимізації, процес реалізації та налаштування

вибраних алгоритмів та перелічено інструменти та технології, котрі використані в роботі.

У третьому розділі кваліфікаційної роботи описано архітектуру автоматизованої системи з інтегрованими алгоритмами МН та процес розробки програмного забезпечення для системи, а також моделювання та симуляція процесів керування.

У четвертому розділі кваліфікаційної роботи розглянуто методологію, що використовувалася для проведення експериментів, а саме на прикладі ДВР алюмінієвого стопу, описано результати експериментів та їхнє значення.

В п'ятому розділі кваліфікаційної роботи описано специфіку використання нейронних мереж у промислових системах, застосування випадкових лісів та підсилених дерев для підвищення точності прогнозування.

В шостому розділі кваліфікаційної роботи розглянуто забезпечення безпечної роботи з обладнанням.

ANNOTATION

Integration of machine learning algorithms for optimizing automated control processes in industrial systems // Master's degree qualification work / Yasinovskyi Pavlo Andriiovych // Ternopil Ivan Puluj National Technical University, Faculty of Applied Information Technologies and Electrical Engineering, Department of Computer-Integrated Technologies, group KTm-62 // Ternopil, 2024 // P. 83, Fig. 32, Table 0, Supplement 1, Bibliography 20.

Keywords: machine learning algorithms, neural networks, random forests, reinforced trees, k -nearest neighbors method, support vector machine method, fatigue failure diagram, fatigue crack growth rate.

The qualification work is devoted to the integration of machine learning algorithms to optimize automated control processes in industrial systems. The main objective of the research is to develop and implement modern machine learning algorithms to improve the efficiency, accuracy and reliability of automated control systems.

The paper is organized as follows:

In the first chapter, an overview of existing automated control methods is made, in particular, the current state of automated control technologies and methods is considered, and machine learning algorithms such as neural networks, random forests, reinforced trees, support vector machines, and k -nearest neighbors algorithm are analyzed. The main challenges and problems that arise when implementing machine learning algorithms are described.

The second chapter of the qualification work describes in detail the industrial processes that need to be optimized, the process of implementing and configuring the selected algorithms, and lists the tools and technologies used in the work.

The third chapter of the qualification work describes the architecture of the automated system with integrated machine learning algorithms and the process of

developing software for the system, as well as modeling and simulation of control processes.

The fourth chapter of the qualification work describes the methodology used to conduct the experiments, namely, on the example of fatigue failure diagrams of an aluminum alloy, describes the results of the experiments and their significance.

The fifth chapter of the qualification work describes the specifics of using neural networks in industrial systems, use of random forests and reinforced trees to improve forecasting accuracy.

The sixth chapter of the qualification work deals with ensuring safe operation of equipment.

ПЕРЕЛІК СКОРОЧЕНЬ І ТЕРМІНІВ

ІІІ (англ. Artificial Intelligence) – штучний інтелект;

МН (англ. Machine Learning) – машинне навчання;

НМ (англ. Neural Networks) – нейронні мережі;

SVM (англ. Support Vector Machines) – метод опорно-векторних машин;

BT (англ. Boosted Trees) – підсилені дерева;

RF (англ. Random Forest) – випадкові ліси;

KNN (англ. K-Neares Neighbors) – метод k -найближчих сусідів;

АСК – автоматизовані системи керування;

ДВР – діаграма втомного руйнування;

PBT – ріст втомної тріщини;

КІН – коефіцієнт інтенсивності напружень;

R – асиметрія циклу навантаження;

da/dN – швидкість росту втомної тріщини.

ЗМІСТ

ВСТУП	10
РОЗДІЛ 1. АНАЛІТИЧНА ЧАСТИНА.....	12
1.1 Аналіз існуючих методів автоматизованого керування в промислових системах.....	12
1.2 Аналіз алгоритмів машинного навчання	23
1.3 Вибір методів для інтеграції в автоматизовані системи	32
1.4 Стан та проблеми реалізації існуючих методів	35
РОЗДІЛ 2. ТЕХНОЛОГІЧНА ЧАСТИНА.....	39
2.1 Кінетична діаграма втомного руйнування матеріалів.....	39
2.2 Інтеграція алгоритмів МН у промислові процеси	42
2.3 Побудова бази даних для навчання моделей.....	44
РОЗДІЛ 3. КОНСТРУКТОРСЬКА ЧАСТИНА.....	46
3.1 Проєктування архітектури автоматизованої системи з інтегрованими алгоритмами машинного навчання	46
3.2 Вибір програмного забезпечення	48
3.3 Моделювання та симуляція процесів керування	49
РОЗДІЛ 4. НАУКОВО-ДОСЛІДНА ЧАСТИНА	53
4.1 Використання експериментальних даних діаграм втомного руйнування алюмінієвого сплаву	53
4.2 Навчання моделей нейронних мереж, випадкових лісів, підсилених дерев, опорно-векторних машин і k -найближчих сусідів.....	55
4.3 Оцінка точності алгоритмів машинного навчання	61
4.4 Порівняння результатів та вибір оптимального підходу машинного навчання.....	63
РОЗДІЛ 5. СПЕЦІАЛЬНА ЧАСТИНА	66
5.1 Особливості застосування нейронних мереж у промислових системах.....	66
5.2 Застосування підсилених дерев та випадкових лісів для підвищення точності прогнозування.....	71

РОЗДІЛ 6. ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ	73
6.1 Опис негативних впливів виробничого середовища	73
6.2 Організація безпечної роботи з персональним комп'ютером.....	75
ВИСНОВКИ	80
ПЕРЕЛІК ДЖЕРЕЛ.....	82

ДОДАТКИ

ВСТУП

Актуальність теми. Зростання та розвиток сучасних промислових систем стикається з необхідністю постійного підвищення ефективності, точності та надійності процесів автоматизованого керування. Інтеграція алгоритмів машинного навчання відкриває новітні можливості для оптимізації процесів, що дозволяє мінімізувати витрати, покращити якість продукції та підвищити безпеку праці. Важливість впровадження передових технологій є незаперечною, адже це сприяє не тільки економічному зростанню, але й забезпечує конкурентоспроможність на світовому ринку.

Мета і задачі дослідження: метою дослідження є розробка та впровадження алгоритмів машинного навчання для оптимізації процесів автоматизованого керування в промислових системах, зокрема, прогнозування ДВР стопів різними методами МН.

Об'єкт, методи та джерела дослідження. Об'єктом дослідження є важливі елементи конструкцій.

Практичне значення одержаних результатів. Дослід, котрий проведений у цій роботі, спрямоване на розробку нових підходів до інтеграції алгоритмів машинного навчання для оптимізації процесів автоматизованого керування в промислових системах. Обраним прикладом є система моніторингу та прогнозування втомного руйнування стопів, котрі широко застосовуються в авіаційній та автомобільній промисловості. Зокрема, використання алгоритмів машинного навчання для аналізу ДВР передбачає розробку моделей, що дозволяють прогнозувати залишковий ресурс матеріалу на основі аналізу його втомного руйнування. Тому впровадження нейронних мереж, випадкових лісів, підсилених дерев, k -найближчих сусідів та опорно-векторних машин для обробки та аналізу великої кількості експериментальних даних є важливим.

Загалом, розробка методів для покращення точності та надійності прогнозування дозволяють мінімізувати ризики відмов і підвищити безпеку експлуатації обладнання. А також запропоновані моделі та алгоритми

дозволяють більш точно передбачати залишковий ресурс матеріалів, що дає можливість своєчасно виявляти критичні зони втомного руйнування і запобігати аваріям. Тому впровадження інтегрованих моделей у системи керування дозволяє зменшити ймовірність відмов, що є критично важливим у промислових галузях з високими вимогами до безпеки.

Відомо, що автоматизовані системи, котрі використовують алгоритми МН, можуть адаптуватися до змінних умов експлуатації, забезпечуючи оптимальні параметри роботи обладнання. Тому моделі та алгоритми, розроблені в роботі, можуть бути застосовані не тільки в авіаційній та автомобільній промисловості, але й у інших галузях, де використовуються матеріали, котрі схильні до втомного руйнування (для наприкладу, в будівництві, суднобудуванні, енергетиці), а також служити основою для розробки нових методик прогнозування та керування, що сприятиме подальшому розвитку автоматизованих систем керування та підвищенню їхньої ефективності.

Таким чином, результати цієї роботи мають велике значення як у науковій, так і у практичній сферах, сприяючи підвищенню ефективності та безпеки промислових систем.

РОЗДІЛ 1. АНАЛІТИЧНА ЧАСТИНА

1.1 Аналіз існуючих методів автоматизованого керування в промислових системах

Автоматизовані системи керування є важливими у сучасних промислових процесах, забезпечуючи підвищення продуктивності, якості продукції та зниження витрат. Існує декілька основних методів автоматизованого керування, які широко застосовуються у промисловості.

Традиційні методи автоматизованого керування.

1.1. Пропорційно-інтегрально-диференційне керування (PID Control)

PID-регулятор є одним з найбільш поширених інструментів у керуванні промисловими процесами [1]. PID-регулятор безперервно обчислює сигнал помилки як різницю між бажаною уставкою (цільовим значенням) і поточною змінною процесу (вимірним значенням). На основі цього сигналу помилки контролер коригує керуючий вхід системи, щоб мінімізувати помилку і підтримувати змінну процесу близько до заданого значення. Вони використовують три компоненти:

- пропорційний (P), що реагує на поточну похибку між заданим і фактичним значенням;
- інтегральний (I), який враховує накопичену похибку за певний період;
- диференційний (D): реагує на швидкість зміни похибки.

Елементами такої схеми є:

- вхідний сигнал (задане значення);
- PID-регулятор із трьома блоками: пропорційний (P), інтегральний (I), диференційний (D);
- контур зворотного зв'язку;
- система, що керується (наприклад, двигун або нагрівач).




Рисунок 1.1 – Принципова схема ПІД-регулятора [1]

Їх застосовують для керування температурою, тиском, рівнем рідини, швидкістю. Наприклад, підтримання стабільної температури в печі.

1.2. Програмовані логічні контролери (PLC)

Програмовані логічні контролери є найпоширенішою технологією керування промисловими процесами (рис.1.2). ПЛК є комп'ютером промислового класу, який можна запрограмувати на виконувати функції керування. Програмований контролер усунув більшу частину електропроводки, пов'язаної з зі звичайними релейними схемами управління. Інші переваги включають швидка реакція, легке програмування та встановлення, висока швидкість керування, сумісність з мережею, зручність усунення несправностей і тестування, зручність усунення несправностей і висока надійність.



(a)




(b)

Рисунок 1.2 – ПЛК [1]

Відомо, що програми для управління та експлуатації виробничого обладнання та машин, як правило, зберігаються в акумуляторній або енергонезалежній пам'яті. ПЛК є прикладом системи реального часу, оскільки вихідні дані системи, керованої ПЛК, залежить від вхідних умов.

Отже, ПЛК – є цифровим комп'ютером, призначений для використання у керуванні машинами. На відміну від персонального комп'ютера, він був розроблений для роботи в промисловому середовищі і оснащений спеціальними інтерфейсами вводу/виводу та мовою програмування керування. Загальноприйнята аббревіатура, що використовується в промисловості для цих пристроїв, ПК, може бути заплутати, оскільки вона також є аббревіатурою для «персонального комп'ютер». Тому більшість виробників називають свої програмований контролер як ПЛК. Загалом, спочатку ПЛК використовувався для заміни релейної логіки, але його постійно зростаючий діапазон функцій означає, що він що його можна знайти в багатьох і більш складних додатках. Тому що структура ПЛК базується на тих же принципах, що і які використовуються в архітектурі комп'ютерів, він здатний не тільки тільки виконувати завдання релейного перемикачання, але й виконувати інші додатки, такі як синхронізація, підрахунок, обчислення, порівняння та обробка аналогових сигналів.

ПЛК переважають над звичайним релейним типом керування. Тому, реле мають бути жорстко налаштовані на виконання певної функції. Коли системні вимоги змінюються, проводка реле повинна бути змінювати або модифікувати. Програмований контролер усунув більшу частину жорсткої проводки, пов'язаної з зі звичайними релейними схемами управління (рис.1.3). Він невеликий і недорогий порівняно з еквівалентними релейними системами керування технологічними процесами. Сучасні системи керування все ще включають реле, але вони рідко використовуються для логіки.



(a)



(b)

Рисунок 1.2 – Панелі керування на основі реле та ПЛК. (a) Панель керування на основі реле, (б) Панель керування на основі ПЛК [1]

Їх застосовують для керування конвеєрами, роботами, пакувальними машинами. Для прикладу, щоб отримати уявлення про те, як працює ПЛК, розглянемо просту задачу керування технологічним процесом, зображену на рисунку 1.3. Тут двигун мішалки повинен використовуватися для автоматичного перемішування рідину в чані, коли температура і тиск досягають заданих значень [2]. Крім того, пряме ручне керування двигуном забезпечується за допомогою окремого кнопочового пульта. Процес контролюється за допомогою вимикачами датчиків температури і тиску, які замикають відповідні контакти, коли умови досягають заданих значень.




Рисунок 1.3 – Проблема управління процесом змішування [2]

Цю проблему управління можна вирішити за допомогою релейного метод керування двигуном, показаний на схемі релейних сходів рисунку 1.4. Котушка пускача двигуна (M) подається під напругу, коли реле тиску і температури замкнуті або коли натиснута кнопка.




Рисунок 1.4 – Структурна схема реле керування процесом [2]

1.3. SCADA-системи (Supervisory Control and Data Acquisition)

SCADA-системи надають можливість моніторити й контролювати виробничі процеси у реальному часі. Архітектура, показана на рис.1.5, ілюструє типову SCADA-систему з точки зору компонентів або елементів, які з'єднані між

собою через комунікаційну мережу. Виділяють п'ять основних областей або компонентів системи SCADA, як:

- польові пристрої та сигнали;
- програмований контролер процесу;
- робоча станція користувача SCADA;
- комп'ютер сервера SCADA;
- комунікаційна мережа.




Рисунок 1.5 – Структурна схема реле керування процесом [3]

Польові пристрої представлені у вигляді сигналів, що надходять і виходять з ППК; це сюди входять керуючі пристрої, такі як насоси, клапани, електромагніти тощо. Ці польові пристрої є сполучною ланкою між технологією SCADA і технологічними операціями будь-якого автоматизованого об'єкта.

ППК є серцем будь-якої SCADA-системи, оскільки він виконує функції моніторингу та функції моніторингу та управління польовими пристроями. Програмування програмного забезпечення для цих компонентів може стати досить складним через безліч завдань, програм і процедур. Робоча станція користувача SCADA Operations надає користувацький інтерфейс у вигляді графічних зображень процесів, трендів і відповідних звітів. Більшість систем

SCADA мають кілька робочих станцій, через які користувач може взаємодіяти з системою для контролювати операції і здійснювати управління обладнанням.

Серверний комп'ютер SCADA використовується для підтримки технологічних та історичних баз даних для робочих станцій користувачів, а також для забезпечення інтерфейсу зв'язку між серверним комп'ютером і ПЛК.

Комунікаційна мережа - це апаратне та програмне забезпечення, яке з'єднує всі компоненти системи. Типові мережі сьогодні включають Ethernet з Transmission Control Protocol/Internet Protocol (TCP/IP) та власну топологію зв'язку.

Найкращий спосіб проілюструвати концепції та ідеї програмного забезпечення SCADA - це використовувати реальні приклади. Для прикладу, на рис.1.5. показано водоочисну станцію - загальний потік системи.




Рисунок 1.5 – Технологічний процес на водоочисній станції [3]

2. Методи керування на основі моделей MPC.

Керування з передбаченням (Model Predictive Control, MPC) використовує математичну модель системи для прогнозування її поведінки в майбутньому та вибору оптимальних дій. Він став широко використовуваним у промисловості завдяки здатності враховувати обмеження, багатофакторність та динамічність систем, зокрема, для керування хімічними реакторами, турбінами, енергетичними установками (рис.1.6).




Рисунок 1.6 – Модельна схема керування (MPC)

Загалом, використовується модель об'єкта керування (наприклад, динамічні рівняння або емпіричні дані), котра описує, як змінюються вихідні параметри (температура, тиск, швидкість тощо) залежно від керуючих сигналів. Зокрема, модель прогнозує майбутню поведінку системи на певний період часу (горизонт прогнозу) на основі поточного стану та запропонованих керуючих дій. Крім того, алгоритм оптимізує керуючі дії, щоб мінімізувати цільову функцію (наприклад, відхилення від заданого значення або витрати енергії) з урахуванням обмежень на змінні. Після виконання першої оптимальної дії система вимірює новий стан і процес повторюється.

В основі MPC лежить точна модель об'єкта керування. Це можуть бути:

- лінійні моделі (ARX, state-space);
- нелінійні моделі (нейронні мережі, емпіричні моделі).

Цільова функція зазвичай враховує:

- мінімізацію відхилення вихідних параметрів від заданого значення;
- мінімізацію витрат на керування (наприклад, енергоспоживання).

Обмеженнями є:

- фізичні обмеження (діапазон температури, тиску);
- обмеження на змінні стану (наприклад, максимальна швидкість);
- обмеження на керуючі сигнали (наприклад, обмеження потужності).

Отже, горизонтом прогнозу та керування є:

- горизонт прогнозу: час, на який алгоритм передбачає поведінку системи;
- горизонт керування: період, протягом якого застосовуються оптимізовані дії.

MPC є одним із найефективніших методів автоматизованого керування для складних і багатофакторних систем, які потребують оптимізації та врахування обмежень.

3. Інтелектуальні методи автоматизованого керування

Інтелектуальні методи автоматизованого керування базуються на використанні алгоритмів машинного навчання, які дозволяють системам адаптуватися до змінних умов, виявляти приховані закономірності в даних та автоматично приймати оптимальні рішення. Ці методи є основою сучасних "розумних" промислових систем.

Алгоритми ML — це математичні моделі, які "вчать" на основі даних. Мета полягає у створенні моделей, здатних аналізувати дані, робити прогнози та приймати рішення без необхідності жорстко запрограмованих правил.

Основними типами алгоритмів машинного навчання є (рис.1.7):

- контрольоване навчання, де моделі навчаються на основі даних із заданими мітками (наприклад, визначення дефектів на лінії виробництва);
- неконтрольоване навчання, що використовується для виявлення груп або аномалій у даних (наприклад, кластеризація станів обладнання);
- навчання з підкріпленням, де алгоритми вчать через дії, отримуючи винагороди за правильні рішення (наприклад, оптимізація руху роботів).




Рисунок 1.7 – Типи методів машинного навчання

Моделі машинного навчання аналізують історичні дані, щоб передбачати майбутні стани системи. Для прикладу, прогнозування несправностей обладнання на основі параметрів, таких як температура, вібрація, швидкість чи прогнозування кількості циклів до поломки деталей.

Алгоритми ML можуть класифікувати дані в реальному часі, для того, аби визначити, в якому стані знаходиться система:

- класифікація якості продукції (добра/бракована);
- класифікація рівнів ризику у роботі обладнання (нормальний/ризик/аварія).

Загалом, використовується для автоматичного виявлення відхилень у роботі системи. Тобто, виявлення нетипових показників температури чи тиску, які можуть вказувати на проблему.

А також, алгоритми ML можуть визначати оптимальні параметри керування, що мінімізують витрати або збільшують продуктивність. Для прикладу:

- оптимізація енергоспоживання у виробничих лініях;
- вибір оптимальних швидкостей і навантажень для конвеєрів.

Важливо, що системи автоматично змінюють свої параметри залежно від змін умов роботи. Алгоритми машинного навчання є основою сучасних інтелектуальних систем автоматизованого керування, дозволяючи вирішувати складні завдання, підвищувати продуктивність та оптимізувати процеси в промисловості. Їх використання відкриває широкі перспективи для розвитку "розумних" фабрик і підприємств.

4. Інтеграція IoT та Big Data

Інтеграція Інтернету речей і технологій Big Data є однією з ключових складових сучасних автоматизованих систем керування. Вона дозволяє збирати, зберігати, аналізувати і використовувати величезні обсяги даних.

IoT - це мережа взаємопов'язаних фізичних пристроїв, які оснащені датчиками, а також, програмним забезпеченням та різними технологіями, що стосуються збору та обміну даними. Відомо, що їх компонентами є:

- датчики, для збору даних (температура, тиск, вібрації тощо);
- з'єднання, канали передачі даних (Wi-Fi, Bluetooth, LoRaWAN);
- обчислювальні пристрої, для попередньої обробки даних (мікроконтролери, шлюзи).

Big Data — це великі обсяги структурованих і неструктурованих даних, які потребують спеціальних методів і технологій для ефективної обробки та аналізу. Характеристиками Big Data є:

- обсяг, величезна кількість даних, що генерується IoT-пристроями;
- швидкість, дані збираються та обробляються в реальному часі;
- різноманітність, дані з різних джерел (текст, зображення, відео, сенсорні сигнали);

- достовірність, необхідність роботи з "шумними" даними та забезпечення їхньої якості.

Загалом, IoT-пристрої збирають дані з виробничого обладнання (наприклад, температура, тиск, споживання енергії). Тоді дані передаються в аналітичні системи для обробки. Тоді як Big Data-аналітика дозволяє виявляти патерни, які вказують на можливі поломки. Наприклад, аналіз вібрацій для виявлення зношення підшипників.

Дані з IoT-пристроїв аналізуються для визначення оптимальних параметрів роботи обладнання (наприклад, налаштування швидкості конвеєра) та автоматичного виявлення відхилень у роботі системи (наприклад, раптові зміни температури чи тиску). Big Data дозволяє виявити малоефективні процеси та оптимізувати використання енергоресурсів. У табл.1 показано порівняння різних методів, їх переваги та недоліки.

Таблиця 1. Порівняння методів автоматизованого керування в промислових системах

Метод	Переваги	Недоліки
PID-регулятори	Простота, надійність	Не підходить для складних систем
PLC	Гнучкість програмування	Обмежена адаптивність
SCADA	Моніторинг у реальному часі	Висока вартість
MPC	Врахування багатьох змінних	Високі обчислювальні вимоги
Машинне навчання	Адаптація, точність прогнозів	Складність інтеграції

1.2 Аналіз алгоритмів машинного навчання

НМ – це математичні моделі, котрі структурою і функціонуванням схожі до біологічного мозку [4,5]. Основна мета – навчитися моделювати складні нелінійні залежності між вхідними та вихідними даними, використовуючи ітеративний процес навчання.

Нейронна мережа складається з наступних компонентів (рис.1.8):

- вхідний шар: отримує вхідні дані, тобто, кількість нейронів у цьому шарі відповідає кількості характеристик у вхідних даних;
- приховані шари: складаються з нейронів, які виконують обчислення на основі ваг і функцій активації. Кількість шарів і нейронів у них визначає потужність мережі;
- вихідний шар: генерує кінцевий результат (наприклад, класифікацію чи числове передбачення).




Рисунок 1.8 – Структура нейронної мережі

- нейрони, тобто, кожен нейрон є базовим будівельним блоком мережі. Його робота описується рівнянням:

$$z = \sum_{i=1}^n w_i x_i + b$$

де:

- x_i – вхідні сигнали;
- w_i – ваги зв'язків, які визначають, наскільки кожен вхід важливий;
- b – зсув (bias), який дозволяє зміщувати активацію.

- функція активації, тобто, функція активації застосовується до z для введення нелінійності в модель:

$$a = f(z)$$

Типові функції активації:

- Сигмоїда: $f(z) = \frac{1}{1+e^{-z}}$ (використовується для ймовірностей).
- ReLU: $f(z) = \max(0, z)$ (поширена у глибоких мережах).
- tanh: $f(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$ (нормалізує значення від -1 до 1).

Кожен нейрон із одного шару з'єднаний із кожним нейроном наступного шару, утворюючи повнозв'язну структуру. Навчання НМ є важливим та полягає у налаштуванні вагових коефіцієнтів так, щоб мережа могла правильно прогнозувати результати на основі вхідних даних. Це досягається за допомогою методу зворотного поширення помилки та алгоритмів оптимізації, таких як градієнтний спуск.

Метод зворотного поширення помилки включає:

- визначення помилки, тобто, різниця між передбаченим та фактичним значеннями;
- обчислення градієнтів, а саме, використання часткових похідних для обчислення градієнтів функції помилки щодо ваг;
- оновлення ваг, зокрема, регулювання ваг з урахуванням обчислених градієнтів і швидкості навчання.

Отже, НМ є потужним інструментом для розв'язання широкого спектра задач, починаючи від класифікації та регресії до обробки зображень та тексту. Використання різних архітектур, функцій активації та методів оптимізації дозволяє адаптувати нейронні мережі до конкретних задач і досягати високої точності прогнозування.

Підсилені дерева є потужною технікою ансамблевого навчання, яка поєднує безліч простих моделей (дерев рішень) для створення однієї сильної

моделі. Основна ідея полягає в послідовному навчанні моделей, де кожна наступна модель намагається виправити помилки попередніх [6].

Підсилені дерева використовують ітеративний процес, де кожне дерево рішень навчається на основі помилок попереднього дерева. Основними алгоритмами підсилення є AdaBoost, Gradient Boosting та XGBoost.

Основною ідеєю AdaBoost (Adaptive Boosting) є надати більшу вагу спостереженням, які були неправильно класифіковані попередніми моделями. Тому на кожному етапі зважена сума помилок використовується для навчання нового дерева рішень. Остаточне рішення базується на зваженому голосуванні всіх дерев.

Ідеєю Gradient Boosting є оптимізувати функцію втрат шляхом додавання нових дерев, які мінімізують залишкову похибку попередньої моделі. Зокрема, на кожному етапі додається дерево, яке навчається на залишкових похибках попереднього дерева. Ці залишкові похибки розраховуються як градієнти функції втрат.

Основною ідеєю XGBoost (Extreme Gradient Boosting) є покращити продуктивність Gradient Boosting за допомогою регуляризації та оптимізації обчислень. Зокрема, використовує ту ж ідею градієнтного підсилення, але з додатковими можливостями для контролю перенавчання та прискорення обчислень.

Ключовими етапами роботи підсилення дерев є (рис.1.9):

- ініціалізація моделі, починається з простої моделі (наприклад, середнього значення для регресії або рівномірної ймовірності для класифікації);
- ітеративне навчання: на кожній ітерації розраховуються залишкові помилки або градієнт функції втрат, навчається нове дерево, яке намагається передбачити ці помилки, комбінується поточна модель з попередніми моделями.

Дані → Дерево 1 → Дерево 2 → ... → Дерево T
↘ Комбінація результатів ✓
Остаточний прогноз

Рисунок 1.9 – Приклад побудови алгоритму підсилених дерев

Загальний прогноз отримуємо підсумовування внесків усіх дерев:

$$F(x) = \sum_{t=1}^T \alpha_t h_t(x)$$

де:

- $h_t(x)$ – слабка модель (дерево);
- α_t – вага кожного дерева;
- T – кількість дерев.

Отже, підсилені дерева є потужною технікою машинного навчання, яка дозволяє досягати високої точності при мінімізації помилок попередніх моделей. Зокрема, метод широко використовують у задачах класифікації, регресії та ранжування завдяки своїй здатності адаптуватися до складних даних та вирішувати проблеми перенавчання.

Випадкові ліси є потужним методом ансамблевого навчання, що використовується для задач класифікації чи регресії [7]. Загалом, поєднується велика кількість дерев рішень, створених на різних підмножинах навчальних даних, для підвищення точності та стабільності прогнозів. Зокрема, випадкові ліси використовують метод підсумовування або усереднення результатів багатьох дерев рішень. Тому основна ідея методу полягає у створенні множини дерев, які навчаються на різних підмножинах даних та використовують випадковий вибір ознак для поділу вузлів (рис. 1.10).

Основними етапами створення випадкового лісу є:

$$w \cdot x + b = 0$$

де:

- w – вектор ваг (нормаль до гіперплощини);
- x – вхідний вектор ознак;
- b – зсув (bias).

Ядра використовуються для обчислення скалярного добутку у вищому вимірі, не виконуючи явного проектування. Основними типами ядер є:

1. Лінійне ядро:

$$K(x_i, x_j) = x_i \cdot x_j$$

2. Поліноміальне ядро:

$$K(x_i, x_j) = (x_i \cdot x_j + c)^d$$

де c – зміщення, d – ступінь полінома.

3. RBF (Radial Basis Function):

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$$

де γ – параметр, що контролює "ширину" функції.

4. Сигмоїдне ядро:

$$K(x_i, x_j) = \tanh(\alpha x_i \cdot x_j + c)$$

Метою опорно-векторних машин є знаходження гіперплощини, котра забезпечує максимальний зазор між найближчими точками обох класів.

Схемою роботи опорно-векторних машин є (рис. 1.11):

- збір та нормалізація даних;
- вибір ядра (лінійного чи нелінійного);
- побудова гіперплощини або ядрового перетворення для нелінійних даних;
- класифікація нових даних на основі побудованої моделі.



Рисунок 1.11 – Приклад побудови алгоритму опорно-векторних машин

Опорно-векторні машини є потужним методом для розв'язання задач класифікації та регресії, оскільки вони здатні знаходити оптимальні гіперплощини для розділення даних. Використання ядерних методів дозволяє SVM працювати з нелінійно роздільними даними, забезпечуючи високу точність і ефективність.

Алгоритм k -найближчих сусідів є простим та інтуїтивним методом машинного навчання, оскільки його часто застосовують для задач класифікації та регресії. Основна ідея полягає у визначенні найближчих сусідів для об'єкта на

основі відстані між точками в багатовимірному просторі та прогнозуванні його класу або значення на основі цих сусідів [9].

Метод k -найближчих сусідів не вимагає явного процесу навчання. Всі навчальні дані зберігаються, і весь обчислювальний процес відбувається під час прогнозування. Тобто, визначається відстань між новим об'єктом і всіма об'єктами в навчальному наборі даних. Тоді вибираються k найближчих сусідів. Зокрема, клас або значення нового об'єкта визначається на основі класів або значень сусідів.

Основними метриками для вимірювання відстані є:

1. Евклідова відстань:

$$d(x_{\text{test}}, x_i) = \sqrt{\sum_{j=1}^m (x_{\text{test},j} - x_{i,j})^2}$$

2. Манхеттенська відстань:

$$d(x_{\text{test}}, x_i) = \sum_{j=1}^m |x_{\text{test},j} - x_{i,j}|$$

3. Косинусна схожість:

Використовується для виявлення подібності між векторами:

$$\cos \theta = \frac{\sum_{j=1}^m x_{\text{test},j} \cdot x_{i,j}}{\sqrt{\sum_{j=1}^m (x_{\text{test},j})^2} \cdot \sqrt{\sum_{j=1}^m (x_{i,j})^2}}$$

Схемою роботи алгоритму k -найближчих сусідів є (рис. 1.12):

- всі доступні дані зберігаються;
- обчислення відстані між новим об'єктом та всіма навчальними даними;
- вибір k найближчих сусідів;
- для класифікації - голосування більшості; для регресії - усереднення значень.

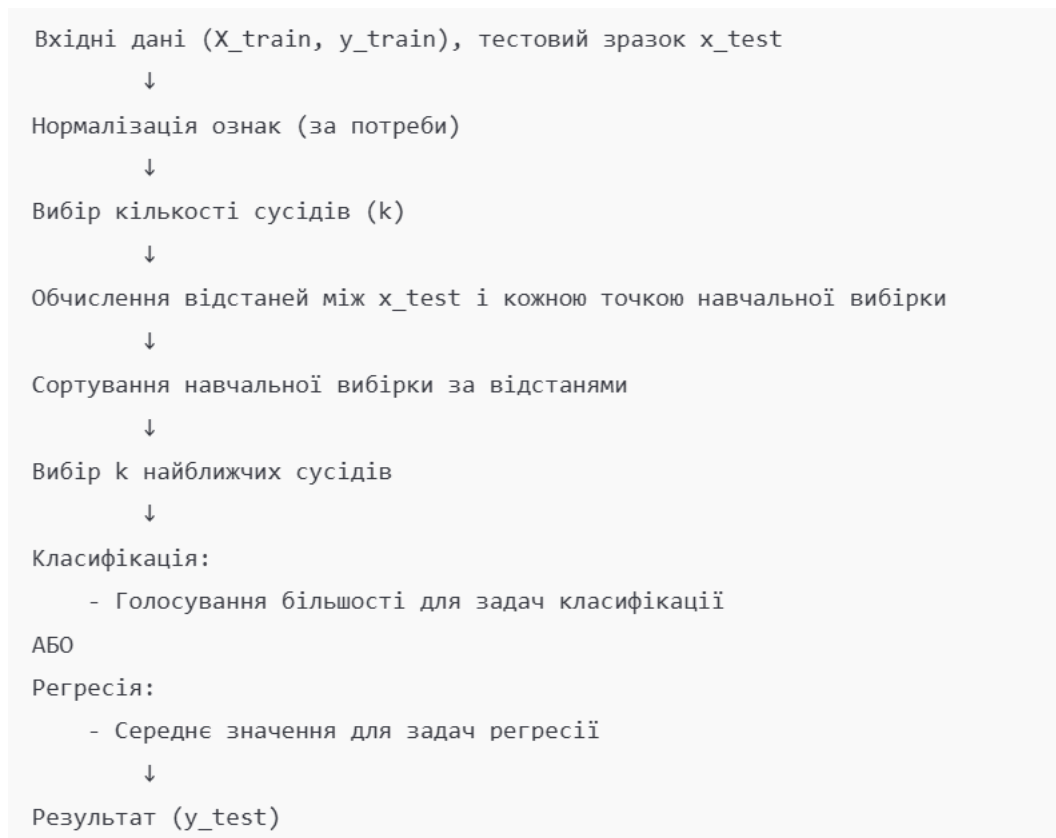


Рисунок 1.12 – Приклад побудови алгоритму k -найближчих сусідів

Алгоритм k -найближчих сусідів є ефективним інструментом для багатьох задач, завдяки своїй простоті та інтуїтивності. Його можна застосовувати до широкого спектра даних, враховуючи правильний вибір метрики відстані та кількості сусідів. Адже він базується на ідеї, що схожі об'єкти знаходяться поруч один з одним у багатовимірному просторі ознак.

1.3 Вибір методів для інтеграції в автоматизовані системи

Інтеграція алгоритмів машинного навчання в автоматизовані системи керування вимагає ретельного аналізу та вибору методів, які будуть найбільш ефективними для конкретних завдань. Зокрема, вибір методів залежить від типу даних, вимог до точності, швидкості обробки та інших факторів. Основними кроками та критеріями вибору методів для інтеграції є:

- визначення мети і завдань. Першим кроком є чітке визначення мети інтеграції алгоритмів машинного навчання, тобто, поліпшення точності прогнозування: наприклад, підвищення точності виявлення дефектів у виробничому процесі чи оптимізація процесів: наприклад, зменшення часу простою обладнання шляхом прогнозування несправностей або адаптивне керування: наприклад, автоматичне налаштування параметрів системи для підтримання оптимальних умов роботи;
- аналіз даних. Другим важливим кроком є детальний аналіз наявних даних, зокрема, тип даних: часові ряди, зображення, текстові дані, табличні дані; розмір даних: кількість доступних зразків, розмірність даних; якість даних: наявність пропущених значень, шуму, аномалій.
- вибір алгоритмів машинного навчання. На основі аналізу даних і вимог до системи здійснюється вибір алгоритмів машинного навчання. Найпопулярнішими методами машинного навчання є:
- нейронні мережі
 - тип даних: зображення, текст, складні часові ряди;
 - застосування: виявлення аномалій, прогнозування, класифікація, регресія;
 - переваги: висока точність, здатність до самонавчання;
 - недоліки: необхідність великих обчислювальних ресурсів і великих обсягів даних;
- випадкові ліси
 - тип даних: табличні дані;
 - застосування: класифікація, регресія;
 - переваги: стійкість до перенавчання, інтерпретованість;
 - недоліки: високі обчислювальні витрати при великих наборах даних;
- підсилені дерева
 - тип даних: табличні дані;
 - застосування: класифікація, регресія;

- переваги: висока точність, ефективність;
- недоліки: складність налаштування, потреба в обчислювальних ресурсах;
- опорно-векторні машини
 - тип даних: табличні дані, дані середньої розмірності;
 - застосування: класифікація, регресія;
 - переваги: висока точність, ефективність для малих та середніх наборів даних;
 - недоліки: високі обчислювальні витрати при великих наборах даних, складність налаштування ядерних функцій;
- алгоритм k -найближчих сусідів
 - тип даних: табличні дані, дані з невеликою кількістю ознак;
 - застосування: класифікація, регресія;
 - переваги: простота реалізації та інтерпретованість;
 - недоліки: високі обчислювальні витрати при великих наборах даних, чутливість до параметра k .

Перед тим, як вибрати остаточний алгоритм, необхідно провести оцінку і порівняння ефективності різних методів:

- модельна оцінка, тобто, використання методів перехресної перевірки для оцінки точності моделей;
- обчислювальні витрати, зокрема, аналіз потреб в обчислювальних ресурсах для тренування і прогнозування;
- інтерпретованість, а саме, врахування можливості інтерпретації результатів алгоритму;
- стійкість до шуму, тобто, оцінка стійкості алгоритму до наявності шуму та аномалій у даних.

Після вибору оптимального алгоритму проводиться інтеграція в автоматизовану систему керування. Тобто, створення інтерфейсів для взаємодії алгоритму з іншими компонентами системи, проведення тестування для

перевірки коректності роботи алгоритму в реальних умовах та впровадження механізмів моніторингу і періодичної оптимізації алгоритму на основі нових даних.

Отже, вибір методів для інтеграції в автоматизовані системи є багатокроковим процесом, що включає аналіз даних, вибір відповідних алгоритмів, їх оцінку та інтеграцію. Важливо враховувати специфіку даних і вимоги до системи, щоб забезпечити високу точність і ефективність прогнозування.

1.4 Стан та проблеми реалізації існуючих методів

Сьогодні машинне навчання активно інтегрується в автоматизовані системи управління промисловими процесами, де від точності прогнозування залежить ефективність і надійність технологічних процесів [7-9]. Найбільш поширені методи, такі як нейронні мережі, випадкові ліси, підсилені дерева, метод опорно-векторних машин і метод k -найближчих сусідів, демонструють високу продуктивність у вирішенні задач класифікації, регресії, кластеризації та виявлення аномалій.

Методи МН широко використовуються для моніторингу стану обладнання, прогнозування зносу матеріалів, оптимізації логістики, управління робототехнікою та інших процесів. Впровадження машинного навчання в промислові системи дозволяє досягти зменшення енергоспоживання, покращення якості продукції та зниження вартості виробництва. Зокрема, для підвищення точності прогнозування та адаптивності автоматизованих систем широко використовується поєднання фізичних моделей і ML-алгоритмів, наприклад, для прогнозування втомного руйнування матеріалів. Тоді як розвиток апаратного забезпечення (GPU, TPU) значно прискорює навчання складних моделей, таких як глибокі нейронні мережі.

Хоча машинне навчання вже демонструє значні переваги, реалізація існуючих методів у промислових системах стикається з рядом викликів:

- вимоги до великих обсягів даних, тобто, більшість алгоритмів машинного навчання потребує значних обсягів якісно маркованих даних для навчання. У промислових системах збір таких даних є складним і дорогим процесом;
- наявність шуму та нерелевантної інформації, зокрема, дані з промислових сенсорів часто мають велику кількість шуму, що ускладнює навчання моделей і може призводити до неправильних прогнозів;
- нестабільність при зміні середовища, тобто, якщо умови роботи системи змінюються (наприклад, через зміну характеристик матеріалів чи умов експлуатації), модель може втратити точність через неврахування нових даних;
- високі ресурси для навчання, а саме, глибокі нейронні мережі та інші складні моделі вимагають значних обчислювальних потужностей. У реальному часі це може стати проблемою для промислових систем із обмеженим апаратним забезпеченням;
- складність оптимізації, тобто, деякі моделі, такі як метод опорно-векторних машин або підсилені дерева, можуть бути обчислювально складними при роботі з великими обсягами даних;
- "чорна скринька" моделей, тобто, багато алгоритмів ML, зокрема нейронні мережі та підсилені дерева, є важкими для інтерпретації. Це ускладнює довіру до системи та її впровадження у відповідальні процеси, такі як контроль за станом критичних конструкцій;
- наслідки непередбачуваної поведінки, зокрема, при інтеграції моделей машинного навчання в реальні промислові системи помилки в прогнозуванні можуть спричинити серйозні наслідки, включаючи збої в роботі обладнання чи втрату ресурсів;

- складність налаштування, підбір гіперпараметрів, вибір оптимальних моделей і їх адаптація до конкретних задач потребує значних знань та досвіду;
- складність тестування, тобто, моделі машинного навчання можуть показувати високі результати на тестових наборах, але давати значні похибки в реальних умовах. Це пов'язано з можливим "перенавчанням" на специфічні дані;
- відсутність стандартів, зокрема, у сфері впровадження ML у промисловість бракує єдиних стандартів для тестування, оцінювання й сертифікації алгоритмів;
- високі початкові витрати, а саме, інтеграція алгоритмів ML у промислові системи потребує значних інвестицій у обладнання, збір даних, розробку й тестування моделей;
- навчання персоналу, впровадження ML вимагає підготовки фахівців, які розуміють принципи роботи моделей і можуть їх обслуговувати.

Для покращення якості даних важливим є використання методів попередньої обробки, таких як видалення шуму, балансування класів, генерація синтетичних даних та розробка автоматизованих систем збору даних, котрі дозволяють зменшити людський фактор. Тоді як для оптимізації обчислювальних процесів важливим є використання хмарних обчислень або розподілених систем для обробки величезних даних та застосування менш складних моделей у задачах, де точність не критично важлива.

Відомо, що розробка адаптивних моделей включає впровадження підходів, які дозволяють ML-моделям адаптуватися до змін у навколишньому середовищі або нових даних без потреби повного перенавчання, а також, використання реальних даних для тестування моделей перед впровадженням.

Отже, ці проблеми та шляхи їх вирішення показують, що впровадження методів МН в промислові автоматизовані системи є перспективним напрямом,

але потребує значної уваги до якості даних, оптимізації моделей і забезпечення їх надійності.

РОЗДІЛ 2. ТЕХНОЛОГІЧНА ЧАСТИНА

2.1 Кінетична діаграма втомного руйнування матеріалів

Втомне руйнування – це поступове руйнування матеріалу під впливом циклічних навантажень. Воно відбувається навіть при навантаженнях, які значно нижчі за межу статичної міцності матеріалу. Основною метою аналізу втомного руйнування є прогнозування довговічності матеріалів та конструкцій, а також попередити їх передчасне руйнування.

Оцінкою міцності та довговічності конструкцій займається багато різних галузей науки та інженерії. На рис. 2.1 показано основні процеси руйнування на різних масштабах і рівнях, зокрема, в механіці руйнування поведінка тріщин у твердих тілах описується на макроскопічному рівні [10].




Рисунок 2.1 – Руйнування на різних масштабах і рівнях [10]

Одним із ключових інструментів аналізу є кінетична діаграма втомного руйнування (рис.2.2), яка дозволяє моделювати та прогнозувати поведінку матеріалу під дією змінних навантажень.




Рисунок 2.2 – Кінетична діаграма втомного руйнування [11]

Кінетична діаграма втомного руйнування описує залежність між:

- кількістю циклів навантаження до руйнування N ;
- зростанням тріщини (da/dN);
- рівнем напруження в матеріалі (ΔK).

Цей підхід базується на механіці руйнування та аналізі росту втомних тріщин. Основна залежність описується через закон Паріса-Ердогана:

$$\frac{da}{dN} = C \cdot (\Delta K)^m$$

Де:

- a – довжина тріщини,
- N – кількість циклів навантаження,
- $\Delta K = K_{\max} - K_{\min}$ – діапазон коефіцієнта інтенсивності напружень,
- C, m – матеріалозалежні константи.

Напружено-деформований стан практично описує умови, за яких відбуваються процеси руйнування у вершині тріщини (рис. 2.3).




Рисунок 2.3 – Зона мікромеханічних процесів руйнування біля вершини тріщини [10]

Відомо, що реальні умови роботи матеріалу (температура, вологість, агресивне середовище) значно впливають на параметри росту тріщини [12]. Зокрема, у реальних матеріалах ріст тріщини може бути нерівномірним через структурні дефекти (пори, включення тощо). А також, закон Паріса не враховує низку факторів, таких як перевантаження, змінність амплітуди навантажень і мікроструктурні ефекти. Тому алгоритми МН, такі як НМ або підсилені дерева, дозволяють:

- прогнозувати ріст тріщин на основі великих наборів експериментальних даних;
- враховувати складні залежності між параметрами навантаження, геометрією та структурними характеристиками матеріалу;
- підвищувати точність моделювання шляхом автоматичного врахування множини факторів, які важко формалізувати традиційними методами.

Кінетична діаграма втомного руйнування є важливим інструментом для прогнозування довговічності матеріалів. Її побудова базується на фізичних моделях росту тріщин, але сучасні проблеми, пов'язані з нерівномірністю даних і складністю експериментів, потребують впровадження новітніх методів аналізу.

Інтеграція алгоритмів МН дозволяє значно розширити можливості моделювання, забезпечуючи точність і надійність прогнозів у промислових системах.

2.2 Інтеграція алгоритмів МН у промислові процеси

Інтеграція машинного навчання у промислові процеси є інноваційним підходом до автоматизації, оптимізації та прогнозування стану обладнання й матеріалів. Вона передбачає використання алгоритмів МН для аналізу великих масивів даних, які генеруються у реальному часі, та прийняття рішень на основі отриманих результатів. Цей процес охоплює кілька ключових етапів: від збору даних до реального впровадження моделей у виробничі цикли.

Основними етапами інтеграції алгоритмів методів машинного навчання є:

- збір та підготовка даних (дані, зібрані з промислових сенсорів, контролерів, ERP-систем чи SCADA-систем, є основою для навчання ML-моделей);
- джерела даних (сенсори температури, тиску, вібрації, навантаження, дані про цикли роботи, витрати матеріалів, енергоспоживання);
- проблеми (дані часто містять шум, пропуски, дублікати або нерелевантну інформацію. Це потребує ретельного очищення та обробки);
- обробка (нормалізація, видалення пропусків, інженерія ознак, застосування методів боротьби з дисбалансом класів).

На рисунку 2.4 показано схему інтеграції методів МН у промислові процеси.




Рисунок 2.4 – Схема інтеграції методів МН

Для інтеграції МН використовуються алгоритми, що найкраще підходять до специфіки завдання:

- нейронні мережі, що використовуються для складних задач, таких як розпізнавання образів, прогнозування складних залежностей, аналіз зображень (наприклад, візуальний контроль якості);
- випадкові ліси, котрі підходять для задач класифікації та регресії, де важливо отримати інтерпретовані результати;
- підсилені дерева, наприклад, XGBoost або LightGBM, які ефективні для моделювання великих наборів даних із високою точністю;
- метод опорно-векторних машин, що використовується для задач класифікації з невеликими обсягами даних;
- метод k -найближчих сусідів, що підходить для швидкого розпізнавання шаблонів або кластеризації в малих наборах даних.

Моделі машинного навчання навчаються на історичних даних, які відображають характерні поведінкові особливості системи, а також інтегруються в програмне забезпечення автоматизованих систем управління, таких як SCADA для прикладу.

Інтеграція методів МН в промислові процеси дозволяє досягти значного підвищення ефективності, точності управління та надійності обладнання. Однак успіх впровадження залежить від правильної підготовки даних, вибору алгоритмів та інтеграції в існуючу інфраструктуру. Інтеграція МН не лише оптимізує процеси, а й відкриває нові горизонти автоматизації та цифрової трансформації промисловості.

2.3 Побудова бази даних для навчання моделей

Створення якісної бази даних є одним із ключових етапів у розробці ефективних моделей машинного навчання. База даних повинна бути структурованою, репрезентативною та відповідати специфіці завдань. У контексті промислових процесів база даних формується на основі інформації, отриманої з сенсорів, журналів обладнання, експериментів або інших джерел.

Перш ніж розпочати побудову бази даних, важливо визначити цілі та вимоги до даних:

- цілі навчання, які саме моделі будуть навчатись (класифікація, регресія, кластеризація);
- тип даних, вхідні дані можуть бути числовими, категоріальними, часовими рядами, текстом, зображеннями;
- обсяг даних, кількість зразків, необхідних для навчання моделей з достатньою точністю.

Джерела даних залежать від специфіки процесу:

- дані сенсорів, інформація про температуру, тиск, вібрацію, навантаження;
- експериментальні дані, результати лабораторних випробувань, наприклад, кінетичні діаграми втомного руйнування;
- лог-файли, журнали роботи обладнання, записи про помилки чи поломки;

- зображення чи відео, для задач комп'ютерного зору, наприклад, виявлення дефектів продукції.

Зокрема, дані мають бути структуровані в зручному форматі, який легко інтегрувати в моделі. Зазвичай, використовується:

- об'єкт дослідження;
- вхідні ознаки, а саме, параметри, що описують об'єкт;
- цільова змінна, те, що модель повинна передбачати (наприклад, час до руйнування, наявність дефекту).

На рис. 2.5 показано схему побудови бази даних для навчання моделей.




Рисунок 2.5 – Схема побудови бази даних

Отже, побудова бази даних для навчання моделей є багатокроковим процесом, що включає збір, обробку, очищення та структурування даних.

РОЗДІЛ 3. КОНСТРУКТОРСЬКА ЧАСТИНА

3.1 Проєктування архітектури автоматизованої системи з інтегрованими алгоритмами машинного навчання

Проєктування архітектури автоматизованої системи з інтегрованими алгоритмами машинного навчання є складним процесом, що потребує ретельного планування та врахування багатьох факторів. Основна мета - створення системи, котра забезпечує ефективну інтеграцію моделей МН для оптимізації виробничих процесів, підвищення точності прогнозів, автоматизації контролю якості та інших завдань. Зокрема, має забезпечувати ефективне збирання, обробку, аналіз даних і використання моделей для підтримки прийняття рішень у реальному часі. Така система орієнтована на індустріальні процеси, оптимізацію виробництва та підвищення його надійності та складається з підсистем:

- модуль збору даних, що відповідає за отримання даних із сенсорів, промислових пристроїв або інших джерел;
- модуль попередньої обробки даних, що виконує очищення, нормалізацію та перетворення даних;
- модуль машинного навчання, котрий реалізує алгоритми навчання, прогнозування та адаптації моделей;
- модуль інтеграції, що забезпечує передачу даних між компонентами та підключення до промислового обладнання;
- інтерфейс управління, що забезпечує моніторинг стану системи, перегляд результатів прогнозування та управління процесами.

Загалом, система проєктується як набір функціональних блоків, що забезпечують:

- безперервний збір даних;
- інтерактивний аналіз та візуалізацію;
- автоматизоване прийняття рішень.

Відомо, що до модуля збору даних відноситься:

- сенсори (температура, тиск, навантаження);
- промислові контролери (PLC, SCADA-системи);
- бази даних історичних записів (SQL/NoSQL);
- протоколи передачі даних.

Модуль попередньої обробки даних готує дані до використання моделями машинного навчання, а саме:

- фільтрація шумів, використання середньо-ковзаючих фільтрів чи хвильового перетворення;
- нормалізація та стандартизація даних, приведення значень до єдиного масштабу для коректної роботи алгоритмів;
- виявлення аномалій, алгоритми статистичного аналізу чи МН;
- агрегація даних, групування за часовими інтервалами.

Модуль машинного навчання складається з таких компонентів:

- база моделей, наприклад, нейронні мережі, алгоритми підсилених дерев, опорно-векторні машини для класифікації дефектів;
- дані зберігаються у форматі, придатному для навчання, наприклад, .csv;
- у реальному часі отримує дані та повертає прогноз (наприклад, залишковий ресурс матеріалу або ризик відмови);
- використання підходів онлайн-навчання для адаптації до даних, котрі є новими, невідомими для системи, без перерви.

До модуля інтеграції відноситься:

- інтеграція з існуючими системами автоматизованого управління (SCADA);
- використання хмарних платформ (Google Cloud) для масштабованості;
- API для доступу до прогнозів та статистики.

Інтерфейс управління включає веб-додаток або робоча станція оператора для моніторингу стану системи (графіки, таблиці), налаштування моделей та порогів та отримання інтерактивних звітів про роботу.

Проектування архітектури автоматизованої системи з інтегрованими алгоритмами МН є важливим етапом сучасних технологій, котрі впроваджують у промисловість. Система повинна бути масштабованою, надійною та гнучкою для ефективної інтеграції ML-алгоритмів, забезпечуючи точність і швидкість прийняття рішень.

3.2 Вибір програмного забезпечення

Для реалізації інтеграції методів МН в автоматизовані системи вибір програмного забезпечення зосереджується на інструментах, що забезпечують аналіз експериментальних даних, побудову моделей прогнозування та інтеграцію в промислові процеси. У цьому контексті основний акцент зроблено на використанні програмного пакета STATISTICA, а також на базовому апаратному забезпеченні для підтримки роботи програми.

STATISTICA є потужним програмним пакетом для аналізу даних, моделювання та візуалізації, який забезпечує широкі можливості для реалізації методів МН в контексті дослідження та прогнозування характеристик матеріалів, а також дозволяє виконувати повний спектр статистичних розрахунків, таких як описова статистика, регресійний чи кластерний аналіз. А також, є підтримка роботи з великими наборами експериментальних даних, що є критично важливим для побудови моделей на основі діаграм втомного руйнування.

Відомо, що STATISTICA включає модулі для побудови моделей класифікації та регресії, зокрема, НМ, дерев рішень, випадкових лісів і методів підтримки векторів. А також, є можливість налаштовувати гіперпараметри моделей, що дозволяє підвищити їх точність. Додатково, модулі STATISTICA для прогнозування дають змогу будувати моделі росту втомних тріщин та прогнозувати поведінку матеріалів при різних умовах навантаження.

Використання програмного забезпечення дозволяє здійснити:

- обробку експериментальних даних, тобто, аналіз масивів даних, отриманих з експериментів на циклічних машинах, що визначають втомне руйнування матеріалів;
- побудову кінетичних моделей, використання модуля регресійного аналізу для побудови кінетичних діаграм втомного руйнування, що описують швидкість росту тріщин залежно від циклічного навантаження;
- прогнозування, а саме, навчання алгоритмів МН для прогнозу поведінки алюмінієвого сплаву при різних умовах експлуатації;
- візуалізацію, а саме, відображення залежностей між параметрами втомного руйнування у вигляді 3D-графіків для кращого розуміння процесів.

STATISTICA є оптимальним програмним забезпеченням для виконання завдань аналізу та моделювання в рамках проекту. Воно забезпечує необхідний функціонал для обробки експериментальних даних, побудови моделей машинного навчання та візуалізації результатів. У поєднанні з обраним апаратним забезпеченням STATISTICA дозволяє ефективно інтегрувати алгоритми машинного навчання у промислові процеси, підвищуючи точність прогнозів та оптимізуючи управління.

3.3 Моделювання та симуляція процесів керування

Моделювання та симуляція процесів керування є важливими етапами у розробці та оптимізації систем автоматизованого керування, зокрема для промислових застосувань, що виявляють потенційні проблеми на початкових етапах розробки, протестувати різні стратегії керування і забезпечити ефективність роботи системи до її впровадження на практиці.

Моделювання процесів керування включає створення абстракцій (математичних моделей), які відображають поведінку системи в умовах заданих

вхідних параметрів. Моделювання є ключовим етапом, оскільки дозволяє розробникам проаналізувати динаміку процесів і підібрати оптимальні стратегії керування, а також зрозуміти реакцію системи на різні умови.

Математичними моделями процесів керування є:

- диференціальні рівняння, зокрема, для моделювання динамічних систем часто використовуються диференціальні рівняння, які описують зміну параметрів системи з часом. Наприклад, для моделювання втомного руйнування матеріалів можуть використовуватися рівняння;
- моделі на основі стану, котрі можуть бути побудовані з використанням рівнянь стану, які описують поведінку системи через вектори стану. Це дозволяє включити в модель різноманітні аспекти, такі як зміни вхідних сигналів і параметрів процесу;
- аналіз стійкості та оптимізація, тобто, моделювання стійкості керування вимагає аналізу системи на стабільність і досягнення оптимальних результатів. Для цього використовуються такі методи, як лінійний і нелінійний аналіз стійкості (наприклад, метод Ляпунова).

Існують такі типи моделей керування:

- моделі відкритого циклу, що не використовують зворотний зв'язок для корекції результатів. Вони корисні в простих процесах, де умови та параметри не змінюються під час роботи;
- моделі замкнутого циклу, що використовують зворотний зв'язок для коригування процесу на основі реальних результатів. Це особливо корисно в системах, де параметри можуть змінюватися, наприклад, при варіаціях навантаження на матеріал;
- адаптивні та інтелектуальні моделі, зокрема, у випадку інтеграції алгоритмів машинного навчання, моделі можуть адаптуватися до нових умов в реальному часі. Наприклад, застосування нейронних мереж або підсилених дерев дозволяє моделі пристосовуватися до змін в умовах експлуатації.

Симуляція є важливою у вивченні систем керування, оскільки дозволяє провести експерименти з моделями до їх реальної реалізації. За допомогою симуляції можна перевірити, як система буде поводитись у різних умовах, і виявити можливі недоліки. Симуляція також дозволяє виконати численні «що-якщо» аналізи. Метою симуляції є:

- оцінка поведінки системи, тобто, симуляція дає можливість зрозуміти, які параметри впливають на ефективність керування;
- перевірка коректності моделей. За допомогою симуляції можна перевірити, чи правильно побудована математична модель, чи коректно вона відображає реальні процеси;
- оптимізація процесів, а саме, симуляція дозволяє знаходити оптимальні стратегії керування, перевіряти їх ефективність і оптимізувати витрати ресурсів, наприклад, через мінімізацію енергоспоживання або збільшення терміну служби матеріалів;
- аналіз стійкості. За допомогою симуляцій можна провести аналіз стійкості керування та визначити, чи система витримає зміни в умовах навантаження без збоїв.

Для симуляції процесів керування часто використовуються спеціалізовані програмні інструменти, такі як STATISTICA, MATLAB тощо.

Після проведення симуляцій необхідно провести оцінку їх результатів. Це включає:

- аналіз точності, тобто, порівняння результатів симуляції з реальними даними для перевірки коректності моделей;
- перевірка на стійкість, а саме, оцінка того, чи система зберігає стабільність при зміні вхідних параметрів або зовнішніх умов;
- оцінка ефективності, зокрема, оцінка ефективності запропонованих стратегій керування для різних сценаріїв роботи системи.

Інтеграція моделювання та симуляції в процеси керування є важливою частиною розвитку автоматизованих систем. Зокрема, моделі машинного

навчання можуть інтегрують в процеси керування для адаптивного підлаштування параметрів у реальному часі. А також, використання симуляцій для розробки адаптивних стратегій керування, які можуть бути змінені в залежності від умов. Важливими є використання результатів симуляцій для автоматичного налаштування параметрів керування в реальному часі на основі отриманих прогнозів.

Отже, моделювання та симуляція процесів керування є важливими етапами в розробці та впровадженні ефективних систем автоматизованого керування. Вони дають змогу проаналізувати поведінку системи, оптимізувати процеси та передбачити можливі проблеми. Використання алгоритмів машинного навчання в поєднанні з моделями симуляції дозволяє розробити адаптивні та високопродуктивні стратегії

РОЗДІЛ 4. НАУКОВО-ДОСЛІДНА ЧАСТИНА

4.1 Використання експериментальних даних діаграм втомного руйнування алюмінієвого сплаву

Експериментальні дані діаграм втомного руйнування є важливими при аналізі та моделюванні процесів втомного руйнування матеріалів, зокрема алюмінієвих сплавів [13,14]. Втомне руйнування є важливим фактором для оцінки довговічності матеріалів і конструкцій, що піддаються циклічним навантаженням. Для оптимізації процесів автоматизованого керування, зокрема при прогнозуванні часу до втомного руйнування в конструкціях, часто використовуються ці діаграми.

Діаграма $S-N$ (напруга-кількість циклів) є найпоширенішою формою діаграми втомного руйнування. Вона відображає кількість циклів, які матеріал може витримати при заданій амплітуді напруження до виникнення руйнування. Зазвичай, така діаграма показує зворотну залежність між кількістю циклів і амплітудою напруження, тобто, чим більша амплітуда напруження, тим менша кількість циклів до руйнування.

Для отримання експериментальних даних ДВР алюмінієвих стопів роблять випробування з використанням циклічних навантажень, що можуть бути однотипними (симетричними) або мати змінну амплітуду. Загальна методологія виглядає так:

- вибір зразків, тобто, для експериментів беруть зразки певного виду алюмінієвого сплаву;
- визначення умов навантаження, зокрема, для кожного зразка визначають умови циклічного навантаження, наприклад, величину амплітуди напруження, частоту навантажень, середнє напруження тощо;

- випробування, а саме, зразки піддаються циклічним навантаженням в тестових машинах, таких як машини для випробування на втому з контрольованим навантаженням і частотою. Під час випробувань фіксується кількість циклів до руйнування зразка при кожному значенні амплітуди напруження;
- реєстрація результатів, загалом, після завершення випробувань відзначають час до руйнування зразка, кількість циклів, температуру, наявність макроскопічних дефектів на поверхні;
- побудова діаграм, тобто, на основі отриманих даних будується діаграма $S-N$. Для кожної амплітуди напруження визначається кількість циклів до руйнування. Відмічаються значення напружень та циклів, після чого проводиться апроксимація отриманих точок для побудови графіка.

Експериментальні дані діаграм втомного руйнування мають важливе значення для прогнозування часу до втомного руйнування в промислових системах, зокрема в контексті автоматизованого керування [15,16]. Прогнозування на основі експериментальних даних дозволяє точно передбачити кількість циклів навантаження, які матеріал витримає до руйнування при різних рівнях навантаження. А також, на основі експериментальних даних можна створити стратегії для зниження рівня напружень у матеріалах, що дозволяє продовжити їхній експлуатаційний ресурс. Зокрема, знання діаграм втомного руйнування дозволяє обчислювати, скільки циклів навантаження може витримати конструкція, що працює в умовах змінного навантаження. Для реальних промислових систем можуть бути розроблені автоматизовані системи прогнозування на основі вхідних параметрів, таких як величина циклічного навантаження, температурні коливання, час роботи.

Використання алгоритмів машинного навчання для обробки експериментальних даних дозволяє створити адаптивні моделі, які можуть передбачати втомне руйнування матеріалу з урахуванням більш складних і змінних умов. Наприклад, методи нейронних мереж можуть враховувати кілька

параметрів, таких як температура, вологість, види навантаження тощо, для більш точного прогнозування часу до руйнування. Важливим є те, що використання даних про втомне руйнування дозволяє автоматизувати моніторинг стану матеріалів у реальному часі в промислових системах. Це може бути здійснено за допомогою сенсорів, що фіксують зміни напруження і відправляють ці дані в систему керування, яка обчислює прогнозований ресурс матеріалу. Додатково, працюючи зі системами, які піддаються постійним механічним навантаженням (наприклад, роботизовані руки, що виконують цикл обробки), ці дані допомагають керувати станом роботів, прогнозуючи їхній ресурс і визначаючи час для технічного обслуговування. Інженери використовують ці дані для проектування конструкцій, що працюють в умовах втомного руйнування. Це включає вибір матеріалів, оптимізацію геометрії конструкцій для зменшення навантажень на критичних ділянках і визначення допустимих меж використання.

Загалом, експериментальні дані ДВР алюмінієвих сплавів є надзвичайно важливими для розробки систем прогнозування та оптимізації процесів в промислових системах. Вони дають змогу передбачити ресурси матеріалів і вчасно вжити заходів для запобігання їхньому руйнуванню. Інтеграція цих даних з алгоритмами машинного навчання і системами автоматизованого керування дозволяє значно підвищити точність прогнозів і ефективність роботи складних промислових систем.

4.2 Навчання моделей нейронних мереж, випадкових лісів, підсилених дерев, опорно-векторних машин і k -найближчих сусідів

Помилка! Закладку не визначено.

Навчання моделей машинного навчання є ключовим етапом при створенні ефективних систем для прогнозування та класифікації даних [17]. Існують три основні типи навчання моделей машинного навчання: навчання з учителем,

навчання без учителя та змішане навчання (рис.4.1). Кожен з цих методів має свої особливості, застосування та підходи до навчання.




Рисунок 4.1 – Основні типи навчання моделей машинного навчання

Навчання з учителем є найбільш поширеним типом машинного навчання. У цьому методі система тренується на даних, для яких відомі правильні виходи. Процес навчання складається із побудови моделі, яка передбачає зв'язок між вхідними ознаками і відповідними вихідними значеннями.

У навчанні з учителем надано велику кількість зразків даних, які мають відомі мітки або цільові значення. Наприклад, для задачі класифікації кожен зразок має свою категорію, а для задач регресії — числове значення. Алгоритм машинного навчання намагається знайти математичну модель, яка мінімізує відмінності між фактичними та передбаченими виходами для всіх зразків навчальної вибірки. Після навчання модель тестується на нових, невідомих даних, щоб перевірити її здатність правильно передбачати мітки на нових зразках.

Навчання без учителя використовується для аналізу даних, де мітки або цільові значення відсутні. Алгоритм намагається знайти структуру або шаблони в даних без будь-яких відомих відповідей. Основною метою є виявлення прихованих зв'язків у даних, групування схожих об'єктів або зниження розмірності.

У цьому типі навчання дані не містять еталонних виходів. Замість цього алгоритм шукає структуру вхідних даних, намагаючись класифікувати або групувати їх. Алгоритми без учителя, зазвичай, застосовуються для кластеризації або зниження розмірності. Вони можуть використовувати метрики схожості між об'єктами для групування даних в класи або для знаходження найбільш важливих ознак.


Змішане навчання є комбінованим методом, що поєднує елементи навчання з учителем та без учителя. У цьому випадку доступна обмежена кількість мічених даних, а також велика кількість немічених даних. Алгоритм використовує обидва типи даних для покращення навчання та підвищення точності моделі.

Навчання починається з обмеженого набору мічених даних, на яких створюється початкова модель. Потім модель застосовується до немічених даних для виявлення структури та класифікації. Часто використовуються методи кластеризації або інші алгоритми без учителя для генерації "штучних" міток, що допомагають удосконалити модель.


Загалом, навчання з учителем - це метод, коли є відомі мітки даних, і модель вчиться на основі цих міток для прогнозування або класифікації нових зразків. Тоді як навчання без учителя використовується для виявлення структур, шаблонів або груп в даних, коли немає міток або еталонних відповідей. Зокрема, змішане навчання поєднує обидва підходи, дозволяючи ефективно використовувати як мічені, так і немічені дані для покращення якості моделей.

Експериментальне дослідження є дуже складним та потребує значних фінансових і часових витрат. Тому важливо застосовувати чисельне моделювання [18,19]. Метою цього дослідження є прогнозування швидкості РВТ алюмінієвого стопу при різних значеннях коефіцієнта навантаження $R = 0,2; 0,4; 0,6$. Вирішується це за допомогою кількох методів машинного навчання без необхідності визначати аналітичні моделі процесу втоми та порівнювати їх результати [17,18].


Швидкість втомного руйнування була спрогнозована на основі експериментальних даних, отриманих у дослідженні [19] для різних значень $R = 0,2; 0,4; 0,6$. Вибірка складала 225 елементів, з яких 70% були випадковим чином вибрані для навчальної вибірки, а решта 30% використані для тестування (рис.4.2 та рис.4.3). Результати прогнозування виявились близькими до експериментальних. Найкращим методом є нейронний метод (похибка 2,7%). Зокрема, похибки інших методів: підсилених дерев - 9,9%, випадкових лісів - 9,2%, k -найближчих сусідів — 7,1%, тоді як опорно-векторних машин - 2,9%.




а)




б)



в)




г)




д)


Рисунок 4.2 – Швидкості РВТ, отримані методами НМ (а), ВТ (б), RF (в), SVM (г) та k -NN (д)




а)




б)



в)



г)




д)


Рисунок 4.3 – Прогнозовані та експериментальні швидкості РВТ від КІН отримані НМ (а), ВТ (б), RF (в), SVM (г) та k -NN (д)

Для прогнозування швидкості РВТ методом НМ було створено модель MLP 2-27-, з функцією активації - тангенціальною та логарифмічною функцією для вихідного шару. Коефіцієнт кореляції на тестовій вибірці склав 0,99. У ансамблевих методах використовувалось 200 дерев, в методі опорно-векторних машин застосовано 20 опорних векторів, тоді як в методі k -найближчих сусідів - евклідова відстань.

Залежність середньоквадратичної похибки від кількості дерев у методах підсилених дерев та випадкових лісах демонструє, як зміна числа дерев впливає на точність прогнозування (рис.4.4). Зазвичай, із збільшенням кількості дерев середньоквадратична похибка зменшується, оскільки більше дерев сприяють кращій генералізації моделі та знижують вплив шуму в даних. Однак після досягнення певної кількості дерев додаткові дерева можуть мати незначний або нульовий ефект на покращення результатів, а також можуть призвести до перевитрат ресурсів та часу на обчислення.



а)



б)

Рисунок 4.4 – Похибка, розрахована від кількості дерев, методами підсилених дерев (а) та випадкових лісів (б)

4.3 Оцінка точності алгоритмів машинного навчання

Оцінка точності алгоритмів машинного навчання для задач регресії є важливим етапом, оскільки вона дозволяє оцінити, наскільки точно модель прогнозує числові значення. У випадку регресії точність, зазвичай, вимірюється за допомогою спеціальних метрик, які враховують різницю між фактичними (спостережуваними) і прогнозованими значеннями:

- середньоквадратична похибка є однією з найбільш поширених метрик для оцінки точності моделей регресії. Вона вимірює середній квадрат різниці між фактичними значеннями та прогнозами моделі. Чим менше значення MSE, тим точніша модель;

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

де:

- y_i — фактичне значення для i -го спостереження,
- $\hat{y}_i$ — прогнозоване значення для i -го спостереження,
- n — кількість спостережень.

- середня абсолютна похибка є менш чутливою до викидів, оскільки вона вимірює середнє значення абсолютних різниць між фактичними та прогнозованими значеннями;

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

де:

- y_i — фактичне значення для i -го спостереження,
 - $\hat{y}_i$ — прогнозоване значення для i -го спостереження,
 - n — кількість спостережень.
- корінь середньоквадратичної похибки є квадратним коренем середньоквадратичної похибки (MSE). Ця метрика дозволяє зберегти одиниці вимірювання прогнозованих значень, що робить її більш інтерпретованою;

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

- коефіцієнт детермінації (R -squared, R^2) вимірює, яку частину варіації вихідних даних пояснює модель. Це показник того, наскільки добре модель пояснює дисперсію залежної змінної, порівняно з простою моделлю, яка передбачає середнє значення.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

де:

- y_i — фактичне значення для i -го спостереження,
- $\hat{y}_i$ — прогнозоване значення для i -го спостереження,
- $\bar{y}$ — середнє значення всіх фактичних значень.

Отже, оцінка точності алгоритмів машинного навчання для задач регресії передбачає використання різноманітних метрик, таких як середньоквадратична

похибка, середня абсолютна похибка, коефіцієнт детермінації (R^2), кореляція Пірсона та інші. Кожна з цих метрик має свої переваги і недоліки, тому вибір відповідної метрики залежить від специфіки задачі та типу даних. Перехресна валідація та аналіз залишків є важливими інструментами для оцінки стабільності та надійності моделі, що дозволяє отримати точні та інтерпретовані результати.

4.4 Порівняння результатів та вибір оптимального підходу машинного навчання

Порівняння результатів різних алгоритмів машинного навчання є важливою частиною процесу моделювання, оскільки дозволяє оцінити ефективність кожного методу в контексті конкретної задачі. У контексті прогнозування швидкості втомного руйнування або інших задач регресії [20], важливо порівняти різні моделі за допомогою числових метрик, які оцінюють точність, надійність і загальну продуктивність алгоритмів.

Після того як декілька моделей машинного навчання були застосовані до задачі, результати кожної моделі потрібно порівняти, щоб вибрати найкращу. Наприклад, якщо для прогнозування швидкості втомного руйнування використовується кілька алгоритмів, таких як нейронні мережі, випадкові ліси, підсилені дерева, опорно-векторні машини та метод k -найближчих сусідів, то результати будуть порівнюватися на основі точності прогнозування. Тобто, в задачі прогнозування швидкості втомного руйнування алюмінієвого сплаву на основі експериментальних даних, можна отримати наступні результати для різних моделей:

- нейронні мережі, похибка прогнозування становить 2,7%, що свідчить про високу точність, а коефіцієнт R^2 рівний 0,99;
- підсилені дерева, похибка прогнозування становить 9,9%, що вказує на відносно велику помилку в порівнянні з НМ, але все ж залишається досить конкурентоспроможною;

- випадкові ліси, похибка прогнозування 9,2%, що схоже до результатів підсилених дерев, але з дещо більшою стабільністю;
- опорно-векторні машини, похибка прогнозування 2,9%, що вказує на хорошу точність, але не настільки хороша, як у нейронних мережах;
- метод k -найближчих сусідів, похибка прогнозування становить 7,1%, що є середнім результатом серед усіх методів.

Після порівняння результатів потрібно вибрати оптимальну модель в залежності від критеріїв, що мають найбільше значення для конкретного застосування. Враховуючи результат порівняння, можна зробити наступні висновки:

- якщо точність прогнозування є головним критерієм, то нейронні мережі є оптимальним вибором, оскільки вони забезпечують найменшу похибку в прогнозах;
- якщо потрібна більш інтерпретована модель, наприклад, для пояснення результатів або подальшого аналізу, то дерево рішень або метод k -найближчих сусідів можуть бути кращими через свою простоту;
- якщо модель повинна бути стійкою до викидів і швидко працювати на великих даних, то метод випадкових лісів або підсилених дерев можуть бути кращими, оскільки вони зазвичай більш стійкі до викидів та забезпечують швидке прогнозування;
- у випадках, коли важливо досягти балансу між точністю та швидкістю, опорно-векторні машини можуть стати оптимальним вибором, оскільки вони є хорошими для задач з великими наборами даних, забезпечуючи високу точність без значних витрат часу на навчання.

Оптимальний вибір алгоритму машинного навчання залежить від специфіки задачі та критеріїв, що ставляться перед моделлю. Для досягнення найкращих результатів важливо провести ретельний аналіз різних моделей, враховуючи їх точність, стійкість до викидів, складність та ефективність. Збалансований підхід, який використовує кілька моделей або комбінує їх


результати, може допомогти досягти кращих результатів у задачах, таких як прогнозування швидкості втомного руйнування.

РОЗДІЛ 5. СПЕЦІАЛЬНА ЧАСТИНА

5.1 Особливості застосування нейронних мереж у промислових системах

Нейронні мережі є невід'ємною частиною сучасності завдяки своїй здатності вирішувати складні задачі, які важко піддаються традиційним підходам. Використання НМ у промисловості дозволяє підвищити точність прогнозування, автоматизувати процеси керування та значно покращити ефективність технологічних операцій. Тому, хід побудови методом нейронних мережа показано на рис. 5.1-5.9.

Отож, вибираємо *Data Mining*. Далі, для прогнозування вибираємо *Regression* як тип аналізу даних (рис. 5.2).



The screenshot shows the Minitab software interface. The 'Data Mining' menu is open, displaying options like 'Advanced Models', 'Neural Nets', 'Mult/Exploratory', 'PLS, PCA, ...', 'Power Analysis', and 'Variance'. Below the menu, a data table is visible with 10 columns and 20 rows. The columns are labeled: 1, 2, 3, 4, 5, 6, 7, 8, 9, 10. The rows are numbered 1 to 20. The data values are as follows:

	1	2	3	4	5	6	7	8	9	10
	Log10(K)	Log10(V)	R	Var4	Var5	Var6	Var7	Var8	Var9	Var10
1	0,3579	-9,27	0,2							
2	0,361	-10,451	0,2							
3	0,3673	-9,7496	0,2							
4	0,3754	-9,3354	0,2							
5	0,3945	-9,0057	0,2							
6	0,3972	-9,0209	0,2							
7	0,4242	-8,9355	0,2							
8	0,4346	-8,983	0,2							
9	0,4396	-8,6635	0,2							
10	0,493	-8,4962	0,2							
11	0,4953	-8,6556	0,2							
12	0,5201	-8,6216	0,2							
13	0,5222	-8,4789	0,2							
14	0,5534	-8,4828	0,2							
15	0,5933	-8,3799	0,2							
16	0,5942	-8,251	0,2							
17	0,5959	-8,4123	0,2							
18	0,5977	-8,5171	0,2							
19	0,5986	-8,5229	0,2							
20	0,6012	-8,301	0,2							

Рисунок 5.1 – База даних для прогнозування швидкості РВТ




Рисунок 5.2 – *Regression* як тип аналізу даних

Наприклад (рис. 5.3), обираючи *Variables*, вказуємо вихідну змінну (перший стовбець), тоді вибираємо вхідні змінні (другий стовбець). Далі переходимо до *Quick* (рис. 5.4).




Рисунок 5.3 – *Variables* для аналізу даних




Рисунок 5.4 – Для перевірки відповідних змінних *Quick*

У меню *Sampling* розділяємо дані на навчальну та тестову вибірки (рис. 5.5).




Рисунок 5.5 – Для розподілу на вибірки меню *Sampling*

Дані показано побудову мережі (рис. 5.6).




Рисунок 5.6 – Побудова мережі

Навчання нейронних мереж показано на рис. 5.7.




Рисунок 5.7 – Навчання нейронних мереж

Результати нейронних мереж зображено на рис. 5.8.




Рисунок 5.8 – Результати прогнозованих швидкостей РВТ методом нейронних мереж

Далі обирається модель, що найточніше прогнозує швидкість РВТ. Зокрема, у вікні *Graph*, будують залежності експериментальних даних від прогнозованих (рис.5.9).




Рисунок 5.9 – Меню *Graph* для побудови залежностей

Нейронні мережі є потужним інструментом для вирішення складних задач у промислових системах. Їх застосування дозволяє підвищити ефективність процесів, автоматизувати контроль і діагностику, а також значно знизити витрати на експериментальні дослідження. Проте для успішної інтеграції НМ важливо забезпечити якісні дані, потужне апаратне забезпечення та достатню кваліфікацію персоналу.

5.2 Застосування підсилених дерев та випадкових лісів для підвищення точності прогнозування

Методи підсилених дерев та випадкових лісів є популярними підходами у машинному навчанні, які ефективно використовуються для вирішення задач регресії та класифікації. Їх застосування у промислових системах, зокрема для прогнозування, дозволяє забезпечити високу точність результатів завдяки здатності моделювати складні взаємозв'язки між вхідними параметрами та вихідними характеристиками.

Побудову моделей методом підсилених дерев показано на рисунках 5.10-5.12. Тоді як алгоритм методу випадкових лісів є аналогічним. Отож, вибираємо *Data Mining / Boosted Trees*. Далі команду *Regression Analysis - Variables*. Зокрема, в *Advanced* вказуємо параметри моделі (рис. 5.10).

Вікно *Results* (рис. 5.11, а) застосовуємо для перегляду результатів моделювання. Далі показано результати у вигляді таблиць чи графіків (рис. 5.11, б). Після цього розраховується середньоквадратична похибка, як показано на рис. 5.10.






Рисунок 5.10 – *Advanced*, котре дозволяє вибрати параметри



а)



б)

Рисунок 5.11 – Результати аналізу прогнозування

РОЗДІЛ 6. ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ

6.1 Опис негативних впливів виробничого середовища

Під час роботи на виробництві на людину можуть впливати один або низка небезпечних та шкідливих виробничих факторів. Безпека того чи іншого технологічного процесу може бути визначена за їх кількістю і за ступенем небезпеки кожного з них зокрема. Безпека праці на виробництві визначається ступенем безпеки окремих технологічних процесів.

Небезпечні й шкідливі виробничі фактори стандартом ГОСТ 12.0.003-74 поділяються на фізичні, хімічні, біологічні й психофізіологічні. Останні за характером впливу на людину підрозділяються на фізичні й нервово-психічні перевантаження, а інші – на конкретні небезпечні й шкідливі виробничі фактори. В процесі роботи на підприємстві на працівника можуть впливати такі небезпечні й шкідливі виробничі фактори:

- машини, що рухаються, автотранспорт і механізми;
- рухомі незахищені елементи механізмів, машин і виробничого обладнання;
- падаючі вироби техніки, інструмент і матеріали під час роботи;
- ударна хвиля (вибух посудини, що працює під тиском пари рідини);
- струмені газів і рідин, що стікають із посудин і трубопроводів під тиском;
- підвищене ковзання (через зледеніння, зволоження й замаслювання поверхонь, по яких переміщується робочий персонал);
- підвищені запыленість й загазованість повітря;
- підвищена чи знижена температура поверхонь техніки, обладнання й матеріалів;
- підвищена чи знижена температура, вологість і рухомість повітря;

- підвищений рівень шуму, вібрації, ультра та інфразвуку;
- підвищена напруга в електричному ланцюзі, замикання якого може відбутися через тіло людини;
- підвищений рівень статичної електрики;
- гострі кромки, задирки й шорсткість на поверхнях обладнання й інструментів;
- відсутність чи нестача природного світла;
- недостатня освітленість робочої зони;
- знижена контрастність об'єктів в порівнянні з фоном;
- пряма блискість (прожекторне освітлення територій виробництв, світло фар автотранспорту) і відбита блискість (від розливої води й інших рідин на поверхні територій виробництв);
- підвищена пульсація світлового потоку;
- підвищений рівень ультрафіолетової й інфрачервоної радіації;
- хімічні речовини (токсичні, подразнюючі, сенсibiliзуючі, канцерогенні, мутагенні, що впливають на репродуктивну функцію людини);
- хімічні речовини, що проникають в організм через органи дихання, шлунково-кишковий тракт, шкірні покриви і слизові оболонки;
- патогенні мікроорганізми (бактерії, віруси, гриби, найпростіші) і продукти їхньої життєдіяльності;
- перевантаження (статичні й динамічні) і нервово-психічні чинники (емоційні перевантаження, перенапруга аналізаторів, розумова перенапруга, монотонність праці).

Рівні небезпечних і шкідливих виробничих факторів не повинні перевищувати граничнодопустимих значень, встановлених у санітарних нормах, правилах і нормативно-технічній документації.

6.2 Організація безпечної роботи з персональним комп'ютером

Під час роботи на комп'ютерах можуть діяти такі небезпечні та шкідливі фактори, як:

- фізичні;
- психофізіологічні.

Електробезпека при роботі.

Заходи щодо усунення небезпеки ураження електричним струмом зводяться до правильного розміщення устаткування та електричних кабелів. Інші заходи щодо забезпечення електробезпеки, збігаються з загальними заходами пожежо- та електробезпеки.

В якості профілактичних заходів для забезпечення пожежної безпеки слід використовувати скриту електромережу, надійні розетки з пожежобезпечних матеріалів, силові мережі живлення устаткування виконувати кабелями, розрахованими на підключення в 3-5 разів більшого навантаження, включати й виключати живлення обладнання за допомогою штатних вимикачів. Треба регулярно робити очистку внутрішніх частин комп'ютерів, іншого устаткування від пилу, розташовувати комп'ютери на окремих неспалюваних столах. Для запобігання іскріння необхідно рідше встромляти і виймати штепсельні вилки з розеток.

Освітлення.

Система освітлення повинна відповідати таким вимогам:

- освітленість на робочому місці повинна відповідати характеру зорової роботи, який визначається трьома параметрами: об'єктом розрізнення – найменшим розміром об'єкта, що розглядається на моніторі ПК; фоном, який характеризується коефіцієнтом відбиття; контрастом об'єкта і фону;
- необхідно забезпечити достатньо рівномірне розподілення яскравості на робочій поверхні монітора, а також в межах навколишнього простору;

- на робочій поверхні повинні бути відсутні різкі тіні;
- в полі зору не повинно бути відблиски (підвищеної яскравості поверхонь, які світяться та викликають осліплення);
- величина освітленості повинна бути постійною під час роботи;
- слід обирати оптимальну спрямованість світлового потоку і необхідний склад світла.

Вимоги до монітору.

Основним обладнанням робочого місця користувача комп'ютера є монітор, системний блок та клавіатура.

Робочі місця мають бути розташовані на відстані не менше 1,5 м від стіни з вікнами, від інших стін на відстані 1 м, між собою на відстані не менше 1,5 м. Відносно вікон робоче місце доцільно розташовувати таким чином, щоб природне світло падало на нього збоку, переважно зліва.

Робочі місця слід розташовувати так, щоб уникнути попадання в очі прямого світла. Джерела освітлення рекомендується розташовувати з обох боків екрану паралельно напрямку погляду. Для уникнення світлових відблисків екрану, клавіатури в напрямку очей користувача, від світильників загального освітлення або сонячних променів, необхідно використовувати антиполюскові сітки, спеціальні фільтри для екранів, захисні козирки, на вікнах – жалюзі.

Екран дисплея повинен бути розташованим перпендикулярно до напрямку погляду. Якщо він розташований під кутом, то стає причиною сутулості. Відстань від дисплея до очей повинна трохи перевищувати звичну відстань між книгою та очима. Перед екраном монітора, особливо старих типів, повинен бути спеціальний захисний екран. При його відсутності треба сидіти на відстані витягнутої руки від монітора.

Фільтри з металевої або нейлонової сітки використовувати не рекомендується, тому що сітка спотворює зображення через інтерференцію світла. Найкращу якість зображення забезпечують скляні поляризаційні фільтри.

Вони усувають практично усі відблиски, роблять зображення чітким і контрастним.

При роботі з текстовою інформацією (в режимі введення даних та редагування тексту, читання з екрану) найбільш фізіологічним правильним є зображення чорних знаків на світловому (чорному) фоні.

Монітор повинен бути розташований на робочому місці так, щоб поверхня екрана знаходилася в центрі поля зору на відстані 400-700 мм від очей користувача. Рекомендується розміщувати елементи робочого місця так, щоб витримувалася однакова відстань очей від екрана, клавіатури, тексту.

Робоча поза.

Зручна робоча поза при роботі з комп'ютером забезпечується регулюванням висоти робочого столу, крісла та підставки для ніг. Рациональною робочою позою може вважатися таке положення, при якому ступні працівника розташовані горизонтально на підлозі або підставці для ніг, стегна зорієнтовані у горизонтальній площині, верхні частини рук – вертикальній. Кут ліктьового суглоба коливається в межах 70-90°, зап'ястя зігнуті під кутом не більше ніж 20°, нахил голови 15-20°.

Важливою є форма спинки крісла, яка повинна повторювати форму спини. Висота крісла повинна бути такою, щоб користувач не відчував тиску на куприк або стегна. Крісло бажано обладнати бильцями. Його потрібно встановити так, щоб не треба було тягтися до клавіатури. Періодично користувачу необхідно рухатися, вчасно змінювати положення тіла і робити перерви у роботі.

При напруженій роботі за комп'ютером щогодини необхідно робити перерву на 15 хвилин через кожну годину і треба займатися іншою справою. Декілька разів на годину бажано виконувати серію легких вправ для розслаблення.

Для нейтралізації зарядів статичної електрики в приміщенні, де виконується робота на комп'ютерах, в тому числі на лазерних та світлодіодних принтерах, рекомендується збільшувати вологість повітря за допомогою

кімнатних зволожувачів. Не рекомендується носити одяг з синтетичних матеріалів.

Вимоги безпеки перед початком роботи:

- увімкнути систему кондиціювання в приміщенні;
- перевірити надійність встановлення апаратури на робочому столі.

Повернути монітор так, щоб було зручно дивитися на екран – під прямим кутом (а не збоку) і трохи зверху вниз, при цьому екран має бути трохи нахиленим, нижній його край ближче до оператора;

- перевірити загальний стан апаратури, перевірити справність електропроводки, з'єднувальних шнурів, штепсельних вилок, розеток, заземлення захисного екрана;

- відрегулювати освітленість робочого місця;
- відрегулювати та зафіксувати висоту крісла, зручний для користувача нахил його спинки;

- приєднати до системного блоку необхідну апаратуру. Усі кабелі, що з'єднують системний блок з іншими пристроями, слід вставляти та виймати при вимкненому комп'ютері;

- ввімкнути апаратуру комп'ютера вимикачами на корпусах в послідовності: монітор, системний блок, принтер (якщо передбачається друкування);

- відрегулювати яскравість свічення монітора, мінімальний розмір світної точки, фокусування, контрастність. Не слід робити зображення надто яскравим, щоб не втомлювати очей.

Вимоги безпеки під час виконання роботи:

- необхідно стійко розташовувати клавіатуру на робочому столі, не опускати її хитання. Під час роботи на клавіатурі сидіти прямо, не напружуватися;

- для забезпечення несприятливого впливу на користувача пристроїв типу «миша» належить забезпечувати вільну велику поверхню столу для переміщення «миші» і зручного упору ліктьового суглоба;
- не дозволяються посторонні розмови, подразнюючі шуми;
- періодично при вимкненому комп'ютері прибирати ледь змоченою мильним розчином бавовняною ганчіркою пил з поверхонь апаратури. Екрани ВДТ та захисний екран протирають ганчіркою, змоченою у спирті. Не дозволяється використовувати рідинні або аерозольні засоби очищення поверхонь комп'ютера.

Забороняється:

- класти будь-які предмети на апаратуру комп'ютера;
- закривати будь-чим вентиляційні отвори апаратури, що може призвести до її перегрівання і виходу з ладу.

ВИСНОВКИ

У магістерській роботі було проведено дослідження інтеграції алгоритмів МН для оптимізації процесів автоматизованого керування в промислових системах. Зокрема, застосовано методи нейронних мереж, підсилених дерев, випадкових лісів, опорно-векторних машин та методу k -найближчих сусідів для прогнозування швидкості РВТ алюмінієвого стопу. За результатами роботи можна зробити такі висновки:

- актуальність та доцільність використання машинного навчання у промислових системах, загалом, алгоритми машинного навчання значно підвищують точність прогнозування складних процесів, таких як втомне руйнування матеріалів. Це зменшує залежність від фізичних експериментів, які є дорогими та тривалими, забезпечуючи при цьому високу ефективність та надійність;
- ефективність алгоритмів, тобто, методи нейронних мереж, підсилених дерев, випадкових лісів, опорно-векторних машин та k -найближчих сусідів показали узгодженість між прогнозованими даними та експериментальними. Найвищу точність забезпечили нейронні мережі, тоді як опорно-векторні машини також показали добрий результат. Методи підсилених дерев, випадкових лісів та k -найближчих сусідів показали високу, але трохи нижчу точність, що вказує на їхню придатність для широкого спектра задач;
- переваги інтеграції машинного навчання у промислові системи, зокрема, інтеграція алгоритмів машинного навчання у промислові системи дозволяє автоматизувати процеси контролю та прогнозування, зокрема у задачах оцінки залишкового ресурсу конструкцій. Це знижує ризик аварій та підвищує безпеку експлуатації, особливо для матеріалів і конструкцій, які працюють у критичних умовах;

- моделювання даних та побудова бази знань, а саме, у роботі розроблено базу даних, що включає результати експериментальних досліджень з втомного руйнування алюмінієвого сплаву при різних значеннях коефіцієнта інтенсивності напружень.;
- порівняння алгоритмів та вибір оптимального підходу, загалом, результати порівняння алгоритмів показали, що оптимальним методом для задач прогнозування є нейронні мережі завдяки їх здатності моделювати складні нелінійні залежності. Проте, методи підсилених дерев і випадкових лісів мають переваги у задачах, де важливими є швидкість навчання та можливість інтерпретації моделі;
- розробка автоматизованої системи, зокрема, у роботі спроектовано архітектуру автоматизованої системи прогнозування, що включає алгоритми машинного навчання. Використання сучасного апаратного забезпечення у поєднанні з програмою STATISTICA забезпечило високу продуктивність і точність моделювання;
- тестування та впровадження, тобто, тестування системи підтвердило її працездатність та надійність. Результати моделювання показали, що розроблена система може бути інтегрована у реальні промислові процеси для задач моніторингу та прогнозування.

Робота підтвердила ефективність і доцільність застосування алгоритмів МН для вирішення складних промислових задач, зокрема прогнозування процесів втомного руйнування матеріалів.

ПЕРЕЛІК ДЖЕРЕЛ

1. Frank D. Petruzella. Programmable Logic Controllers, Published by McGraw-Hill Education, 2 Penn Plaza, New York, NY 10121. Copyright © 2017 by McGraw-Hill
2. Nise, Norman S. Control systems engineering / Norman S. Nise, California State Polytechnic University, Pomona. —Seventh edition.
3. McCrady S. G. Designing SCADA application software: A practical approach – Amsterdam, Singapore: Elsevier Science, 2013, 227 pages.
4. Haykin, S., 2009 “Neural Networks and Learning Machines”, Third Edition, McMaster University, Hamilton, Ontario, Canada, 938 p.
5. Шаховська Н.Б., Камінський Р.М., Вовк О.Б. Системи штучного інтелекту: навч. посібник. Львів: Видавництво Львівської політехніки, 2018. 392 p.
6. Alpayndin E. Introduction to Machine Learning // The Knowledge Engineering Review. 2010. Vol. 25, № 3. P. 353–353.
7. Mitchell T.M. Machine learning. London: McGraw-Hill Science/Engineering/Math, 1997.
8. Wasserman Ph.D. Neural Computing: Theory and Practice. New York: Coriolis Group (Sd), 1989.
9. Smola A., Vishwanathan S.V.N. Introduction to Machine Learning. Cambridge University Press, 2010.
10. Kuna M. Finite Elements in Fracture Mechanics: Theory-Numerics-Applications. Springer, 2013. 446 p.
11. Варфоломеев І.В., Ясній.О.П. Моделювання руйнування імовірнісними методами елементів конструкцій з тріщинами // Фіз.-хім. механіка матеріалів. 2008. Vol. 44, № 1. P. 76–83.
12. Ясній О.П., Собчак.А.Р., Ясній В.П. Оцінювання ймовірності руйнування колектора пароперегрівника // Фіз.-хім. механіка матеріалів. 2014. Vol. 50, № 3. P. 63–68.

13. Paris P.C. The growth of fatigue cracks due to variations in load : Ph.D.Thesis. Lehigh University, 1962. 263 p.
14. Pidaparti R.M.V., Palakal M.J. Neural network approach to fatigue-crack-growth predictions under aircraft spectrum loadings // J Aircr. 1995. Vol. 32, № 4. P. 825–831.
15. Mohanty J.R. et al. Application of artificial neural network for predicting fatigue crack propagation life of aluminum alloys // Archives of Computational Materials Science and Surface Engineering. 2009. Vol. 1, № 3. P. 133–138.
16. O. Yasniy, I. Didych, Yu. Lapusta: Prediction of fatigue crack growth diagrams by methods of machine learning under constant amplitude loading, Acta Metallurgica Slovaca, 26(1), 2020, 31 - 33.
17. Yasniy, O., Mytnyk, M., Maruschak, P., Mykytyshyn, A., & Didych, I., 2024 “Machine learning methods as applied to modelling thermal conductivity of epoxy-based composites with different fillers for aircraft,” Aviation, 28(2), pp. 64-71.
18. Ясній О.П. et al. Прогнозування діаграм втомного руйнування алюмінієвого сплаву Д16Т методами машинного навчання // Фізико-хімічна механіка матеріалів. 2018. Vol. 54, № 3. P. 43–48.
19. Ясній П., Пиндус Ю., Фостик В. Вплив асиметрії циклу навантаження на характеристики циклічної тріщиностійкості алюмінієвого сплаву Д16Т // Вісник Тернопільськ. держ. техн. ун-ту. 2007. Vol. 12, № 1. P. 7–12.
20. Didych I. et al. Evaluation of structural elements lifetime by neural network // Acta Metallurgica Slovaca. 2018. Vol. 24, № 1. P. 82–87.

ДОДАТКИ

Тези конференцій

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
Тернопільський національний технічний університет імені Івана Пулюя (Україна)
Університет імені П'єра і Марії Кюрі (Франція)
Маріборський університет (Словенія)
Технічний університет у Кошице (Словаччина)
Вільнюський технічний університет ім. Гедимінаса (Литва)
Міжнародний університет цивільної авіації (Марокко)
Наукове товариство ім. Т.Шевченка

**АКТУАЛЬНІ ЗАДАЧІ
СУЧАСНИХ ТЕХНОЛОГІЙ**

Збірник
тез доповідей

**XII Міжнародної науково-практичної
конференції молодих учених та студентів**
6-7 грудня 2023 року



УКРАЇНА
ТЕРНОПІЛЬ – 2023

12. **М.А. Гловин; І.В. Костецький**
ВПЛИВ ВІДПАЛУ НА ТРИБОТЕХНІЧНІ ВЛАСТИВОСТІ ЕВТЕКТИЧНОГО ЕЛЕКТРОІСКРОВОГО ПОКРИТТЯ
13. **А. Г. Микитишин, І. С. Дідич, Р. І. Яцишин**
ЗАСТОСУВАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ КЛАСИФІКАЦІЇ ДАНИХ В КОМП'ЮТЕРИЗОВАНИХ СИСТЕМАХ КЕРУВАННЯ
14. **І. С. Дідич, А. Г. Микитишин, Р. З. Золотий, П. А. Ясіновський**
ІНТЕГРАЦІЯ АЛГОРИТМІВ МАШИННОГО НАВЧАННЯ ДЛЯ ОПТИМІЗАЦІЇ ПРОЦЕС
15. **І. В. Коваль; В. П. Цимбровський**
ДОСЛІДЖЕННЯ УТЕПЛЮВАЧІВ ФАСАДІВ ДЛЯ БАГАТОПОВЕРХОВОГО ЖИТЛОВОГО БУДИНКУ
16. **В.О. Бойчук**
ДОСЛІДЖЕННЯ ПЕРСПЕКТИВ ЗАСТОСУВАННЯ ГРАФЕНОВИХ ТРАНЗИСТОРІВ У НАНОЕЛЕКТРОНІЦІ
17. **Невожай В.А., Пошивак М.Т., Кравець С.В., Микулик Д.П.**
АВТОМАТИЗОВАНА СИСТЕМИ ОЧИЩЕННЯ ТЕХНОЛОГІЧНОЇ ВОДИ НА ТЕПЛОВИХ ЕЛЕКТРОСТАНЦІЯХ
18. **М. А. Созанський; Р. Р. Гумінілович; В. Є. Стаднік; М. В. Шепіда; О. В. Клапчук; П.Й. Шаповал**
ДОСЛІДЖЕННЯ ОПТИЧНИХ ВЛАСТИВОСТЕЙ ХІМІЧНО СИНТЕЗОВАНИХ ПЛІВОК КАДМІЙ СУЛЬФІДУ-СЕЛЕНІДУ
19. **Р.В. Теслюк; Н.З. Биків**
ПЕРЕВАГИ ЗАСТОСУВАННЯ СПЛАВІВ З ПАМ'ЯТТЮ ФОРМИ В БУДІВЕЛЬНИХ КОНСТРУКЦІЯХ
20. **М.І. Гудь; М.З. Попович**
ДОСЛІДЖЕННЯ ОПТИМАЛЬНИХ ПАРАМЕТРІВ ЗАЛІЗОБЕТОННИХ КОНСТРУКЦІЙ СПОРУД ПОДВІЙНОГО ПРИЗНАЧЕННЯ
21. **Д.Я. Баран; І.В. Габрик; С.В. Криницький; Г.Р. Гавришак**
КОНСТРУКТИВНІ РІШЕННЯ ПРОСТОРОВИХ КАРКАСІВ ГРОМАДСЬКИХ СПОРУД
22. **М.І. Гудь; П.В. Гиря**
ВЛАСТИВОСТІ ПОЛІМЕРБЕТОНІВ
23. **М.І. Гудь; О.М. Юркевич**
БЕТОНИ НА ОСНОВІ ЕПОКСИДНИХ СМОЛ
24. **Л.Г. Бодрова; О.В. Поліщук; Ю.Ю. Данилевич**
КОНСТРУКТИВНІ РІШЕННЯ ВЕЛИКОПРОЛІТНИХ КОНСОЛЕЙ
25. **В.Б. Ігнатєва; В.О. Паньків; В.М. Тимкович; С.В. Синюк; Ю.В. Сокотов**
ВЕЛИКОПРОЛІТНІ АРОЧНІ КОНСТРУКЦІЇ ПОКРИТТЯ
26. **М.І. Гудь; Р.А. Бойко; С.В. Кравчук**
КОНСТРУКТИВНІ РІШЕННЯ ПЕРЕКРИТТЯ ВИСОТНИХ ГРОМАДСЬКИХ СПОРУД
27. **Г.М. Крамар; Р.Я. Васирик; К.В. Клименко**
ПРОСТОРОВІ ВЕЛИКОПРОЛІТНІ ПОКРИТТЯ
28. **Г.М. Крамар; М.І. Гудь; Н.А. Яржемський**
РОБОТА ПРОСТОРОВОЇ КОНСОЛЬНОЇ ФЕРМИ
29. **Я.Л. Швед; В.Р. Поліщук; В.В. Мардинавка**

УДК 539.42, 004.032.26,

І. С. Дідич, доктор філософії, А. Г. Микитишин, канд. техн. наук, доцент,

Р. З. Золотий, канд. техн. наук, доцент, П. А. Ясіновський

Тернопільський національний технічний університет імені Івана Пулюя, Україна.

ІНТЕГРАЦІЯ АЛГОРИТМІВ МАШИННОГО НАВЧАННЯ ДЛЯ ОПТИМІЗАЦІЇ ПРОЦЕСІВ АВТОМАТИЗОВАНОГО КЕРУВАННЯ

I. S. Didych, Ph.D., A. H. Mykytyshyn., Ph.D., Assoc. Prof., R. Z. Zoloty, Ph.D., Assoc. Prof., P. A. Yasinovskyi

INTEGRATION OF MACHINE LEARNING ALGORITHMS FOR OPTIMIZING AUTOMATED CONTROL PROCESSES

Автоматизація промислових систем є важливим елементом сучасного виробництва, що дозволяє забезпечити підвищення ефективності, точності та стабільності процесів. Промислові системи охоплюють широкий спектр галузей, зокрема, машинобудування, авіацію, енергетику, будівництво. Інтеграція алгоритмів машинного навчання у ці системи відкриває нові можливості для аналізу великих обсягів даних, прогнозування стану обладнання та прийняття рішень у реальному часі. Тому застосування методів машинного навчання, зокрема, нейронних мереж, випадкових лісів, підсилених дерев, опорно-векторних машин та k -найближчих сусідів, є важливим для прогнозування залишкового ресурсу матеріалів та оцінки їх довговічності [1-2].

Нейронна мережа (НМ) - це обчислювальна модель, котра імітує роботу мозку людини, зокрема, процеси навчання та обробки інформації. НМ складається із штучних нейронів, організованих у шари, які працюють разом для виконання різноманітних задач, таких як розпізнавання образів, класифікація, прогнозування та інші [3]. Зокрема, кожен нейрон виконує просту математичну операцію, тобто, отримує входні дані, обробляє їх, застосовує функцію активації та передає результат далі. Модель штучного нейрона показано на рис. 1.



Рисунок 1. Модель штучного нейрона [3]

Основні типи функцій активації зображено на рис. 2.




Рисунок 2. Функції активації нейронів (а) порогова, (б) сигмоїдна, (в) гіперболічний тангенс [3]

Відомо, що перевагами НМ є здатність автоматично знаходити складні залежності в даних без необхідності вказувати чіткі правила. Зокрема, НМ навчаються на великих обсягах даних, що підвищує точність і універсальність.

Алгоритм випадкових лісів є ансамблевим методом машинного навчання, котрий комбінує багато рішень різних дерев рішень для покращення точності прогнозування. Зокрема, алгоритм генерує безліч дерев рішень, кожне з яких навчається на випадковій підмножині даних. Кожне дерево використовує підмножину ознак, вибраних випадково. Тоді як в методі підсилених дерев моделі створюються послідовно, і кожна нова модель намагається виправити помилки попередньої. Тому, перша модель, тобто, дерево рішень, створюється для прогнозування цільових значень, а наступні моделі для корекції помилок попередніх шляхом прогнозування залишкових значень. Загалом, алгоритм усереднює результати їх передбачень.

Основна ідея методу опорно-векторних машин полягає в пошуку оптимальної гіперплощини, яка розділяє дані на класи з максимально можливою відстанню між ними. Завдяки правильному вибору параметрів методу вдається досягти високої точності прогнозування. Метод k -найближчих сусідів є простим, але ефективним підходом машинного навчання, який класифікує нову точку даних на основі класів її найближчих сусідів у просторі ознак [4].

Втомне руйнування є поступовим пошкодженням матеріалів під впливом циклічного навантаження. Для розв'язування задач механіки, зокрема, прогнозування діаграм втомного руйнування для оцінки залишкового ресурсу, скористались експериментальними даними для алюмінієвого сплаву Д16Т [5]. Результати, зазначені у працях [2,6] показують, що методами машинного навчання можна достатньо точно оцінювати поведінку втомної тріщини. Загалом, отримані результати добре узгоджуються з експериментальними даними.

Інтеграція алгоритмів машинного навчання в автоматизовані системи керування дозволяє забезпечити ефективне використання промислових ресурсів і мінімізувати людський фактор. Застосування різних методів (нейронних мереж, випадкових лісів, підсилених дерев, опорно-векторних машин і k -найближчих сусідів) створює можливості для точного керування процесами, що відповідає потребам сучасної промисловості.

Література

1. Mohanty, J. R., Verma, B. B., Parhi, D. R. K., Ray, D. R., 2009 "Application of artificial neural network for predicting fatigue crack propagation life of aluminum alloys," *Archives of Computational Mat. Sci. and Sur. Eng.*, 1(3), pp. 133-138.
2. O. Yasniy, I. Didych, Yu. Lapusta: Prediction of fatigue crack growth diagrams by methods of machine learning under constant amplitude loading, *Acta Metallurgica Slovaca*, 26(1), 2020, 31 –33.
3. Haykin, S., 2009 "Neural Networks and Learning Machines", Third Edition, McMaster University, Hamilton, Ontario, Canada, 938 p.
4. Smola, A., & Vishwanathan, S. V. N., 2010. *Introduction to Machine Learning*. Cambridge University Press.
5. Ясній П. Вплив асиметрії циклу навантаження на характеристики циклічної тріщиностійкості алюмінієвого сплаву Д16Т / П. Ясній, Ю. Пиндус, В. Фостик // Вісник Тернопільського державного технічного університету. – 2007 – Т.12, №1. – С.7–12.
6. Yasniy, O., Mytnyk, M., Maruschak, P., Mykytyshyn, A., & Didych, I., 2024 "Machine learning methods as applied to modelling thermal conductivity of epoxy-based composites with different fillers for aircraft," *Aviation*, 28(2), pp. 64-71.