

КВАЛІФІКАЦІЙНА РОБОТА

на здобуття освітнього ступеня

бакалавр

(назва освітнього ступеня)

на тему: **Математичне моделювання експлуатаційних характеристик матеріалів на основі алюмінію методами машинного навчання**

Виконав: студент 4 курсу, групи КТс-41

спеціальності 151 – Автоматизація та комп'ютерно-

інтегровані технології

(шифр і назва спеціальності)

Заваринський О.І.
(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 Козбур І.Р.
(підпис) (прізвище та ініціали)

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)

« 17 » травня 2024 р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

на здобуття освітнього ступеня бакалавр
(назва освітнього ступеня)

за спеціальністю 151 – «Автоматизація та комп'ютерно-інтегровані технології»
(шифр і назва спеціальності)

студенту Заваринському Олегу Івановичу
(прізвище, ім'я, по батькові)

1. Тема роботи Математичне моделювання експлуатаційних характеристик матеріалів на основі алюмінію методами машинного навчання

Керівник роботи Дідич Ірина Степанівна, доктор філософії

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

Затверджені наказом ректора від « 17 » травня 2024 року № 4/7-515

2. Термін подання студентом завершеної роботи 23.06.2024 р.

3. Вихідні дані до роботи Регресійні методи прогнозування, критерії їх оцінки, нейронні мережі, підсилені дерева, випадкові ліси, датасет

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

1. Аналітична частина.

2. Проектна частина.

3. Спеціальна частина.

4. Безпека життєдіяльності, основи охорони праці.

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. Втомне руйнування. 9. ДВР.

10. Процес збору, обробки та підготовки даних для моделювання.

11-16. Отримані результати моделювання швидкості РВТ методами МН. 17. Висновки

6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
<i>Безпека життєдіяльності, основи охорони праці</i>	<i>кандидат технічних наук, доцент кафедри МТ Сенчишин В. С.</i>		

7. Дата видачі завдання 17 травня 2024 р.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1.	<i>Аналіз втомного руйнування елементів конструкцій</i>	<i>3.06.2024</i>	<i>Виконано</i>
2.	<i>Постановка задачі моделювання швидкості РВТ</i>	<i>4.06.2024</i>	<i>Виконано</i>
3.	<i>Вибір методів машинного навчання для дослідження швидкості РВТ</i>	<i>5.06.2024</i>	<i>Виконано</i>
5.	<i>Метод нейронних мереж, підсилених дерев, випадкових лісів</i>	<i>7.06.2024</i>	<i>Виконано</i>
6.	<i>Розробка програмного забезпечення для моделювання РВТ</i>	<i>10.06.2024</i>	<i>Виконано</i>
7.	<i>Спеціальна частина</i>	<i>14.06.2024</i>	<i>Виконано</i>
8.	<i>Безпека життєдіяльності, основи охорони праці</i>	<i>15.06.2024</i>	<i>Виконано</i>
9.	<i>Оформлення графічної частини</i>	<i>18.06.2024</i>	<i>Виконано</i>
10.	<i>Захист кваліфікаційної роботи</i>	<i>26.06.2024</i>	<i>Виконано</i>

Студент

_____ (підпис)

Заваринський О.І.

_____ (прізвище та ініціали)

Керівник роботи

_____ (підпис)

Дідич І.С.

_____ (прізвище та ініціали)

АНОТАЦІЯ

У даній кваліфікаційній роботі проаналізовано питання математичного моделювання експлуатаційних характеристик матеріалів на основі алюмінію методами машинного навчання. Метою дослідження є моделювання швидкості РВТ методами МН, зокрема, НМ, випадковими лісами та підсиленими деревами. Застосування штучного інтелекту до прогнозування швидкості РВТ дозволяє отримати точні результати прогнозування та покращити процеси проектування та самого виробництва.

Проведено аналіз існуючих методів для моделювання експлуатаційних характеристик матеріалів на основі алюмінію, вибрано та обґрунтовано методи МН, котрі найточніше моделюють властивості алюмінієвих сплавів.

Проаналізувавши методи МН та застосувавши їх на практиці, отримано досить високі результати моделювання і проведено порівняння з експериментальними даними.

Загалом, програмний пакет STATISTICA дозволяє ефективно реалізувати та автоматизувати процеси МН, забезпечуючи високу точність та надійність моделей.

Ключові слова: штучний інтелект, машинне навчання, нейронні мережі, підсилені дерева, випадкові ліси.

ПЕРЕЛІК СКОРОЧЕНЬ І ТЕРМІНІВ

ДВР – діаграма втомного руйнування;

РВТ – ріст втомної тріщини;

НДС – напружено-деформований стан;

КІН – коефіцієнт інтенсивності напружень;

R – асиметрія циклу навантаження;

МН – машинне навчання;

НМ – нейронні мережі;

ВТ – підсилені дерева;

RF – випадкові ліси;

ЗМІСТ

ВСТУП.....	6
РОЗДІЛ 1. АНАЛІТИЧНА ЧАСТИНА.....	8
1.1 Аналіз втомного руйнування елементів конструкцій.....	8
1.2 Найпоширеніші рівняння для опису швидкості РВТ.....	11
РОЗДІЛ 2. ПРОЕКТНА ЧАСТИНА.....	16
2.1 Постановка задачі моделювання швидкості РВТ	16
2.2 Вибір методів машинного навчання для дослідження швидкості РВТ.....	16
2.3 Алгоритм НМ.....	20
2.4 Процес начання НМ	24
2.5 Метод підсилених дерев	28
2.6 Метод випадкових лісів	31
2.7 Підготовка даних до моделювання.....	33
2.8 Розробка програмного забезпечення для моделювання РВТ.....	36
РОЗДІЛ 3. СПЕЦІАЛЬНА ЧАСТИНА	46
3.1 Аналіз результатів прогнозування швидкості РВТ алюмінієвого сплаву Д16Т.....	46
3.2 Порівняння результатів з експериментальними даними	51
РОЗДІЛ 4. БЕЗПЕКА ЖИТТЄДІЯЛЬНОСТІ, ОСНОВИ ОХОРОНИ ПРАЦІ	53
4.1 Характеристика шкідливих факторів виробничого середовища	53
4.2 Забезпечення безпеки життєдіяльності при роботі з ПК.....	55
ВИСНОВКИ.....	60
ПЕРЕЛІК ПОСИЛАНЬ	61

ВСТУП

Алюмінієві сплави є актуальними матеріалами в сучасній промисловості завдячуючи своїм властивостям, таким як легкість, висока міцність, корозійна стійкість і хороша теплопровідність. Для забезпечення надійності та ефективності їх застосування необхідно досліджувати експлуатаційні характеристики цих сплавів. Відомо, що конструкційні елементи часто втрачають свою міцність через втому матеріалу, котрий поступово накопичує пошкодження під дією циклічних навантажень. Це критично у таких галузях, як авіабудування, машинобудування та металургія, де безпека і надійність конструкцій є пріоритетом. Тому своєчасне виявлення та вирішення проблем, котрі пов'язані з втомою матеріалу, зокрема, прогнозування експлуатаційних характеристик матеріалів на основі алюмінію, є важливим.

Сучасні технології мають можливість синхронізувати результати моделювання з комп'ютерно-інтегрованими системами, що забезпечує автоматизацію процесів та прийняття рішень. Це сприяє оптимізації механічних систем з досить високою точністю. Збільшення обсягів даних, котрі є пов'язаними з втомою матеріалів, сприяє частому застосуванню штучного інтелекту у цій сфері. Загалом, за наявності великої кількості експериментальних даних, доцільно обирати методи машинного навчання для прогнозування.

Такі методи машинного навчання, як нейронні мережі, підсилені дерева та випадкові ліси ефективно використовують для дослідження і прогнозування експлуатаційних характеристик матеріалів на основі алюмінію. Дані методи дозволяють покращити точність прогнозів, котрі стосуються надійності конструкційних елементів, що, у свою чергу, підвищує їх безпеку та ефективність у практичному застосуванні.

Отже, рекомендовано моделі, які можуть враховувати широкий спектр факторів і дозволяють отримувати високоточні результати прогнозування. Загалом, проведено дослідження різними алгоритмами машинного навчання, котре дозволяє обґрунтовано обрати найефективніші методи МН для вибраної задачі.

Практична цінність кваліфікаційної роботи полягає в можливості застосування моделей МН для прогнозування експлуатаційних характеристик алюмінієвих сплавів у справжніх виробничих умовах. Це дозволить зменшити витрати на експериментальні дослідження, а також, оптимізувати процеси проектування та виробництва та підвищити якість кінцевої продукції. Результати дослідження можуть бути впроваджені у виробництво, котре використовує алюмінієві сплави, зокрема, у науково-дослідні інститути для вдосконалення методів прогнозування та дослідження матеріалів.

Метою дослідження є прогнозування експлуатаційних характеристик матеріалів методами машинного навчання, зокрема, нейронними мережами, випадковими лісами та підсиленими деревами. Для досягнення цієї мети необхідно вирішити такі задачі як: проаналізувати літературу втомного руйнування матеріалів, обґрунтувати вибір методів машинного навчання, які підходять для розв'язання поставленої задачі, зібрати і підготувати дані, необхідні для навчання моделей, створити і натренувати моделі МН для прогнозування втомних характеристик матеріалів, провести верифікацію та валідацію отриманих моделей для оцінки їх точності і надійності та проаналізувати результати і порівняти їх з експериментальними даними.

Об'єкт дослідження – матеріали на основі алюмінію, зокрема їх експлуатаційні характеристики.

Предмет дослідження – алгоритмів машинного навчання для моделювання втомних характеристик алюмінієвих сплавів.

РОЗДІЛ 1. АНАЛІТИЧНА ЧАСТИНА

1.1 Аналіз втомного руйнування елементів конструкцій

Втомне руйнування є процесом поступового накопичення пошкоджень у матеріалі під впливом циклічних навантажень, що зрештою призводить до його руйнування. Алюмінієві сплави, котрі широко використовуювані в авіації, автомобілебудуванні, будівництві та інших галузях, також піддаються втомному руйнуванню. Основними причинами втомного руйнування алюмінієвих сплавів є:

- циклічні навантаження. Зокрема, постійний вплив змінних навантажень призводить до утворення мікротріщин, які поступово збільшуються з кожним циклом;
- корозія, зокрема, вплив агресивного середовища може прискорити процес втомного руйнування;
- структурні дефекти. Тобто, наявність внутрішніх дефектів, таких як пори або включення, може стати місцем зародження тріщин;
- температурні коливання. Часті зміни температури можуть сприяти термічному розширенню та стисненню матеріалу, що сприяє розвитку тріщин.

Відомо, що тріщини можуть зароджуватися на поверхні або всередині матеріалу в місцях концентрації напружень. Найбільш поширені місця ініціації - поверхневі дефекти, зварні шви, різьбові з'єднання та інші області з підвищеною концентрацією напружень. Зокрема, тріщини поступово збільшуються під дією циклічних навантажень та темп розвитку тріщин залежить від амплітуди та частоти навантажень, властивостей матеріалу, температури та корозійного середовища. Загалом, коли тріщина досягає критичного розміру, конструкційний елемент руйнується під дією чергового циклу навантаження. Кінцеве руйнування зазвичай відбувається раптово і може призвести до катастрофічних наслідків.

Аварія, причиною якої став втомний ріст тріщини в колесі, сталася в 1998 році під Ешеде [1], в результаті якої загинула 101 людина. Катастрофа завдала колосальних збитків, що призвело до детального вивчення процесів втоми і накопичення пошкоджень в матеріалах при циклічному навантаженні (рис. 1).



Рис. 1.1 – Залізнична аварія внаслідок розриву обода колеса [1]

Найпоширенішими методами запобігання втомному руйнуванню є:

- покращення якості матеріалу: використання високоякісних алюмінієвих сплавів з мінімальним вмістом домішок та дефектів;
- контроль циклічних навантажень: оптимізація конструкцій для зменшення концентрації напружень та використання методів зниження амплітуди циклічних навантажень.
- захист від корозії: а саме, нанесення захисних покриттів та використання антикорозійних засобів.
- регулярне обслуговування та інспекція: зокрема, проведення регулярних оглядів та моніторинг стану конструкцій та використання неруйнівних методів контролю для виявлення тріщин на ранніх стадіях.

Згідно з літературними джерелами [1] наведено приклад поширення РВТ при змішаному навантаженні, тобто обрано випробування на згин при зсуві. Початкова тріщина довжиною 6 мм розташована на верхньому краю зразка на

відстані $b = 30$ мм від отвору. Зразок затискають з лівого боку і прикладають до отвору циклічну силу (нульовий натяг) з величиною, що знаходиться вище порогового значення втоми, так, щоб тріщина росла.

На рис. 1.2 показано грубу початкову сітку для моделювання та три етапи поширення тріщини з автоматичним адаптивним уточненням сітки. У цьому випадку розширення тріщини задається з постійним кроком $a = 3$ мм.

Таким чином, реальна криволінійна траєкторія тріщини може бути відтворена лише приблизно, але це можна покращити, використовуючи менші кроки a .

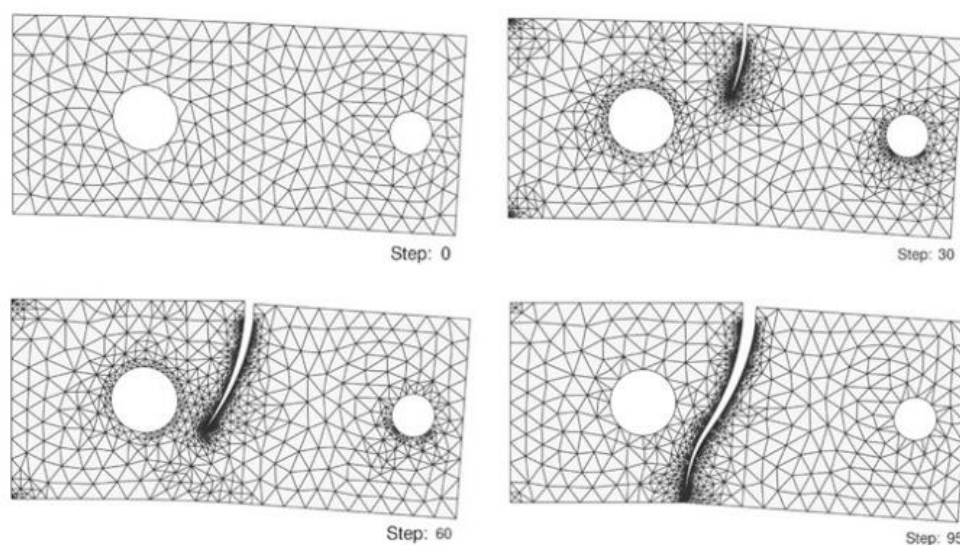


Рисунок 1.2 – Моделювання поширення тріщини у зразку, що згинається під дією зсувної сили [1]

Використання методів МН для прогнозування втомного руйнування алюмінієвих сплавів дозволяє підвищити надійність та безпеку конструкцій, зменшити витрати на технічне обслуговування та запобігти аварійним ситуаціям.

Важливим є такі етапи застосування методів МН для прогнозування втомного руйнування:

- збір та аналіз даних. Зокрема, використання великих обсягів даних про експлуатаційні характеристики, умови навантаження, корозію та інші фактори для навчання моделей;

- розробка моделей МН. Тобто, застосування алгоритмів МН, таких як НМ, випадкові ліси, метод опорних векторів, для прогнозування втомного руйнування;
- інтеграція з автоматизованими системами моніторингу. Зокрема, застосування моделей МН у системах реального часу для постійного моніторингу стану конструкцій, а також автоматизація процесів прийняття рішень щодо технічного обслуговування та ремонту.

1.2 Найпоширеніші рівняння для опису швидкості РВТ

Довговічність критично важливих елементів конструкцій, які зазнають впливу втомних навантажень, визначається періодом росту макротріщини, тобто, від її зародження до досягнення критичного розміру, при якому відбувається руйнування. Цей процес зазвичай представлений у вигляді графічної залежності, відомої як ДВР, котра є ключовим інструментом для оцінки циклічної тріщиностійкості матеріалів, оскільки дозволяє визначити поведінку матеріалу під дією циклічних навантажень та прогнозувати його довговічність [2-4].

Зокрема, ДВР є відображенням залежності швидкості РВТ від амплітуди циклічного навантаження або від числа циклів навантаження. Вона дозволяє вивчити:

- ініціацію тріщини: початкова стадія (I), на якій виникають мікротріщини, що згодом об'єднуються у макротріщину. Цей процес залежить від мікроструктурних властивостей матеріалу, включаючи наявність дефектів, таких як пори, включення та інші неоднорідності;
- розвиток тріщини: проміжна стадія (II), де макротріщина поступово зростає під дією циклічних навантажень. Швидкість цього росту визначається властивостями матеріалу, амплітудою та частотою циклічних навантажень, а також умовами експлуатації, такими як корозія і температура;

- критичний розмір тріщини: кінцева стадія (III), на якій тріщина досягає критичного розміру, при якому матеріал більше не може витримувати навантаження, і відбувається руйнування. Цей критичний розмір тріщини є важливим параметром, який дозволяє визначити залишковий ресурс конструкційного елемента.

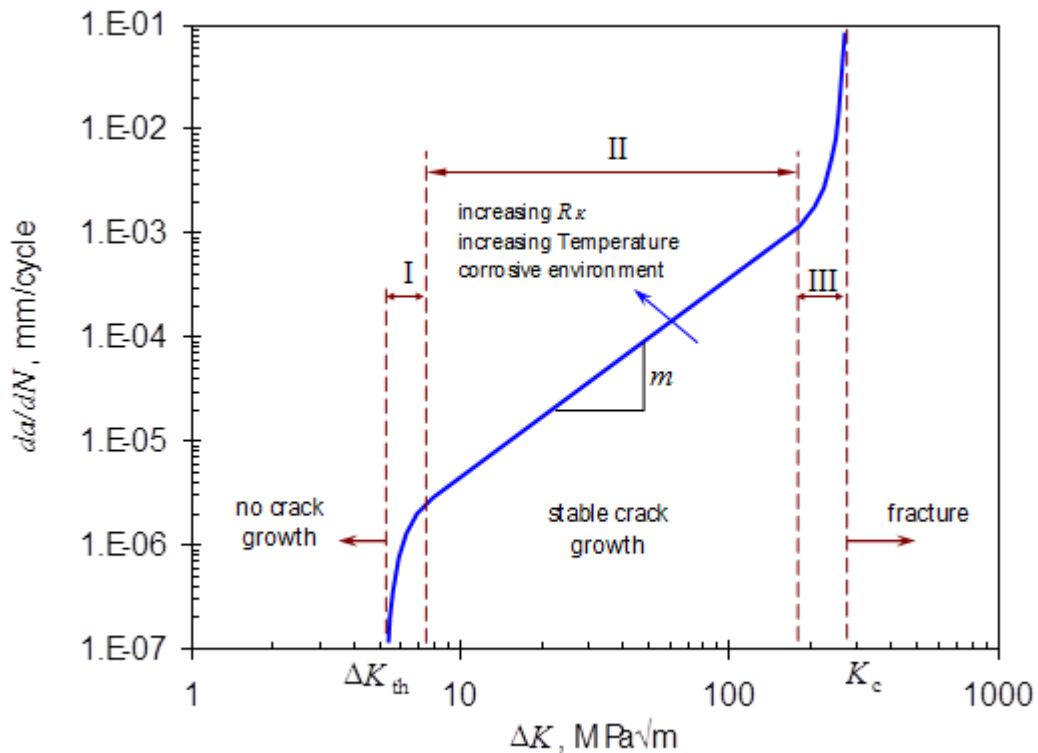


Рисунок 1.3 – Типова ДВР металу [2]

ДВР є важливим інструментом для інженерів і дослідників, які займаються оцінкою довговічності і надійності матеріалів. За допомогою ДВР можна:

- прогнозування довговічності: використовуючи ДВР, можна прогнозувати термін служби конструкційних елементів при заданих умовах експлуатації, що дозволяє планувати технічне обслуговування та заміну елементів до їхнього руйнування;
- оцінка впливу умов експлуатації: ДВР дозволяє оцінити, як різні фактори, такі як температура, вологість, корозійні середовища і змінні навантаження, впливають на швидкість росту тріщин і довговічність матеріалу;

- оптимізація конструкцій: інженери можуть використовувати ДВР для оптимізації конструкцій, знижуючи концентрації напружень у критичних зонах і вибираючи матеріали з високою циклічною тріщиностійкістю, що підвищує загальну надійність і безпеку конструкцій;
- розробка нових матеріалів: ДВР служить основою для розробки нових матеріалів з покращеними властивостями, сприяючи інноваціям в матеріалознавстві і технологіях виробництва.

Таким чином, ДВР є не тільки інструментом для оцінки поточного стану матеріалів, але і критично важливим засобом для прогнозування і забезпечення довговічності та надійності конструкційних елементів, особливо тих, що виготовлені з алюмінієвих сплавів.

Швидкість РВТ визначається за допомогою різних рівнянь та законів, які враховують специфічні умови експлуатації, властивості матеріалу і вплив навколишнього середовища. Зокрема, розглянемо моделі, що є найбільш поширеними і застосовуваними у практиці. Опис швидкості РВТ часто виражається наступною формулою:

$$\frac{da}{dN} = f(\Delta K, R) \quad (1.1)$$

де $R = \sigma_{min}/\sigma_{max}$ – коефіцієнт асиметрії циклу навантаження, σ_{min} та σ_{max} – напруження циклу навантаження (найменше та найбільше, відповідно); a – довжина тріщини, N – кількість циклів навантаження. $\Delta K = K_{max} - K_{min}$; тут K_{max} , K_{min} – найбільший і найменший КІН.

Перісова модель [5] є однією з найпоширеніших моделей для опису швидкості РВТ. Вона встановлює зв'язок між швидкістю росту тріщини (da/dN) і діапазоном коефіцієнта інтенсивності напружень (ΔK):

$$V = C(\Delta K)^m \quad (1.2)$$

де C і m – параметри матеріалу, що визначаються експериментально.

Однак, тут вплив R на швидкість РВТ не враховано. Зокрема, збільшення R призводить до збільшення швидкість РВТ.

Модель Уокера враховує асиметрію циклу навантаження через параметр асиметрії (R) і має вигляд:

$$\frac{da}{dN} = C \left[(1-R)^{m-1} \Delta K \right]^n, R \geq 0 \quad (1.3)$$

де C, m, n – параметр, що залежить від матеріалу і умов навантаження.

Загалом, асиметрія циклу навантаження, позначена як R , є одним із основних експлуатаційних факторів, що суттєво впливають на швидкість РВТ. Через це параметр R часто включають до рівнянь, використовуваних для моделювання РВТ.

Однак, важливими є вплив умов експлуатації та навколишнього середовища на швидкість РВТ, зокрема:

- температури: високі температури можуть прискорити процес РВТ через термічне розширення та окислення матеріалу;
- корозійного середовища: наявність агресивних хімічних середовищ може значно знизити стійкість матеріалу до втомного руйнування через корозійно-втомні процеси;
- частоти циклічних навантажень: висока частота циклів може призводити до швидшого накопичення пошкоджень.

Отже, моделі для опису швидкості РВТ використовують для:

- прогнозування ресурсу матеріалів: зокрема, визначення залишкового ресурсу конструкційних елементів на основі наявних даних про навантаження і властивості матеріалу;
- оптимізації конструкцій, тобто, проектування конструкцій з урахуванням оптимальних форм і матеріалів, які забезпечують мінімальні концентрації напружень і максимальну стійкість до втоми;

- технічного обслуговування та ремонту: а саме, планування і проведення інспекцій та ремонтних робіт для запобігання аварійним ситуаціям;
- розробки нових матеріалів: тобто, створення нових сплавів і композитів з покращеними втомними характеристиками.

Застосування таких моделей дозволяє інженерам та дослідникам більш точно прогнозувати поведінку матеріалів у реальних умовах експлуатації, забезпечуючи високу надійність та безпеку конструкційних елементів.

РОЗДІЛ 2. ПРОЕКТНА ЧАСТИНА

2.1 Постановка задачі моделювання швидкості РВТ

У цьому підрозділі розглянуто всі аспекти постановки задачі моделювання експлуатаційних характеристик матеріалів на основі алюмінію. Метою є створення математичної моделі, яка зможе точно прогнозувати поведінку матеріалу під різними умовами експлуатації, зокрема змодельовати швидкість РВТ в алюмінієвих сплавах.

Основні етапи включають:

- визначення цілей: зокрема, формулювання основних цілей дослідження, таких як підвищення точності прогнозування, зменшення похибок моделі, покращення розуміння механізмів втомного руйнування;
- критерії оцінки: а саме, визначення метрик, за якими буде оцінюватися ефективність моделей, наприклад, середньоквадратична помилка (MSE), коефіцієнт детермінації (R^2), середня абсолютна похибка (MAE);
- обмеження та припущення: тобто, опис обмежень, прийнятих у дослідженні, наприклад, специфікація типів алюмінієвих сплавів, розгляд лише певних умов експлуатації (температура, вологість тощо).

2.2 Вибір методів машинного навчання для дослідження

МН є важливою галуззю ШІ, яка фокусується на розробці та впровадженні алгоритмів, здатних навчатися з наявних даних та вдосконалювати свою продуктивність без необхідності явного програмування [6]. Основною метою МН є виявлення прихованих закономірностей та зв'язків між вхідними даними та відповідними результатами, щоб забезпечити можливість прогнозування та прийняття рішень на основі нових, невідомих даних.

Алгоритми МН аналізують великі обсяги даних, знаходять патерни і створюють моделі, які можуть адаптуватися та поліпшуватися з часом. Цей процес включає кілька ключових етапів:

- збір даних: вибір і збирання відповідних даних, які будуть використовуватися для навчання алгоритмів. Ці дані можуть бути структурованими (таблиці, бази даних) або неструктурованими (тексти, зображення);
- попередня обробка даних: очищення, нормалізація та трансформація даних для забезпечення їх якості та придатності для аналізу. Це включає видалення пропусків, зменшення шуму та створення нових ознак;
- вибір моделі: визначення найбільш підходящого алгоритму МН для вирішення конкретної задачі. Це можуть бути лінійні моделі, НМ, підсилені дерева, випадкові ліси, методи ансамблевого навчання тощо;
- навчання моделі: використання наявних даних для навчання обраного алгоритму. Під час цього процесу модель налаштовує свої параметри, щоб мінімізувати різницю між прогнозованими та реальними результатами;
- оцінка моделі: перевірка якості моделі за допомогою тестових наборів даних, які не були використані під час навчання. Використовуються різні метрики для оцінки точності та ефективності моделі, такі як середньоквадратична помилка (MSE), коефіцієнт детермінації (R^2) тощо;
- вдосконалення моделі: налаштування гіперпараметрів та вдосконалення моделі на основі результатів оцінки. Це може включати зміну структури моделі, вибір інших алгоритмів або додавання нових даних;
- прогнозування та розгортання: використання навченої моделі для прогнозування нових даних. Це може включати інтеграцію моделі в існуючі системи або створення окремих додатків для автоматизації процесу прийняття рішень.

МН дозволяє автоматизувати складні процеси, підвищувати точність прогнозів і оптимізувати операційні процедури, що в кінцевому результаті сприяє підвищенню ефективності та конкурентоспроможності організацій.

Обрано три основні методи МН для моделювання експлуатаційних характеристик матеріалів на основі алюмінію: НМ, підсилені дерева та випадкові ліси. Кожен з цих методів має унікальні переваги, які дозволяють ефективно вирішувати задачі прогнозування та підвищувати точність моделей. Такий підхід забезпечує надійність та узгодженість результатів, що є критично важливим для практичного застосування в промисловості та наукових дослідженнях.

НМ є потужним інструментом для моделювання складних нелінійних залежностей у даних. Вони здатні навчатися з великої кількості прикладів і знаходити приховані патерни, які не завжди очевидні для традиційних методів моделювання. Важливими чинниками, що впливають на точність прогнозування є:

- архітектура: вибір та налаштування кількості шарів, кількості нейронів у кожному шарі, типів шарів (щільні, згорткові тощо);
- функції активації: використання різних функцій активації (ReLU, Sigmoid, Tanh) для введення нелінійності в модель;
- методи оптимізації: використання алгоритмів оптимізації, таких як градієнтний спуск, Adam, RMSprop, для мінімізації функції втрат;
- регуляризація: застосування методів регуляризації (Dropout, L2-регуляризація) для запобігання перенавчанню.

Перевагами НМ є:

- гнучкість та універсальність: НМ можуть застосовувати для різних типів задач, таких як класифікація, регресія, кластеризація та інші. У нашому випадку, вони застосовуються для прогнозування швидкості РВТ в алюмінієвих сплавах;
- обробка нелінійностей: зокрема, завдяки використанню нелінійних функцій активації (ReLU, Sigmoid, Tanh), НМ можуть моделювати складні залежності між вхідними та вихідними даними;
- висока точність: тобто, з правильним налаштуванням архітектури (кількість шарів, кількість нейронів у кожному шарі) та оптимізацією гіперпараметрів, НМ здатні досягати високої точності в прогнозуванні.

НМ були обрані для дослідження через їх здатність обробляти складні та великі обсяги даних, а також через їх ефективність у задачах регресії, що є критично важливим для прогнозування експлуатаційних характеристик матеріалів.

Підсилені дерева, такі як Gradient Boosting та AdaBoost, є ефективними методами для підвищення точності моделей шляхом коригування помилок попередніх моделей. Вони створюють ансамбль дерев, де кожне наступне дерево виправляє помилки попередніх.

Зокрема, Gradient Boosting будує моделі поступово, додаючи кожне нове дерево до ансамблю таким чином, щоб зменшити залишкові помилки попередніх дерев. Gradient Boosting дозволяє контролювати складність моделі за допомогою налаштування гіперпараметрів, таких як кількість дерев, глибина дерев та швидкість навчання.

Тоді як алгоритм AdaBoost збільшує вагу тих прикладів, які були неправильно класифіковані попередніми моделями, і зменшує вагу правильно класифікованих прикладів. Це дозволяє фокусуватися на складних випадках і покращувати загальну точність моделі.

Підсилені дерева були обрані через їх високу точність та здатність працювати з різноманітними наборами даних. Вони ефективно обробляють як числові, так і категоріальні дані, а також добре працюють з пропусками в даних.

Випадкові ліси є ще одним популярним методом ансамблевого навчання, який використовує велику кількість рішучих дерев для покращення точності прогнозування та зменшення ризику перенавчання. Випадковий ліс будується з великої кількості рішучих дерев, де кожне дерево навчається на випадковій підмножині даних та ознак. Це забезпечує високу різноманітність дерев у лісі та сприяє кращій узагальненості моделі.

Перевагами методу випадкових лісів є:

- стійкість до перенавчання: використання великої кількості дерев та випадковий вибір ознак зменшує ризик перенавчання та покращує здатність моделі до узагальнення;

- обробка великих обсягів даних: випадкові ліси добре працюють з великими наборами даних і здатні ефективно обробляти складні взаємозв'язки між ознаками.

Випадкові ліси були обрані через їх стабільність та високу точність у задачах регресії та класифікації. Вони особливо ефективні у випадках, коли дані мають велику кількість ознак та включають значні взаємозв'язки між ознаками.

Загалом, обрані методи МН, а саме, НМ, підсилені дерева та випадкові ліси забезпечують комплексний підхід до моделювання експлуатаційних характеристик матеріалів на основі алюмінію.

2.3 Алгоритм НМ

НМ є одним із найпотужніших інструментів у машинному навчанні завдяки своїй здатності моделювати складні нелінійні залежності [7-9]. Вони складаються з трьох основних типів шарів: вхідного, прихованих та вихідного шарів (рис. 2.1):

- вхідний шар: це шар, який отримує початкові дані. Кожен нейрон у цьому шарі відповідає за одну вхідну ознаку;
- приховані шари: можуть складатися з одного або більше шарів, де кожен нейрон отримує вхідні сигнали, обробляє їх за допомогою функції активації (такої як ReLU, Sigmoid або Tanh), і передає результат наступним нейронам;
- вихідний шар: відповідає за генерацію кінцевих прогнозів. Для задач регресії це може бути один нейрон, що представляє передбачуване значення, а для класифікації - кілька нейронів, які представляють ймовірності класів.




Рисунок 2.1 – Архітектура НМ з прихованим та вихідним шаром нейронів

Зокрема, процес навчання нейронної мережі включає:

- прямий прохід: тобто, вхідні дані проходять через всі шари мережі до вихідного шару;
- обчислення помилки: зокрема, використовується функція втрат (наприклад, середньоквадратична помилка для регресії) для оцінки різниці між прогнозованими та фактичними значеннями;
- зворотний прохід: відомо, що за допомогою алгоритму зворотного поширення помилки (backpropagation) і методу градієнтного спуску (gradient descent) коригуються ваги нейронів, щоб мінімізувати функцію втрат.

У НМ процес передачі сигналів здійснюється поступово через кілька шарів нейронів. Спочатку вхідні сигнали надходять до нейронів першого (вхідного) шару. Ці сигнали обробляються нейронами цього шару і передаються далі до нейронів другого шару, який часто називають прихованим шаром. Сигнали, що генеруються нейронами другого шару, стають вхідними для нейронів третього шару. Цей процес повторюється, передаючи сигнали від шару до шару, поки вони не досягнуть вихідного шару.

У кожному шарі нейрони отримують вхідні сигнали виключно від нейронів попереднього шару, обробляють ці сигнали за допомогою відповідних функцій активації та передають їх далі до наступного шару. Така організація шарів дозволяє нейронній мережі вивчати складні патерни і взаємозв'язки в даних.

Структура НМ може бути описана через кількість нейронів у кожному шарі. Наприклад, мережа з 4 вхідними нейронами, 8 прихованими нейронами та 1 вихідним нейроном може бути позначена як 4-8-1. Це означає, що вхідний шар містить 4 нейронів, які отримують початкові дані. Далі йде прихований шар, який містить 8 нейронів, що обробляють сигнали від вхідного шару. Нарешті, вихідний шар складається з 1 нейрона, який генерує кінцевий результат або прогноз на основі оброблених даних. При детальному описі процесу відомо що:

- вхідний шар складається з 4 нейронів, кожен з яких відповідає за одну конкретну ознаку або параметр вхідних даних. Ці нейрони приймають початкові дані і передають їх далі до наступного шару;
- прихований шар: у цьому випадку містить 8 нейронів. Кожен нейрон у цьому шарі отримує сигнали від усіх 4 нейронів вхідного шару. Використовуючи функції активації, приховані нейрони обробляють ці вхідні сигнали і передають результати до наступного шару;
- вихідний шар складається з одного нейрона. Цей нейрон отримує сигнали від двох нейронів прихованого шару і генерує остаточний вихідний сигнал або прогноз.

Кількість шарів і нейронів у кожному шарі дозволяє мережі обробляти і навчатися на більш складних і багатовимірних даних. Зокрема, кожен шар використовує функції активації (наприклад, ReLU, Sigmoid, Tanh), щоб допомогти нейронам приймати рішення на основі вхідних сигналів, що дозволяє моделі вивчати нелінійні взаємозв'язки. НМ використовують алгоритми, такі як зворотне поширення помилки, для коригування ваг нейронів з метою мінімізації різниці між прогнозованими та фактичними результатами.

Таким чином, нейронні мережі з багатошаровою структурою, як описана 4-8-1, здатні вивчати складні патерни в даних і робити точні прогнози завдяки своїй здатності до глибокого навчання та обробки багатовимірної інформації.

Основними функціями активації нейронів є [7]:

- порогова функція:

$$Out = \begin{cases} 0, NET < \theta, \\ 1, NET \geq \theta \end{cases} \quad (3.2)$$

- сигмоїдальна функція:

$$Out = \frac{1}{1 + e^{-NET}} \quad (3.3)$$

Логарифмічна функція є прикладом сигмоїдальної функції;

- гіперболічний тангенс:

$$Out = \frac{e^{NET} - e^{-NET}}{e^{NET} + e^{-NET}} \quad (3.4)$$

На рис.3.2 показано основні види активаційних функцій.




Рисунок 2.2 – Відображення активаційних функцій нейронів (а) порогова, (б) сигмоїдальна, (в) гіперболічний тангенс [7]

2.4 Процес навчання НМ

Найважливішою властивістю НМ є їх здатність навчатися на основі даних навколишнього середовища і в результаті навчання підвищувати свою продуктивність, яка збільшується з часом відповідно до певних правил. Навчання НМ здійснюється за допомогою інтерактивного процесу коригування синаптичних ваг і рівнів зміщення. В ідеальному випадку, НМ отримує знання про навколишнє середовище на кожній ітерації процесу навчання. З поняттям навчання асоціюється досить багато видів діяльності, тому складно надати цьому процесу однозначне визначення. Більш того, процес навчання залежить від точки зору на нього. Саме це робить практично неможливим появу будь-якого точного визначення. Отже, навчання – це процес, в якому вільні параметри НМ настроюються за допомогою моделювання середовища, в яке ця мережа вбудована. Тип навчання визначається способом підстроювання цих параметрів та передбачає наступну послідовність подій:

- НМ надходять імпульси із зовнішнього середовища;
- в результаті цього змінюються вільні параметри НМ;
- після зміни внутрішньої структури НМ відповідає на порушення вже іншим чином.

Вище вказаний список чітких правил для вирішення проблеми навчання називається його алгоритмом. Нескладно здогадатися, що не існує універсального способу, відповідного для всіх архітектур НМ. Існує лише набір засобів, представлений безліччю алгоритмів навчання, кожен з яких має свої переваги. Вони відрізняються один від одного стилем налаштування синаптичних ваг нейронів. Ще однією відмінною характеристикою є спосіб зв'язку навченої НМ із зовнішнім світом. У цьому контексті говорять про парадигму навчання, яка пов'язана з моделлю навколишнього середовища, в якому функціонує дана нейронна мережа.

В загальному, існує п'ять основних моделей навчання: на основі корекції помилок, Хеббівське, конкурентне, з використанням пам'яті і метод Больцмана [7].

Навчання, засноване на корекції помилок, реалізує метод оптимальної фільтрації. Для того, щоб проілюструвати навчання, розглянуто найпростіший випадок нейрона k -єдиного обчислювального вузла вихідного шару НМ прямого поширення. Навчання на основі корекції помилки за своєю природою є локальним і це приклад замкнутої системи зі зворотним зв'язком. З теорії управління відомо, що стійкість такої системи визначається параметрами зворотного зв'язку. В даному випадку, існує всього один зворотний зв'язок і єдиним цікавим параметром є коефіцієнт швидкості навчання. Вибір цієї величини впливає на точність та інші характеристики процесу навчання. Іншими словами, параметр швидкості навчання грає ключову роль в забезпеченні продуктивності процесу навчання на практиці.

Навчання на основі пам'яті передбачає явне використання навчальних даних.

Постулат Хебба є найстарішим і найвідомішим серед всіх правил навчання. Він названий на честь нейрофізіолога Хебба. Учений запропонував поставити своє спостереження в основу процесу асоціативного навчання, тобто на клітинному рівні. Якщо бути більш точним, то синапс Хебба використовує залежність від часу та локальний механізм взаємодії, що змінює ефективність синаптичного з'єднання в залежності від кореляції між передсинаптичною і постсинаптичною активністю. Для того, щоб описати навчання Хебба в математичних термінах, розглянута синаптична вага нейрона з синаптичними сигналами. Одним із способів подолання обмежень гіпотези Хебба є використання гіпотези коваріації. Відповідно до неї, передсинаптичний і постсинаптичний сигнали замінюють їхніми відхиленнями від середніх значень на даному відрізку часу.

Конкурентний підхід до навчання заснований на нейробіологічних принципах. Як впливає із самої назви, в конкурентному навчанні вихідні

нейрони мережі конкурують між собою за право бути активованими. Якщо в НМ, заснованої на навчанні Хебба, одночасно в збудженому стані може перебувати кілька нейронів, то в конкурентній мережі в кожний момент часу може бути активним тільки один нейрон. Завдяки цій властивості конкурентне навчання дуже зручно використовувати для вивчення статистичних властивостей, використовуваних в задачах класифікації вхідних образів. Найпростіша НМ з конкурентним навчанням містить єдиний шар вихідних нейронів, кожен з яких з'єднаний з вхідними вузлами. У такій мережі можуть існувати зворотні зв'язки між нейронами, які забезпечують латеральне гальмування, коли кожен нейрон прагне "загальмувати" пов'язані з ним нейрони.

В основу методу Больцмана покладені ідеї статистичної механіки. Правило навчання, назване так на його честь, являє собою стохастичний алгоритм. НМ, створена на основі навчання Больцмана, отримала назву машини Больцмана, де всі нейрони представляються рекурентними структурами, що працюють з бінарними сигналами. Це означає, що вони можуть перебувати у включеному (відповідному значенню +1) або вимкненому (відповідному значенню -1) стані. Така машина характеризується функцією енергії E , значення якої визначається конкретними станами окремих нейронів, що складають цю машину. Нейрони машини Больцмана можна розбити на дві функціональні групи: видимі і приховані. Видимі нейрони реалізують інтерфейс між мережею і середовищем її функціонування, а приховані працюють незалежно від зовнішнього середовища. Є два режими функціонування такої мережі: скутий і вільний.

При вивченні алгоритмів навчання розподілених систем корисно ознайомитися з концепцією присвоювання коефіцієнтів довіри. По суті, це завдання присвоювання коефіцієнтів довіри або недовіри всім результатам, отриманим деякою навченою машиною. У багатьох випадках залежність виходів від внутрішніх рішень визначається послідовністю дій, які виконуються машиною. Іншими словами, внутрішні рішення впливають на виконання конкретних дій, після чого саме ці дії, а не самі рішення безпосередньо визначають загальні результати. Структурне завдання присвоювання

коефіцієнтів довіри має сенс в контексті багатокomпонентного вчення машин, коли необхідно точно визначити, поведінку якого елемента системи потрібно скорегувати і на яку величину, щоб підвищити загальну продуктивність системи. З іншого боку, тимчасове завдання присвоєння коефіцієнтів довіри ставиться в тому випадку, коли навчальна машина виконує досить багато дій, що призводять до деякого результату і потрібно визначити, які з них несуть відповідальність за результат.

Загалом, існує дві фундаментальні парадигми навчання: навчання з учителем і без нього. Концептуально участь вчителя можна розглядати як наявність знань про навколишнє середовище, представлених у вигляді пар вхід-вихід. При цьому саме середовище невідоме для навчання НМ. Тепер припустимо, що вчителю і мережі, котра навчається, подається навчальний вектор з навколишнього середовища. На основі вбудованих знань учитель може сформулювати і передати мережі, яка навчається, бажаний відгук, який відповідає цьому вхідному вектору. Цей бажаний результат являє собою оптимальні дії, які повинна виконати НМ. Параметри мережі коригуються з урахуванням навчального вектора і сигналу помилки – різниці між бажаним сигналом і поточним відгуком нейронної мережі. Коригування параметрів виконується крок за кроком з метою імітації НМ поведінки вчителя. Ця емуляція в деякому статистичному сенсі повинна бути оптимальною. Таким чином, в процесі навчання знання вчителя передаються у мережу з максимально повним обсягом. Після закінчення навчання, вчителя можна відключити і дозволити НМ працювати з середовищем самостійно. Описана форма навчання з учителем є нічим іншим, як навчанням на основі корекції помилок. Це замкнута система зі зворотним зв'язком, яка не включає в себе навколишнє середовище. Продуктивність такої системи можна оцінювати в термінах середньоквадратичної помилки або суми квадратів помилок на навчальній вибірці, представленої у вигляді функції від вільних параметрів системи. Для підвищення продуктивності системи в часі значення помилки повинно зміщуватися в бік мінімуму.

Альтернативна парадигма навчання без вчителя самою назвою підкреслює відсутність керівника, який контролює процес налаштування вагових коефіцієнтів. У навчанні з підкріпленням формування вхідних сигналів у вихідні виконується в процесі взаємодії їх із зовнішнім середовищем з метою мінімізації скалярного індексу продуктивності. Блокова діаграма, що є однією з форм системи навчання з підкріпленням, включає блок "критики", який перетворює первинний сигнал підкріплення, отриманий із зовнішнього середовища, в сигнал більш високої якості, званий евристичним. Обидва цих сигнали є скалярними. Така система передбачає навчання з відкладеним підкріпленням. Це означає, що вона отримує із зовнішнього середовища послідовність сигналів збудження, які призводять до генерації евристичного сигналу підкріплення. Може виявитися, що деякі вжиті раніше в даній послідовності дії були визначальними у формуванні загальної поведінки всієї системи. Функція навченою машиною, визначає ці дії і формує на їх основі сигнал зворотного зв'язку, що направляється в зовнішнє середовище.

2.5 Метод підсилених дерев

Підсилені дерева використовують техніку ансамблевого навчання для поліпшення продуктивності моделей шляхом комбінування простих моделей (рішучих дерев) у потужнішу ансамблеву модель [10]. Два найпоширеніші методи підсилення – Gradient Boosting і AdaBoost:

- Gradient Boosting: Кожне наступне дерево навчається на помилках, зроблених попередніми деревами. Зокрема, функція втрат визначає, наскільки добре кожне дерево покращує точність моделі. Використовується градієнтний спуск для мінімізації втрат. Крім того, налаштування гіперпараметрів включає глибину дерев, кількість дерев та швидкість навчання (learning rate). Ці параметри впливають на здатність моделі узагальнювати дані та запобігати перенавчанню;

- AdaBoost: Алгоритм збільшує ваги тих прикладів, які були неправильно класифіковані попередніми деревами, і зменшує ваги правильно класифікованих прикладів. Остаточне передбачення робиться шляхом зваженого голосування всіх дерев у ансамблі, де кожне дерево має вагу, пропорційну його точності.

Для кожного піддерева ми замінюємо його на листовий вузол, що представляє навчальні приклади, охоплені піддеревом (для задач класифікації або регресії відповідно). Якщо листовий вузол демонструє таку ж або кращу продуктивність порівняно з піддеревом на наборі даних для обрізання, ми обрізаємо піддерево та залишаємо лише листовий вузол, оскільки складність піддерева не виправдовує себе. У протилежному випадку піддерево залишається. Наприклад, у третьому дереві на рисунку 2.3 є піддерево, що починається з умови $x < 6.31$. Це піддерево може бути замінене на листовий вузол з передбаченням $y = 0.9$ (як у другому дереві), якщо помилка на наборі даних для обрізання не збільшиться після заміни. Важливо не плутати набір даних для обрізання з перевірочним набором даних, оскільки вони відрізняються один від одного.

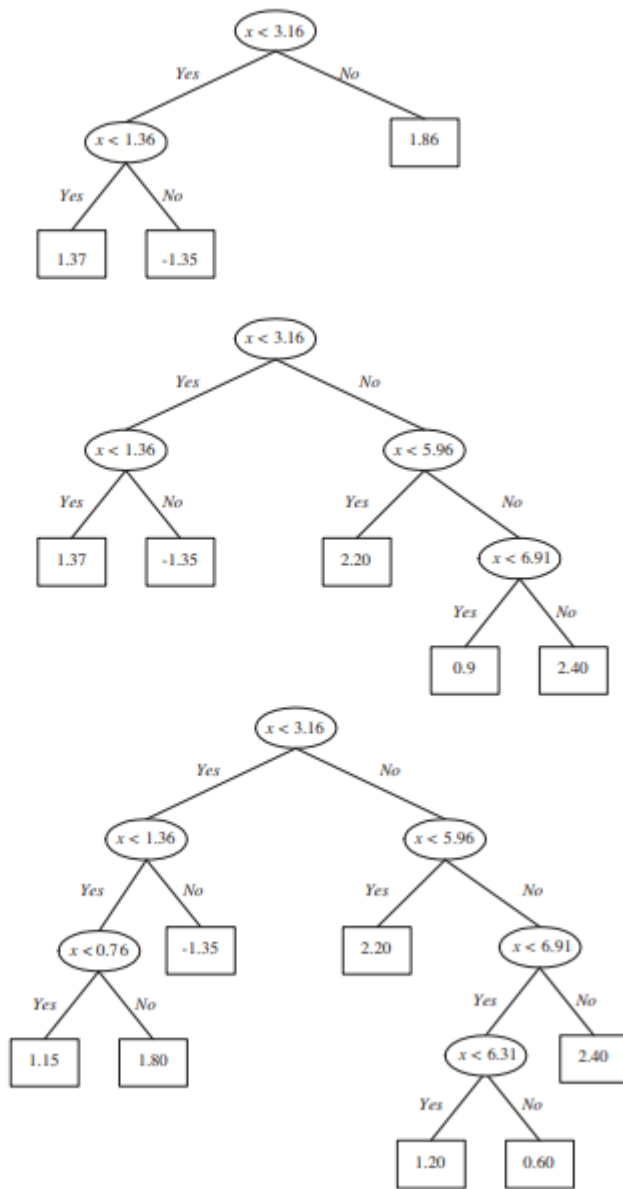


Рисунок 2.3 – Приклад побудови підсилених дерев

Ще одним способом отримати простіші дерева є післяобрізка, яка на практиці працює краще, ніж попереднє обрізання дерева. На кожному кроці процесу ми приймаємо рішення, створюючи вузол і продовжуючи далі, не повертаючись назад і не розглядаючи альтернативи. Єдиний виняток – це післяобрізка, коли ми намагаємося знайти і видалити непотрібні піддерева.

Під час післяобрізки ми розвиваємо дерево до тих пір, поки всі листки не стануть чистими, що означає відсутність помилок навчання. Потім ми визначаємо піддерева, які призводять до перенавчання, і обрізаємо їх. Для цього

ми використовуємо множину даних для обрізки, яка не була задіяна під час початкового навчання, що виділяється з початкової маркованої множини.

2.6 Метод випадкових лісів

Випадковий ліс – це ансамблевий метод МН, який складається з множини незалежних рішень дерев, згенерованих у процесі навчання. Його головна ідея полягає в об'єднанні прогнозів багатьох рішень дерев для отримання більш точних і стабільних результатів. Метод застосовується як для задач класифікації, так і для регресії [11].

Для кожного дерева у випадковому лісі вибирається випадкова підмножина навчальних даних з використанням методу підвантаження (bootstrap sampling). Це означає, що вибірка здійснюється з поверненням, і деякі приклади можуть бути використані більше одного разу, тоді як інші можуть бути виключені. Зокрема, для кожної вибраної підмножини даних будується дерево рішень. На кожному вузлі дерева вибирається випадкова підмножина ознак (характеристик) для поділу. Це додатковий елемент випадковості допомагає знизити кореляцію між деревами, підвищуючи загальну ефективність моделі.

На кожному вузлі дерева обчислюються критерії поділу для кожної ознаки у випадковій підмножині ознак. Критерій поділу може бути, наприклад, критерій Джині для задач класифікації або середньоквадратична помилка (MSE) для задач регресії. Вибирається поділ, який забезпечує найбільше зниження невизначеності.

Дерева будуються до кінця без обрізки (тобто до тих пір, поки кожен листок не буде чистим або не залишиться мінімально можлива кількість прикладів у вузлі). Це максимізує їхню індивідуальну глибину і складність, але на рівні ансамблю це не призводить до перенавчання завдяки використанню багатьох дерев і методу підвантаження.

Для задач класифікації кожне дерево в лісі робить свій прогноз (голосування) щодо класу для нового прикладу, і остаточний клас визначається

більшістю голосів. Для задач регресії кожне дерево прогнозує значення, і остаточний прогноз є середнім значенням прогнозів усіх дерев (рис.2.4).

Перевагами методу випадкових лісів є:

- стійкість до перенавчання: тобто, використання випадкових підмножин даних та ознак для кожного дерева знижує ризик перенавчання;
- висока точність: об'єднання прогнозів багатьох дерев дозволяє отримати більш точні та стабільні результати;
- обробка великої кількості ознак: метод може ефективно працювати з великою кількістю вхідних ознак, автоматично визначаючи найбільш важливі з них;
- вимірювання важливості ознак: випадкові ліси надають інформацію про важливість кожної ознаки, що може бути використано для інтерпретації моделі та подальшого аналізу.

Недоліками є:

- високі обчислювальні витрати: побудова великої кількості дерев може бути обчислювально-інтенсивною і вимагати значних ресурсів;
- можливість утворення надмірно складних моделей: навіть з урахуванням випадковості, великі ліси можуть стати дуже складними і важкими для інтерпретації.

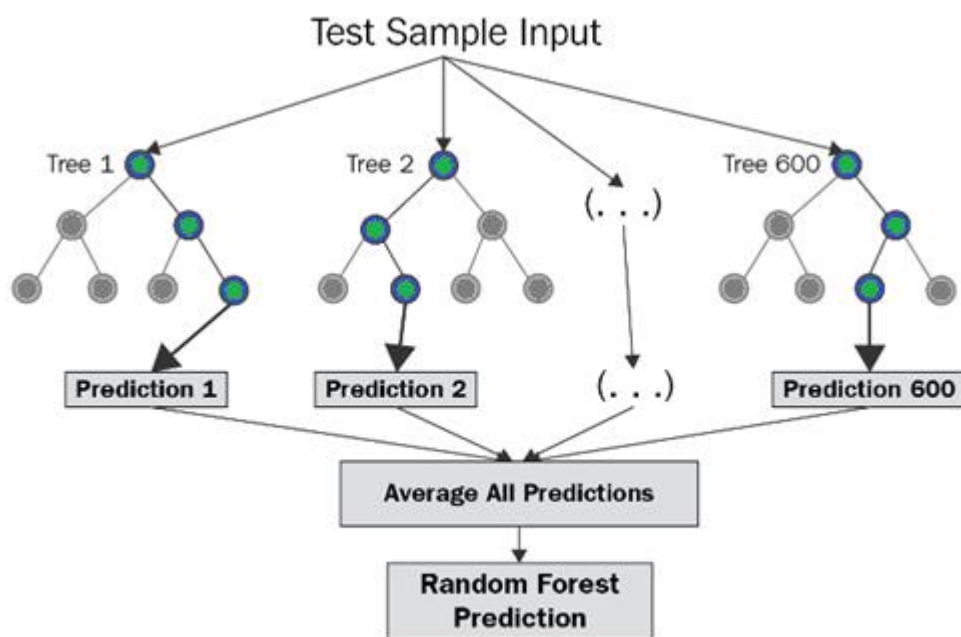


Рисунок 2.4 – Приклад методу випадкових лісів

Метод випадкових лісів є потужним інструментом для вирішення задач класифікації та регресії завдяки своїй стійкості до перенавчання, високій точності та здатності обробляти великі набори даних. Його застосування вимагає належної підготовки даних та вибору відповідних гіперпараметрів для досягнення оптимальних результатів.

2.7 Підготовка даних для моделювання

Збір та підготовка даних є критично важливими етапами в процесі побудови моделей МН. Ці етапи забезпечують, що дані, які використовуються для навчання, є якісними, релевантними та готовими для обробки моделями.

Детальний опис цього процесу включає кілька ключових кроків:

- збір даних: тобто, джерела даних, зокрема, визначення та залучення релевантних джерел даних. Отже, для дослідження експлуатаційних характеристик матеріалів на основі алюмінію можна використовувати:

- експериментальні лабораторні дані. А саме, історичні дані з промислових датчиків і моніторингових систем;
 - публічно доступні набори даних з наукових досліджень та баз даних;
 - інтеграція даних: зокрема, збирання даних з різних джерел та їх інтеграція в єдину базу даних. Це може вимагати створення скриптів для автоматизованого збирання даних або використання спеціалізованих інструментів ETL (Extract, Transform, Load).
- очищення даних, а саме:
- видалення пропусків, тобто, обробка відсутніх значень. Це може включати видалення рядків з пропущеними значеннями, заповнення пропущених значень середніми або медіанними значеннями, або використання методів імпутації;
 - видалення дублікатів, зокрема, ідентифікація та видалення дублікатів даних для запобігання викривлень в моделюванні;
 - фільтрація шумів, тобто, видалення аномалій або шумів у даних, що можуть негативно вплинути на навчання моделей.
- перетворення даних, а саме:
- нормалізація та стандартизація: тобто, масштабування числових даних для забезпечення їхнього однакового впливу на модель. Наприклад, нормалізація (приведення значень до діапазону від 0 до 1) або стандартизація (перетворення значень таким чином, щоб вони мали середнє 0 і стандартне відхилення 1);
 - категоризація: зокрема, перетворення категоріальних даних в числові формати, які можуть бути оброблені моделями МН. Це може включати використання технік one-hot encoding або label encoding;
 - генерація нових ознак: тобто, створення нових ознак на основі існуючих даних, які можуть краще відображати характеристики досліджуваних об'єктів. Наприклад, можна створювати

взаємозв'язки між різними параметрами або агрегувати дані для отримання додаткової інформації.

– розподіл даних, зокрема:

- розділення на тренувальний та тестовий набори: тобто, поділ даних на набори для навчання та перевірки моделі. Зазвичай, дані розділяють у пропорції 70-80% для тренувального набору та 20-30% для тестового;
- валідаційний набір: зокрема, крім тренувального та тестового наборів, часто виділяють окремий валідаційний набір для налаштування гіперпараметрів моделі та оцінки її продуктивності під час навчання.

– аналіз та візуалізація даних, тобто:

- розвідувальний аналіз даних (EDA): тобто, проведення попереднього аналізу даних для виявлення основних характеристик, патернів та аномалій. Це включає використання статистичних методів та візуалізацій, таких як гістограми, діаграми розсіювання, кореляційні матриці тощо;
- візуалізація: а саме, створення візуалізацій для кращого розуміння структури даних та виявлення взаємозв'язків між різними ознаками.

– підготовка даних до навчання моделей, тобто:

- розподіл на фолди (для крос-валідації): зокрема, якщо використовується метод крос-валідації, дані розподіляють на кілька фолдів для проведення багаторазового навчання і тестування моделі;
- балансування класів (для класифікаційних задач): тобто, в разі нерівномірного розподілу класів, проводять балансування класів за допомогою технік, таких як підвибірка, надвибірка або використання алгоритмів, що враховують ваги класів.

Збір та підготовка даних для моделювання – це комплексний процес, що включає кілька етапів, кожен з яких є критично важливим для успішного навчання моделей машинного навчання. Правильна підготовка даних забезпечує

високу якість навчання та точність моделей, а також дозволяє уникнути типових проблем, таких як перенавчання або невідповідність між навчальними та тестовими даними.

2.8 Розробка програмного забезпечення для моделювання РВТ

Розробка програмного забезпечення для моделювання РВТ є важливим етапом, що включає налаштування та використання відповідних інструментів для реалізації моделей МН. Загалом, застосували програму STATISTICA, яка надає потужні засоби для аналізу даних, моделювання та візуалізації.

Детальний опис цього процесу включає наступні кроки:

- вибір інструментів та середовища:
 - програмне забезпечення: основним інструментом є STATISTICA, яка надає зручний графічний інтерфейс для аналізу даних та моделювання;
 - середовище розробки: налаштування робочого середовища для роботи зі STATISTICA, включаючи встановлення необхідних модулів та бібліотек;
- імпорт та попередня обробка даних:
 - імпорт даних: завантаження даних у STATISTICA з різних джерел, таких як CSV, Excel, бази даних SQL тощо;
 - попередня обробка: виконання попередньої обробки даних, яка включає очищення, нормалізацію, перетворення та візуалізацію даних (рис. 2.5);

	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 2.5 – Вікно з даними у STATISTICA

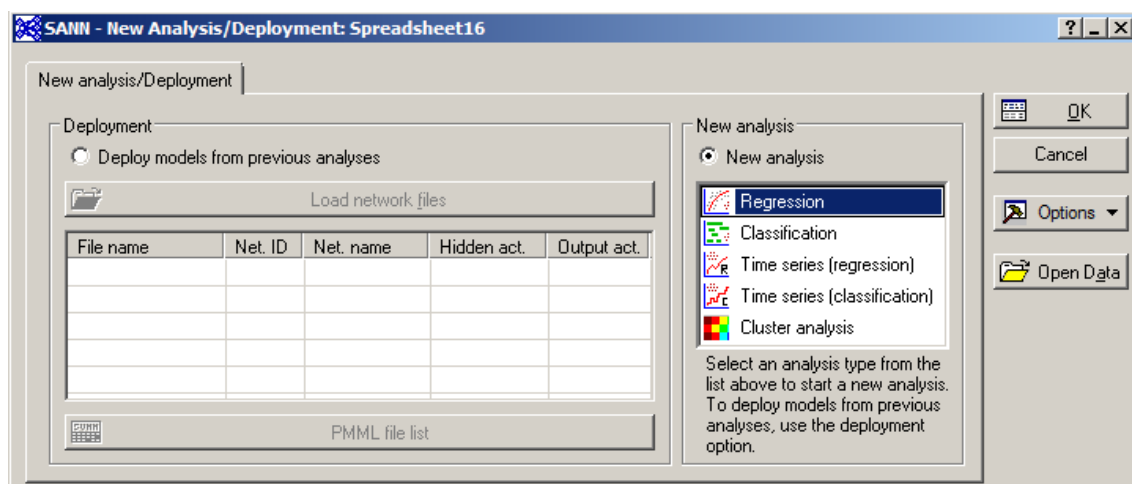


Рисунок 2.6 – Вікно команди *Regression* у STATISTICA

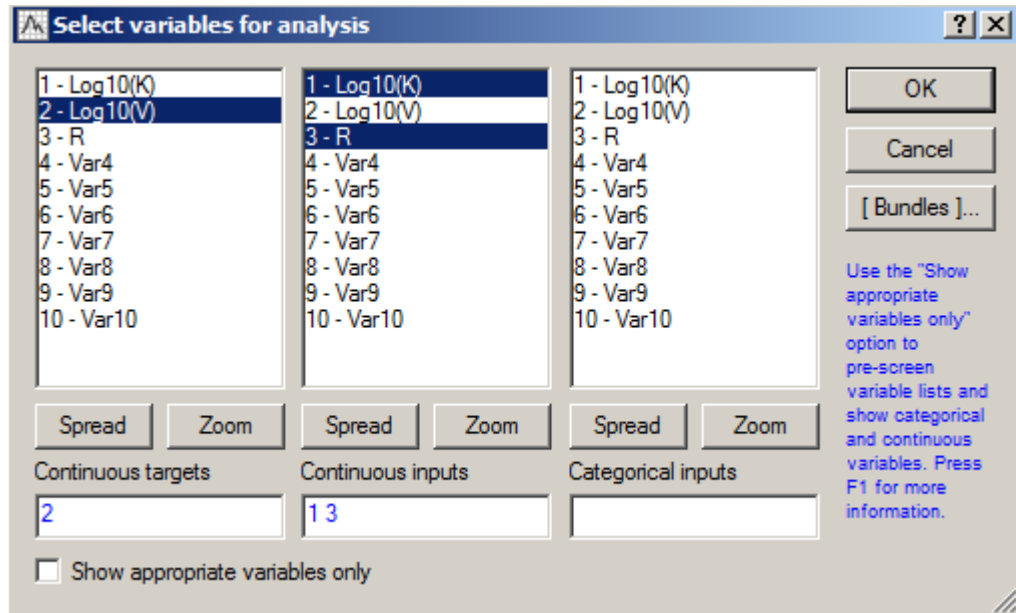


Рисунок 2.7 – Меню *Variables* у STATISTICA (вхідні та вихідні змінні)

– налаштування моделей МН:

- вибір моделей: визначення моделей МН, які будуть використовуватись, таких як НМ, підсилени дерева та випадкові ліси;
- налаштування параметрів: встановлення початкових параметрів для кожної моделі. Це може включати кількість шарів та нейронів у НМ, кількість дерев у випадкових лісах, параметри глибини та кількість підсилених дерев тощо;

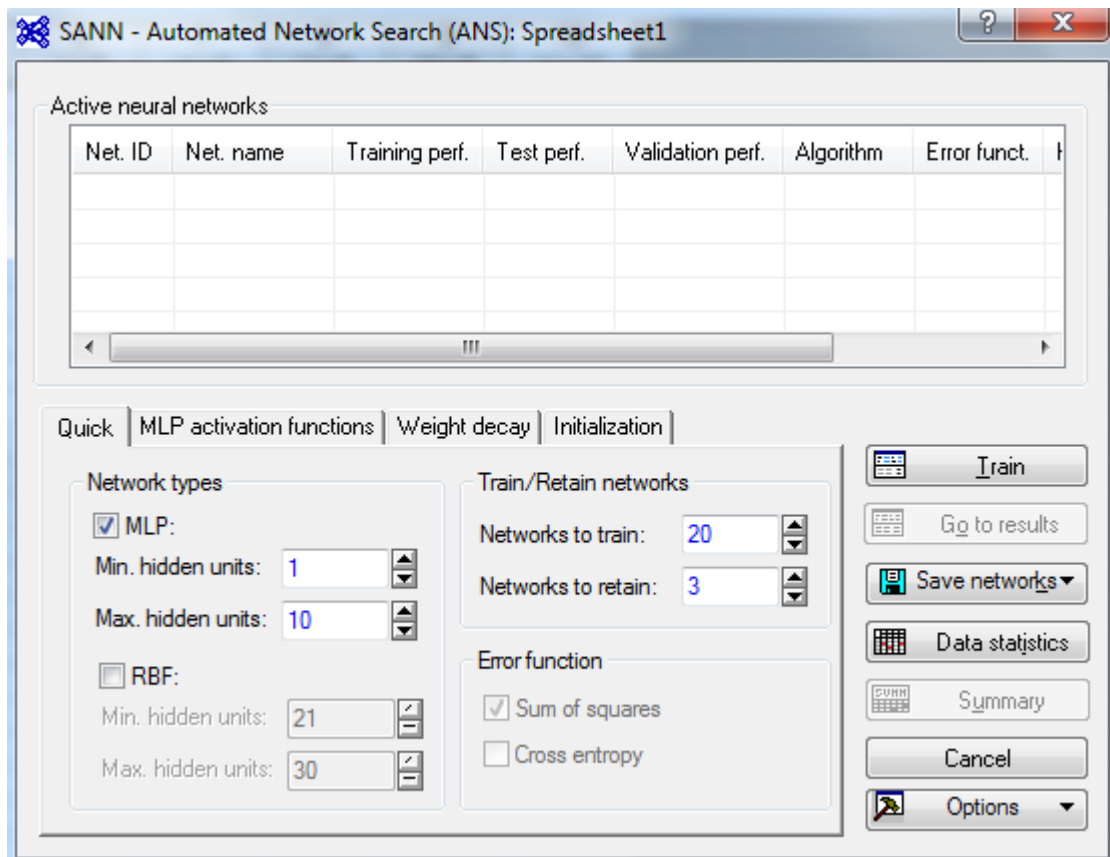


Рисунок 2.8 – Налаштування параметрів НМ

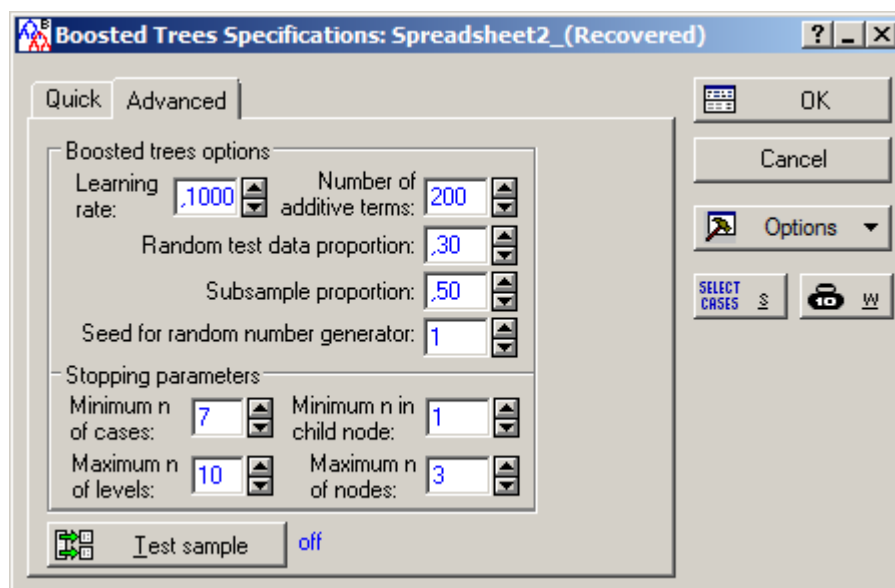


Рисунок 2.9 – Вікно налаштування параметрів підсилени дерев

- розподіл даних: вибір методів розподілу даних для навчання, тестування та валідації моделей;

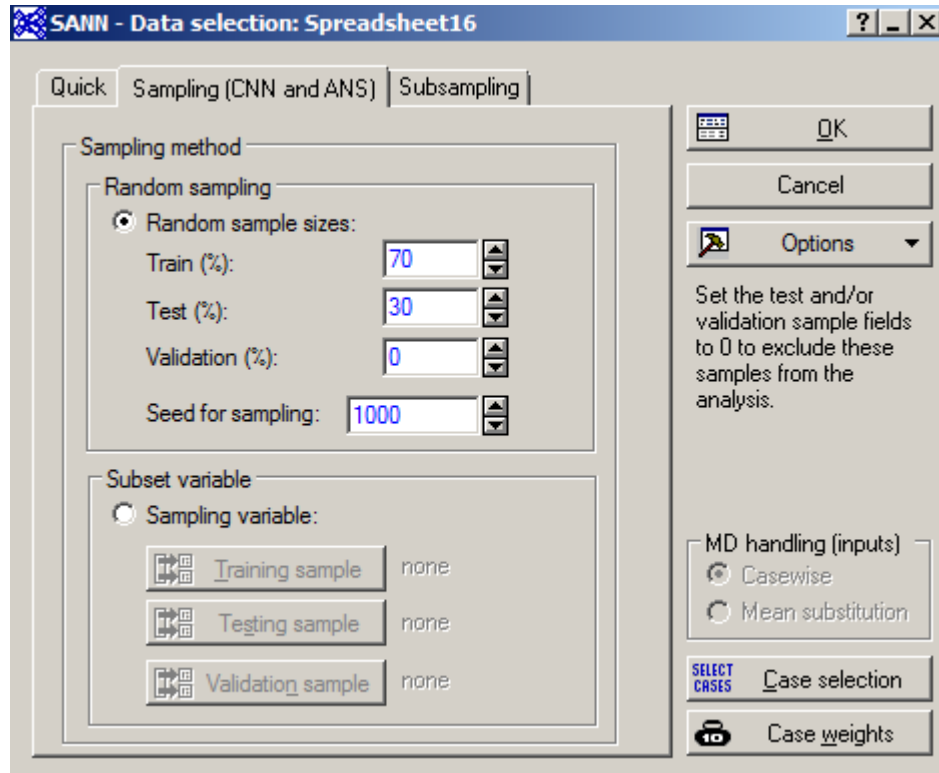


Рисунок 2.10 – Меню розподілу даних для навчальної та тестової вибірок

– навчання моделей:

- запуск навчання: виконання навчання моделей на навчальному наборі даних. STATISTICA надає зручний інтерфейс для контролю процесу навчання, включаючи візуалізацію метрик навчання та валідації в режимі реального часу;

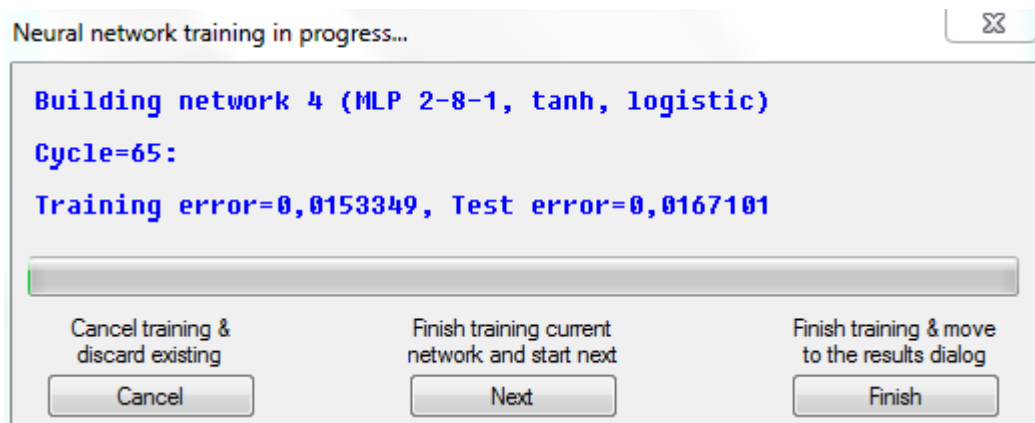


Рисунок 2.11 – Процес навчання НМ у програмі STATISTICA

- тюнінг гіперпараметрів: виконання налаштування гіперпараметрів моделей для оптимізації їх продуктивності. Це може включати використання методів крос-валідації або інших стратегій оптимізації.
- оцінка продуктивності моделей:
- валідація та тестування: оцінка продуктивності моделей на тестовому та валідаційному наборах даних. STATISTICA надає різні метрики для оцінки, такі як точність, прецизійність, F1-міра, середньоквадратична помилка тощо;

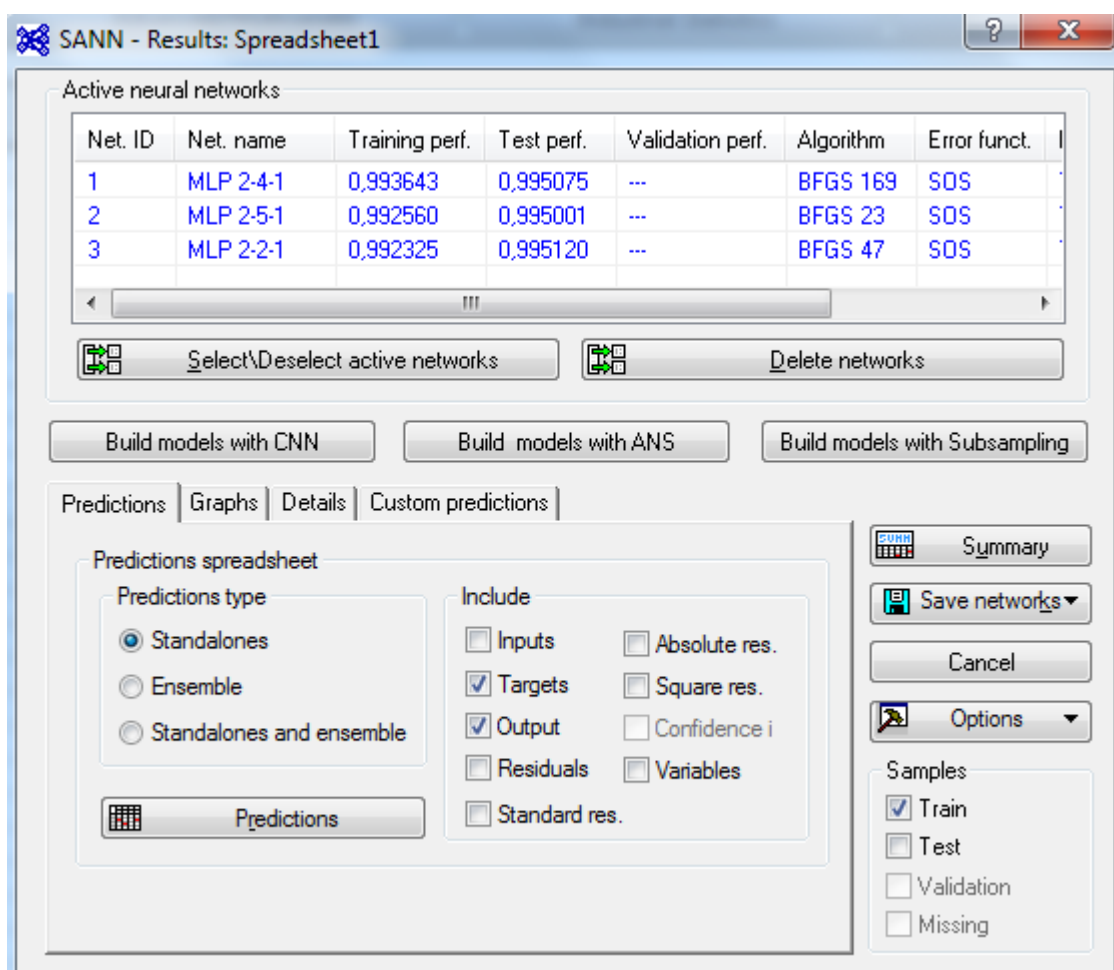
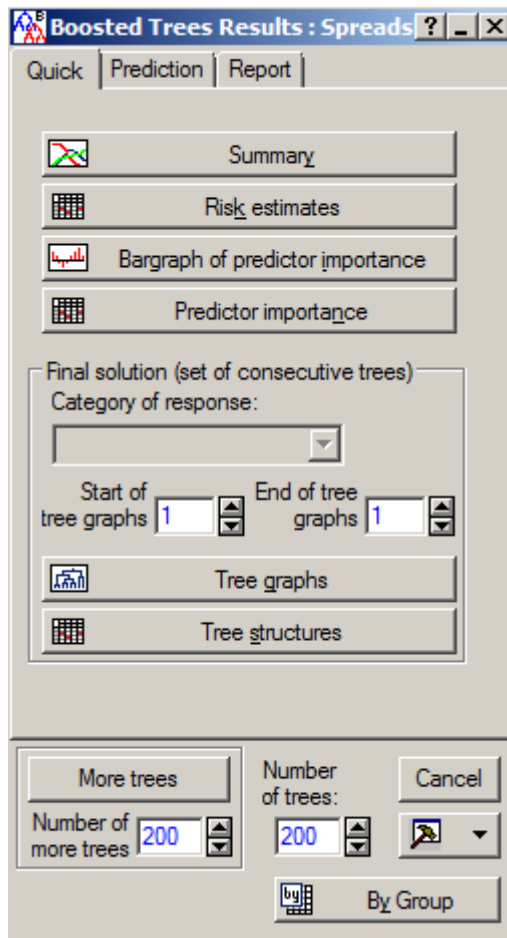
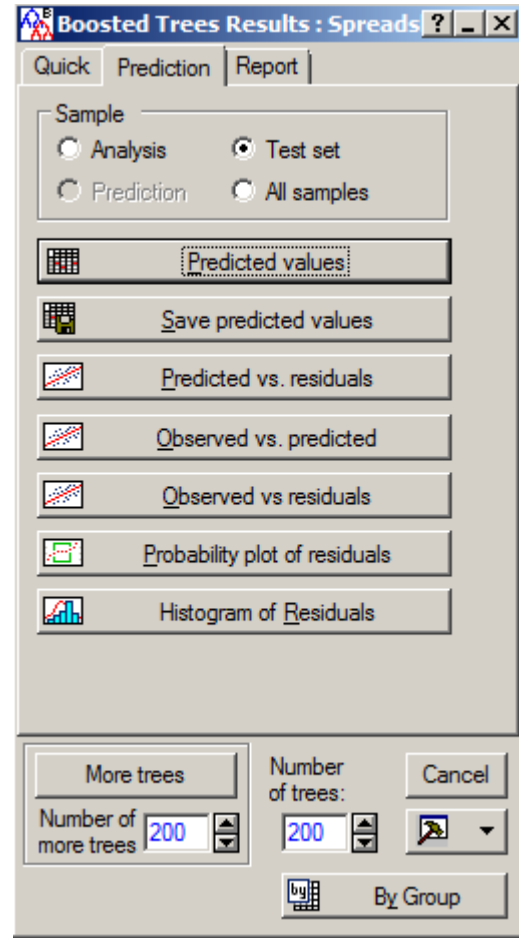


Рисунок 2.12 – Вікно побудованих НМ



a)



б)

Рисунок 2.13 – Вікно отриманих результатів методом підсилених дерев

- аналіз результатів: порівняння продуктивності різних моделей та аналіз їх результатів для вибору найкращої моделі;
- візуалізація результатів:
 - створення графіків та діаграм: використання інструментів STATISTICA для створення візуалізацій результатів, таких як діаграми розсіювання, гістограми, ROC-криві тощо;

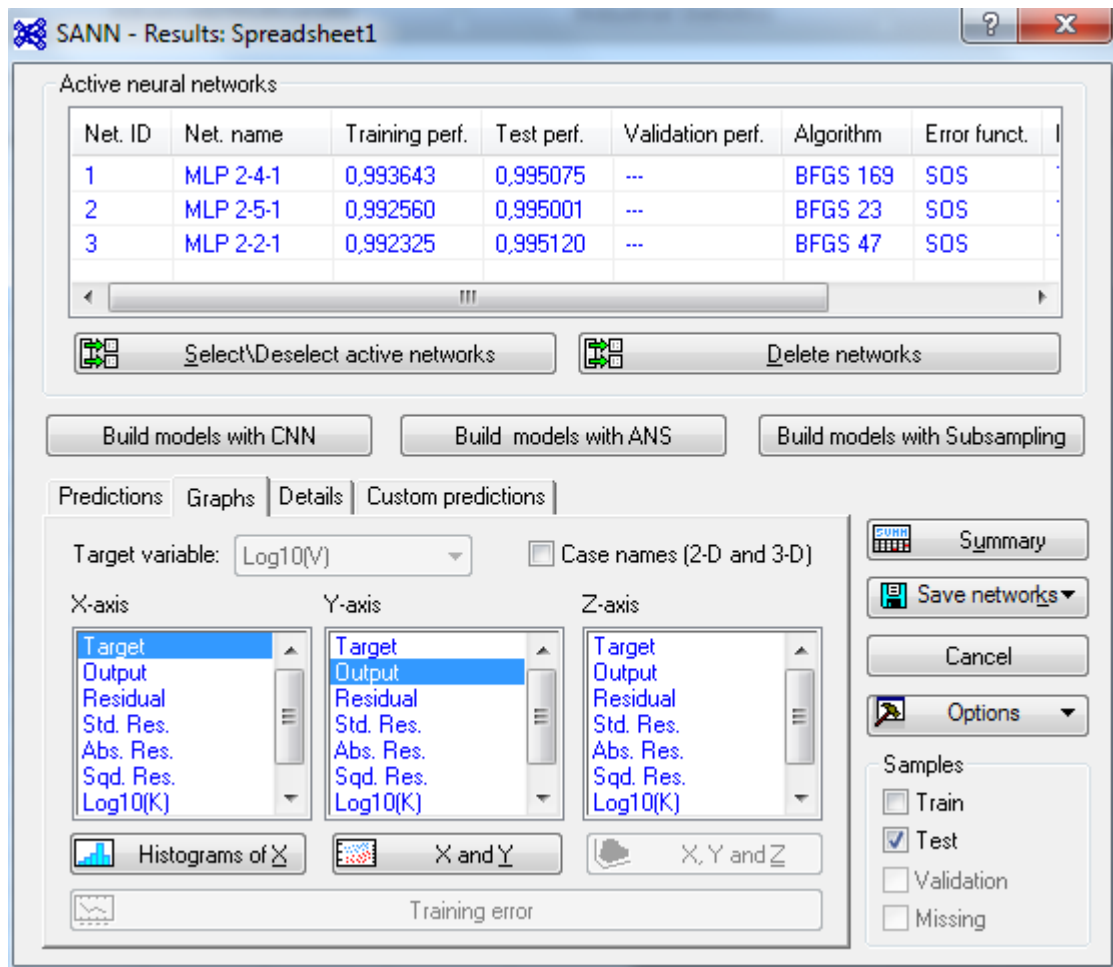


Рисунок 2.14 – Вікно у STATISTICA для створення візуалізацій результатів НМ

- інтерпретація моделей: візуалізація та інтерпретація важливих ознак моделей для кращого розуміння їх роботи та прийняття рішень на основі результатів;
- автоматизація та інтеграція:
 - автоматизація процесів: розробка скриптів для автоматизації повторюваних завдань, таких як підготовка даних, навчання моделей та оцінка їх продуктивності;

Predictions spreadsheet for Log10(V) (Spreadsheet1)							
Samples: Test							
Case name	Log10(V) Target	Log10(V) - Output 1. MLP 2-4-1	Log10(V) - Squared Res. 1. MLP	Log10(V) - Output	Log10(V) - Squared Res. 2-5-1	Log10(V) - Output 3. MLP 2-2-1	Log10(V) - Squared Res. 3. MLP 2-2-1
3	-9,74960	-9,59279			0,1712	-9,28630	0,215574
6	-9,02090	-9,19856					
7	-8,93550	-8,96411			21619	-9,04513	
8	-8,98300	-8,89621			03083	-8,99990	
12	-8,62160	-8,52862			01337	-8,61988	
14	-8,48280	-8,41084			00455	-8,47083	
17	-8,41230	-8,25751			11281	-8,28233	
19	-8,52290	-8,24756			52618	-8,27046	
20	-8,30100	-8,23794			00384	-8,25904	
21	-8,41230	-8,22830			20445	-8,24764	
25	-8,27160	-7,90403			48612	-7,88934	
32	-6,87290	-7,05182			29270	-7,07758	
34	-6,89960	-7,04217			18390	-7,06862	
35	-6,90310	-6,93696			01340	-6,97034	0,004521
43	-6,58170	-6,49360			03262	-6,53473	0,002206
45	-6,41910	-6,31498			06004	-6,34582	0,005370
50	-6,36750	-6,15084			41777	-6,16657	0,040375
54	-5,87610	-5,93229			01601	-5,92586	0,002476
56	-5,97880	-5,87358			16702	-5,86200	0,013643
57	-5,59010	-5,85807			58539	-5,84523	0,065092
58	-5,69900	-5,78637			02766	-5,76838	0,004813
59	-5,73050	-5,58219			40399	-5,55648	0,030283
60	-5,39790	-5,56815			13642	-5,54231	0,020853
62	-5,34970	-5,34701			03638	-5,32484	0,000618
70	-4,23210	-4,35793			07607	-4,29866	0,004430

Рисунок 2.15 – Оцінка точності прогнозування НМ

- інтеграція з іншими системами: налаштування інтеграції STATISTICA з іншими системами для автоматичного збору даних, виконання моделей та передачі результатів;
- документація та звітність:
- документація процесу: детальний опис усіх етапів роботи, включаючи вибір методів, налаштування моделей, результати оцінки та інтерпретацію результатів;
 - створення звітів: генерація звітів для представлення результатів моделювання та їх візуалізації керівництву та зацікавленим сторонам.

Розробка програмного забезпечення для моделювання швидкості РВТ із застосуванням STATISTICA включає кілька етапів, від збору та підготовки даних до навчання, оцінки та візуалізації моделей. Використання STATISTICA

дозволяє ефективно реалізувати та автоматизувати процеси машинного навчання, забезпечуючи високу точність та надійність моделей.

РОЗДІЛ 3. СПЕЦІАЛЬНА ЧАСТИНА

3.1 Аналіз результатів прогнозування швидкості РВТ алюмінієвого сплаву Д16Т


Експериментальне дослідження, яке вивчає втомні руйнування матеріалів, є надзвичайно складним і вимагає значних фінансових витрат. З огляду на ці труднощі, числове моделювання за допомогою методів МН стає важливою альтернативою фізичним експериментам [12-18]. Основна мета цього дослідження полягає у прогнозуванні швидкості РВТ алюмінієвого сплаву Д16Т під регулярним навантаженням з $R = 0,2$ та $R = 0,4$. Для цього застосовано різноманітні методи МН, що дозволяє уникнути явного визначення аналітичних моделей РВТ та порівняти отримані результати між собою.

Прогнозування швидкості РВТ здійснювалося на основі експериментальних даних, які були отримані у статті [16] для значень $R = 0,2$; $0,4$. Загальна вибірка складала 150 елементів, з яких 70% було випадковим чином відібрано для навчальної вибірки, а решта 30% були залишені для тестової вибірки, щоб оцінити якість прогнозування. Результати показали, що прогнозовані значення узгоджуються з експериментальними даними. Найточнішим методом виявилася НМ з похибкою прогнозування 2%. Для інших методів похибка становила: підсилені дерева - 8,7%, випадкові ліси - 8,5%.

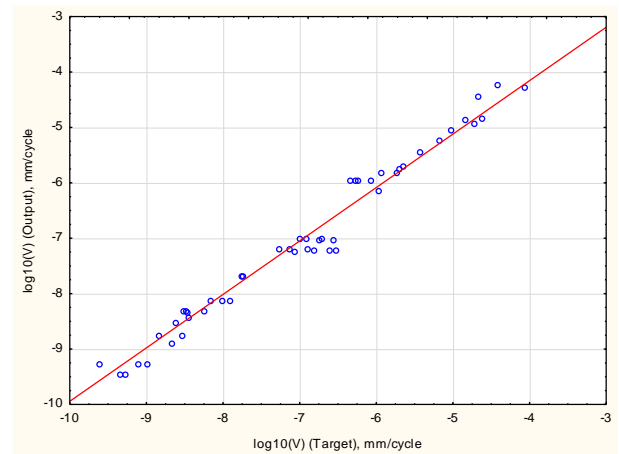
Варто зазначити, що точки на рис. 4.1 розташовані близько до бісектриси першого координатного кута, що свідчить про високу узгодженість між прогнозованими та експериментальними даними [14].

Для прогнозування швидкості РВТ методом НМ була побудована багатошарова мережа (MLP) з архітектурою 2-7-1, де застосовувалася логарифмічна функція активації у прихованому шарі та логарифмічна функція активації у вихідному шарі. Коефіцієнт кореляції для тестової вибірки становив 0,99, що підтверджує високу точність моделі. Для побудови моделей підсилених дерев та випадкових лісів використовувалося по 200 дерев.

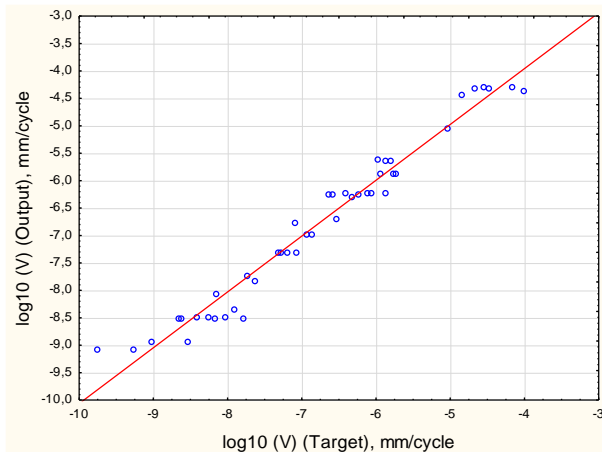
Цей підхід до моделювання та прогнозування дозволяє значно скоротити витрати та час, необхідні для експериментальних досліджень, забезпечуючи при цьому високу точність результатів. Впровадження таких моделей у виробничі процеси може підвищити надійність та довговічність конструкцій, що використовуються в авіабудуванні, машинобудуванні та інших галузях промисловості.



а)

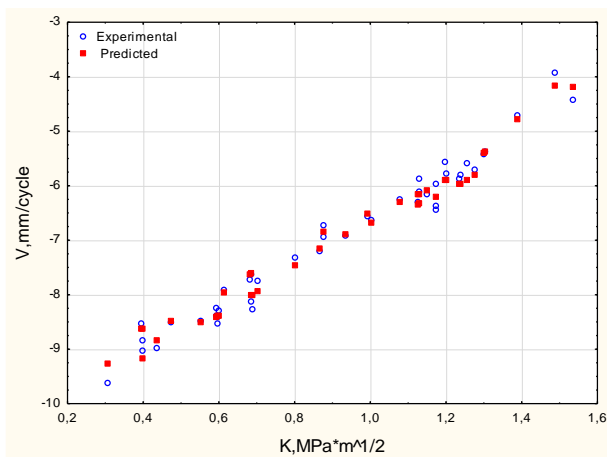


б)

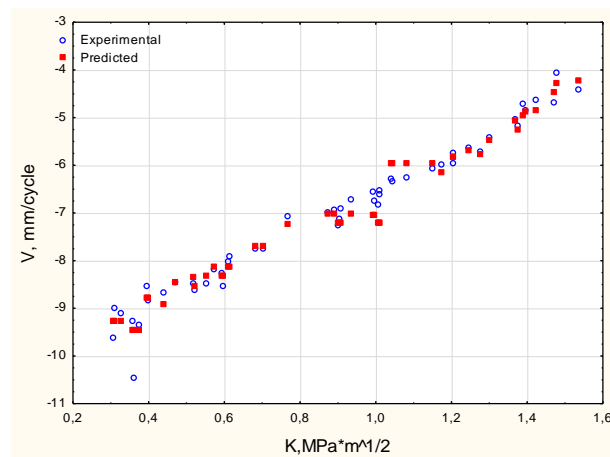


в)


Рисунок 4.1 – Прогнозовані (V) (*Output*) та експериментальні (V) (*Target*) швидкості РВТ одержані методом НМ (а), підсилених дерев (б), випадкових лісів (в)



а)




б)




в)

Рисунок 4.2 – Прогнозовані та експериментальні залежності швидкості РВТ від КІН отримані методом НМ (а), підсилених дерев (б), випадкових лісів (в)

На рис. 4.3 показано залежність середньоквадратичної похибки прогнозування від кількості дерев методом підсилених деревах та випадкових лісах. Зокрема, похибка навчання тестової вибірки стабілізується після побудови 200 дерев. Додатково, на рис. 4.4 та 4.5 показано найбільший вплив вхідних параметрів.



a)



б)

Рисунок 4.3 – Розрахована похибка в залежності від кількості дерев, отримана за допомогою методу підсилених дерев (а) та випадкових лісів (б)

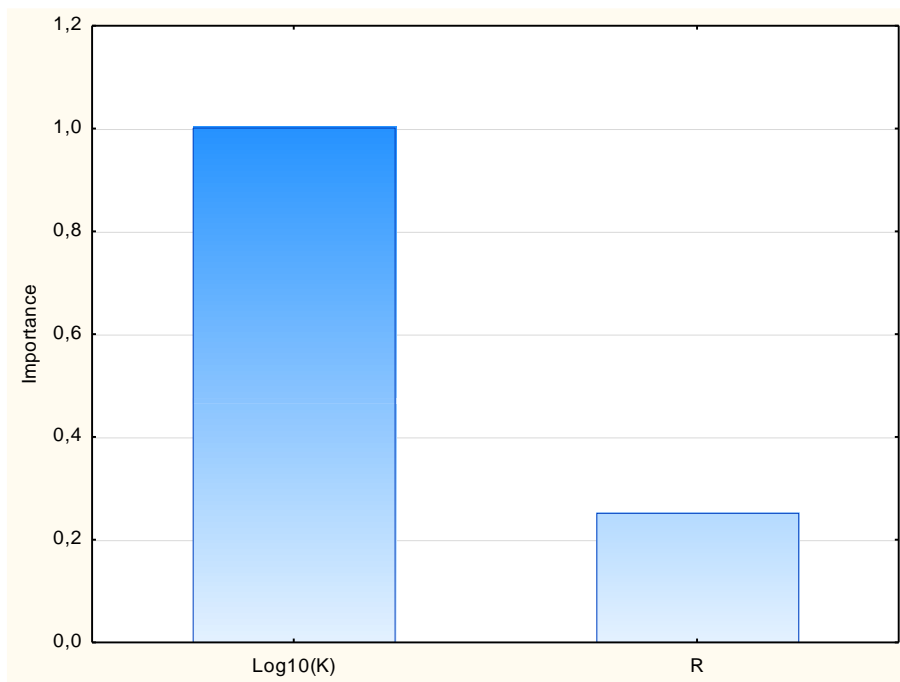


Рисунок 4.4 – Важливість впливу вхідних параметрів методом підсилених дерев

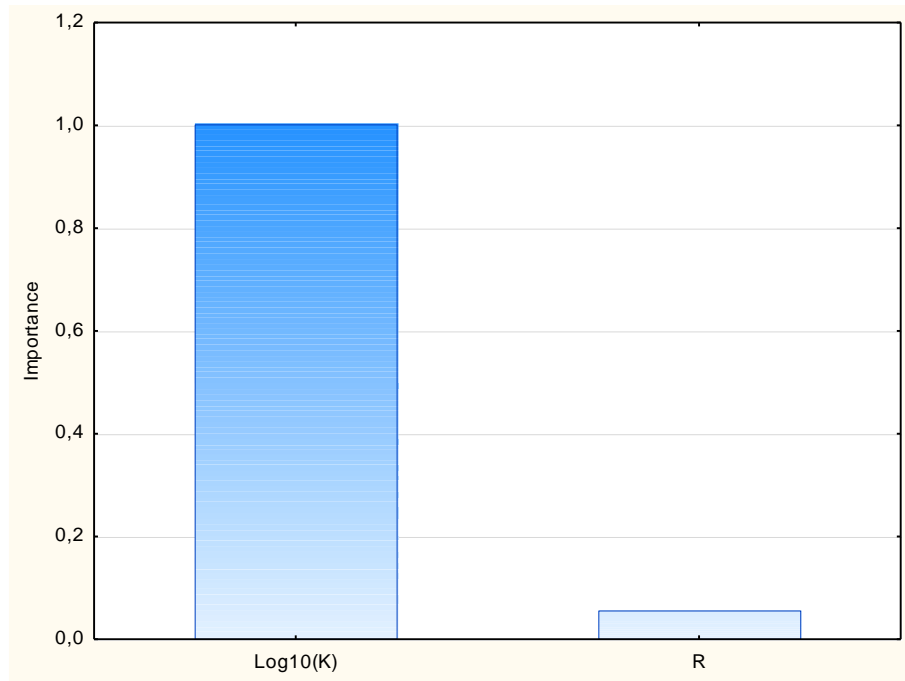




Рисунок 4.5 – Важливість впливу вхідних параметрів методом випадкових лісів

Для аналізу даних часто застосовують статистичний графік у вигляді діаграм залишкових значень. Виявлено, що залишки мають нормальний розподіл.


На рис. 4.6 показано діаграму залишкових значень, отримана за допомогою методу НМ, підсилених дерев та випадкових лісів.



а)



б)



в)

Рисунок 4.6 – Діаграма залишкових значень, отримана за допомогою методу НМ (а), підсилених дерев (б) та випадкових лісів (в)

Отже, розглянуто результати моделювання, їх верифікацію, валідацію та оптимізацію, а також порівняння з експериментальними даними. Виявлено, що метод НМ дає найбільшу точність прогнозування.

3.2 Порівняння результатів з експериментальними даними

Детальний аналіз отриманих результатів моделювання експлуатаційних характеристик матеріалів на основі алюмінію методами МН відіграє важливу роль. Зокрема, основними аспектами аналізу є:

- оцінка точності моделей: а саме, аналіз точності прогнозів кожної з моделей (НМ, підсилені дерева, випадкові ліси) на основі метрик продуктивності, таких як середньоквадратична помилка (MSE), точність (accuracy), F1-міра та інші;
- порівняння моделей: тобто, порівняння продуктивності різних моделей МН для визначення найефективніших методів прогнозування експлуатаційних характеристик;

- аналіз важливості ознак: зокрема, оцінка важливості різних ознак (факторів), які впливають на експлуатаційні характеристики матеріалів, для розуміння того, які з них є найбільш значущими.

Процес верифікації та валідації є критично важливим для оцінки надійності та точності моделей МН. Зокрема, перевірка правильності реалізації моделей, включаючи перевірку коду, використання правильних алгоритмів та процедур, а також коректність вхідних даних. А також оцінка моделей на валідаційних наборах даних для перевірки їх узагальнюючої здатності є важливою. Це включає використання методів крос-валідації та перевірку моделей на нових даних, які не використовувалися під час навчання. Зокрема, аналіз стабільності моделей за різних умов та наборів даних для виявлення можливих аномалій та перевірки наявності перенавчання впливає на точність моделювання.

Для перевірки точності та надійності моделей необхідно порівняти результати моделювання з реальними експериментальними даними. Зокрема, вивчення відхилень між прогнозованими та реальними значеннями для виявлення можливих причин розбіжностей та їх виправлення на точність моделювання. А також важливою є перевірка узгодженості моделей з експериментальними даними для підтвердження їхньої надійності та точності.

РОЗДІЛ 4. БЕЗПЕКА ЖИТТЄДІЯЛЬНОСТІ, ОСНОВИ ОХОРОНИ ПРАЦІ

4.1 Характеристика шкідливих факторів 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 розлитої 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.

4.2 Забезпечення безпеки життєдіяльності при роботі з ПК

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 антиполюсківі 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. Раціональною 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 почував 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 кондиціонування 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 сторонні 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 даній роботі було проведено ґрунтовне дослідження можливостей МН для моделювання та прогнозування втомного руйнування алюмінієвого сплаву Д16Т. Використання методів МН, таких як НМ, підсилені дерева та випадкові ліси, дозволило досягти високої точності прогнозування ДВР за різних умов навантаження. НМ продемонстрували найвищу точність прогнозування зі середньою похибкою 2%. Тоді як підсилені дерева та випадкові ліси мали дещо вищу похибку, відповідно 8,7% та 8,5%, але все ж таки забезпечували прийнятний рівень точності.

Використання МН дозволяє значно скоротити час та витрати на проведення фізичних експериментів. Застосування програмного забезпечення STATISTICA для моделювання значно спрощує процес аналізу та прогнозування, надаючи зручний інтерфейс та потужні інструменти для обробки даних.

Вибір методів МН, таких як НМ, підсилені дерева та випадкові ліси, був обґрунтований їхньою здатністю виявляти приховані залежності та структури в даних. Зокрема, комбінування різних методів дозволяє підвищити надійність прогнозування та мінімізувати вплив можливих похибок одного конкретного методу.

Загалом, впровадження цих моделей у виробничі процеси дозволить підвищити надійність та безпеку експлуатації технічних систем, знизивши ризики аварій та поломок.

Робота показала, що використання методів МН для прогнозування втомного руйнування алюмінієвих сплавів є перспективним напрямком, який може суттєво вплинути на розвиток інженерних практик та підвищення надійності конструкційних матеріалів. Отримані результати підтверджують доцільність застосування числового моделювання в інженерних дослідженнях та відкривають нові можливості для оптимізації виробничих процесів.

ПЕРЕЛІК ПОСИЛАНЬ

1. Kuna M. Finite Elements in Fracture Mechanics: Theory-Numerics-Applications. Springer, 2013. 446 p.
2. Ясній П.В. Пластично деформовані матеріали: втома і тріщиностійкість. Львів: Світ, 1998. 292 p.
3. 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.
4. 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.
5. Paris P.C. The growth of fatigue cracks due to variations in load : Ph.D.Thesis. Lehigh University, 1962. 263 p.
6. Alpayndin E. Introduction to Machine Learning // The Knowledge Engineering Review. 2010. Vol. 25, № 3. P. 353–353.
7. Haykin S. Neural Networks - A Comprehensive Foundation - Simon Haykin. McMaster University, Hamilton, Ontario, Canada, 2006. P. 823.
8. Wasserman Ph.D. Neural Computing: Theory and Practice. New York: Coriolis Group (Sd), 1989.
9. Mitchell T.M. Machine learning. London: McGraw-Hill Science/Engineering/Math, 1997.
10. Шаховська Н.Б., Камінський Р.М., Вовк О.Б. Системи штучного інтелекту: навч. посібник. Львів: Видавництво Львівської політехніки, 2018. 392 p.
11. Smola A., Vishwanathan S.V.N. Introduction to Machine Learning. Cambridge University Press, 2010.
12. 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.

13. 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.
14. 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.
15. Didych I. et al. Evaluation of structural elements lifetime by neural network // *Acta Metallurgica Slovaca*. 2018. Vol. 24, № 1. P. 82–87.
16. 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.
17. Didych, I., Yasniy, O., Pasternak, I., & Sobashek, L. (2022). Modelling of AL-6061 aluminum alloy deformation diagrams by machine learning methods. *Procedia Structural Integrity*, 42, 1344-1349.
18. Yasniy, O., Pastukh, O., Didych, I., Yatsyshyn, V., & Chykhira, I. (2023). Application of machine learning for modeling of 6061-T651 aluminum alloy stress– strain diagram. *Procedia Structural Integrity*, 48, 183-189.

