

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: **Застосування методів машинного навчання для прогнозування
діаграм втомного руйнування алюмінієвих сплавів**

Виконав: студент 6 курсу, групи КТМ-61
спеціальності 151 – Автоматизація та комп'ютерно-
інтегровані технології
(шифр і назва спеціальності)

(підпис)

Черняк Д.В.

(прізвище та ініціали)

Керівник

(підпис)

Дідич І.С.

(прізвище та ініціали)

Нормоконтроль

(підпис)

Чихіра І.В.

(прізвище та ініціали)

Завідувач кафедри

(підпис)

Микитишин А.Г.

(прізвище та ініціали)

Рецензент

(підпис)

Дмитрів О.Р.

(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)

« 20 » листопада 2023 р.

З А В Д А Н Н Я
НА КВАЛІФІКАЦІЙНУ РОБОТУ

на здобуття освітнього ступеня магістр
(назва освітнього ступеня)

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

студенту Черняку Дмитрію Віталійовичу
(прізвище, ім'я, по батькові)

1. Тема роботи Застосування методів машинного навчання для прогнозування діаграм втомного руйнування алюмінієвих сплавів

Керівник роботи Дідич Ірина Степанівна, доктор філософії

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

Затверджені наказом ректора від « 20 » листопада 2023 року № 4/7-1087

2. Термін подання студентом завершеної роботи 22.12.2023 р.

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

АНОТАЦІЯ

Застосування методів машинного навчання для прогнозування діаграм втомного руйнування алюмінієвих сплавів // Кваліфікаційна робота освітнього рівня «Магістр» // Черняк Дмитрій Віталійович // Тернопільський національний технічний університет імені Івана Пулюя, факультет прикладних інформаційних технологій та електроінженерії, кафедра комп'ютерно-інтегрованих технологій, група КТМ-61 // Тернопіль, 2023 // С. 75, рис. – 37, табл. – 0, додат. – 1, бібліогр. – 19.

Ключові слова: штучний інтелект, машинне навчання, нейронні мережі, підсилені дерева, випадкові ліси, метод k -найближчих сусідів, метод опорно-векторних машин, ріст втомної тріщини, діаграма втомного руйнування.

Кваліфікаційна робота присвячена моделюванню діаграм втомного руйнування різними методами машинного навчання, а саме, нейронними мережами, підсиленими деревами, випадковими лісами, опорно-векторними машинами, k -найближчими сусідами.

Метою роботи є:

У першому розділі кваліфікаційної роботи проаналізовано втомне руйнування, кінетичну ДВР матеріалів, зроблено огляд основних рівнянь для опису швидкості РВТ та розглянуто роль асиметрії циклу навантаження як один із основних факторів, що впливає на швидкість РВТ.

У другому розділі кваліфікаційної роботи зроблено огляд сучасних досягнень у використанні машинного навчання для аналізу втоми матеріалів та показано роль машинного навчання для дослідження втоми матеріалів.

У третьому розділі кваліфікаційної роботи проаналізовано та вибрано ефективні алгоритми штучного інтелекту.

У четвертому розділі кваліфікаційної роботи розглянуто процес збору, обробки та підготовки даних для моделювання, спрогнозовано ДВР алюмінієвого сплаву та проаналізовано результати якості прогнозування.

В п'ятому розділі кваліфікаційної роботи показано реалізацію та навчання моделей машинного навчання на підготовлених даних.

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

ANNOTATION

The use of machining learning methods in diagram forecasting of aluminum alloys fatigue failure // Qualification work of educational level «Master» // Cherniak Dmytrii Vitaliiiovych // Ternopil Ivan Puluj National Technical University, Faculty of Applied Information Technologies and Electrical Engineering, Department of Computer-Integrated Technologies, group KTm-61 // Ternopil, 2023 // P. 75, Fig. – 37, Tables. – 0, Annexes. – 1, References. – 19.

Keywords: artificial intelligence, machine learning, neural networks, booster trees, random forests, method of k -nearest neighbors, support-vector machine, fatigue crack growth, fatigue crack growth diagram.

The qualification work is devoted to the modeling of fatigue failure diagrams by various machine learning methods, namely, neural networks, boosted trees, random forests, support-vector machines, k -nearest neighbors.

The aim of the work is:

The first section of the qualification work analyzes fatigue fracture, kinetic FCG diagram of materials, reviews the basic equations for describing the FCG rate, and considers the role of load cycle asymmetry as one of the main factors affecting the FCG rate.

The second chapter of the qualification work provides an overview of current advances in the use of machine learning for material fatigue analysis and shows the role of machine learning in material fatigue research.

The third chapter of the qualification work analyzes and selects effective artificial intelligence algorithms.

Chapter fourth of the thesis describes the process of collecting, processing, and preparing data for modeling, predicting of FCG diagram of aluminum alloy, and analyzing the results of the prediction quality.

The fifth chapter of the qualification work shows the implementation and training of machine learning models on the prepared data.

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

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 (англ. Machine Learning) – машинне навчання;

НМ (англ. Neural Networks) – нейронні мережі;

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

ВТ (англ. Boosted Trees) – підсилені дерева;

RF (англ. Random Forest) – випадкові ліси;

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

ЗМІСТ

ВСТУП.....	10
РОЗДІЛ 1. АНАЛІТИЧНА ЧАСТИНА	12
1.1 Втомне руйнування.....	12
1.2 Кінетична діаграма втомного руйнування матеріалів.....	14
1.3 Огляд основних рівнянь для опису швидкості РВТ	16
1.4 Роль асиметрії циклу навантаження.....	
РОЗДІЛ 2. ТЕХНОЛОГІЧНА ЧАСТИНА	20
2.1 Огляд сучасних досягнень у використанні машинного навчання для аналізу втоми матеріалів	12
2.2 Роль машинного навчання у дослідженні втоми матеріалів	14
РОЗДІЛ 3. КОНСТРУКТОРСЬКА ЧАСТИНА	23
3.1 Опис алгоритмів штучного інтелекту	25
3.2 Вибір та обґрунтування методів машинного навчання	23
3.3 Архітектура нейронних мереж	26
3.4 Алгоритм підсилених дерев	32
3.5 Метод випадкових лісів.....	36
3.6 Метод k -найближчих сусідів.....	39
3.7 Метод опорно-векторних машин.....	40
РОЗДІЛ 4. НАУКОВО-ДОСЛІДНА ЧАСТИНА.....	43
4.1 Процес збору, обробки та підготовки даних для моделювання.....	43
4.2 Поділ даних на навчальний та тестовий набори.....	44
4.3 Прогнозування діаграм втомного руйнування алюмінієвого сплаву Д16Т.....	44
4.4 Аналіз результатів якості прогнозування.....	45
РОЗДІЛ 5. СПЕЦІАЛЬНА ЧАСТИНА.....	51
5.1 Реалізація та навчання моделей на підготовлених даних	51
РОЗДІЛ 6. ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ	65
6.1 Характеристика шкідливих факторів виробничого середовища	65

6.2 Забезпечення безпеки життєдіяльності при роботі з ПК.....	67
ВИСНОВКИ.....	72
ПЕРЕЛІК ДЖЕРЕЛ.....	74

ДОДАТКИ

ВСТУП

Актуальність теми. Багато елементів конструкцій втрачають свою міцність через втому, накопичуючи пошкодження під дією навантаження. Тому, для вчасного виявлення та вирішення проблем, прогнозування довговічності елементів конструкцій є важливим у машино- та авіабудуванні, металургії тощо.

Синхронізація результатів прогнозування з комп'ютерно-інтегрованими технологіями для автоматизації процесів та прийняття рішень дозволяють оптимізувати механічні системи з неймовірною точністю. Відомо, що однією з причин поширення штучного інтелекту є зростання обсягу даних, котрі пов'язані з втомою матеріалів. Тому, за наявності експериментальних даних, доцільно застосовувати методи машинного навчання, а саме, нейронних мереж, підсилених дерев, випадкових лісів, опорно-векторних машин, k -найближчих сусідів для дослідження діаграм втомного руйнування алюмінієвих сплавів. Проведення таких моделювань дозволить підвищити надійність елементів конструкцій.

Мета і задачі дослідження: прогнозування ДВР алюмінієвих сплавів різними методами машинного навчання.

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

Практичне значення одержаних результатів. Моделі машинного навчання можуть надавати точні та швидкі прогнози, аналізуючи складні залежності між даними. Однією з важливих проблем є вивчення втоми матеріалів, зокрема, алюмінієвих сплавів, котрі часто використовують у різних галузях виробництва, оскільки втома є критичним фактором, котрий впливає на міцність елементів конструкцій. Тому, методи машинного навчання володіють потужним потенціалом у виявленні залежності між різними фізико-хімічними властивостями сплавів та їхньою поведінкою за циклічним навантаженням.

З одного боку, врахування втоми, котра накопичується в конструкціях, є важливим для оптимізації матеріалів. Тобто, здатність точно прогнозувати ДВР алюмінієвих сплавів дозволяє підвищити міцність та тривалість служби

матеріалів. З іншого боку, застосування методів машинного навчання допомагає у визначенні оптимальних умов та параметрів, сприяючи зменшенню витрат на експериментальні дослідження, котрі часто є складними та затратними.

Крім того, ефективні моделі машинного навчання, котрі застосовують для прогнозування ДВР алюмінієвих сплавів, сприяють швидкому та точному проектуванню конструкцій. Зокрема, це дозволяє уникнути непередбачених ситуацій на виробництві та підвищити надійність конструкцій.

Загалом, застосування штучного інтелекту, зокрема, методів машинного навчання, а саме, нейронним мереж, підсилених дерев, випадкових лісів, опорно-векторних машин, k -найближчих сусідів для прогнозування ДВР алюмінієвих сплавів є важливим напрямком у розв'язку різних задач. Зокрема, даний підхід дозволяє автоматизувати та вдосконалити прогнозування ДВР, тобто швидкості РВТ, на основі здобутих знань моделі.

РОЗДІЛ 1. АНАЛІТИЧНА ЧАСТИНА

1.1 Втомне руйнування

Втомне руйнування елементів конструкцій називають явище в матеріалах, котре виникає внаслідок циклічного навантаження та розвантаження. Воно є однією з основних причин втомної поломки металевих конструкцій та матеріалів.

Під час дії циклічних навантажень можуть виникати тріщини, зокрема, навіть якщо ці навантаження є нижчими за межу міцності матеріалу. Тобто, на втому впливає низка чинників, а саме тріщиностійкість, зміна форми та структури кристалів у самому матеріалі або накопичення дефектів, асиметрія, частота, вид циклу навантаження, середовище, у якому використовується деталь. Загалом, є низка параметрів, котрі впливають на довговічність відповідальних елементів конструкцій [1].

Для уникнення або мінімізації втомного руйнування інженери використовують різні методи, такі як удосконалення дизайну конструкцій, вибір матеріалів з високою стійкістю до втомного руйнування, застосування термічних обробок і спеціальних покриттів, а також врахування умов експлуатації та розрахунків на втому при проектуванні.

Прикладами є тріщини в будівлях і деталях двигуна, повне обвалення мостів, розрив суден та розпад компонентів транспортних засобів (рис. 1.1). Загалом, причинами є невиявлені дефекти в матеріалі або компонентах, недостатнє розмірювання конструкції порівняно із фактичним навантаженням або застосування матеріалів із недостатньою міцністю. На сьогоднішній день гарантування безпеки, довговічності та надійності технічних конструкцій, компонентів та споруд має велике значення. Помилки в інженерії в цій області можуть мати катастрофічні наслідки [2].



Рисунок 1.1 – Обвалення мосту під час землетрусу [2]

Тому важливою є структура атомних зв'язків матеріалу, зокрема, знання процесів руйнування на різних масштабах сприяють розумінню міцності елементів конструкцій та їх поведінки (рис. 1.2). Загалом, у механіці руйнування поведінку тріщин описують на макроскопічному рівні.

Числове моделювання тріщин та дефектів є ключовим інструментом на всіх рівнях моделювання [3,4]. За допомогою тестів на простих зразках з елементарними умовами навантаження (наприклад, випробування на розтягування), визначаються критичні значення міцності матеріалу, вимірюючи початок руйнування. Для забезпечення безпеки компонентів необхідно, щоб максимальні навантаження залишалися нижче критичних параметрів міцності, що загалом виражається як критерій міцності.

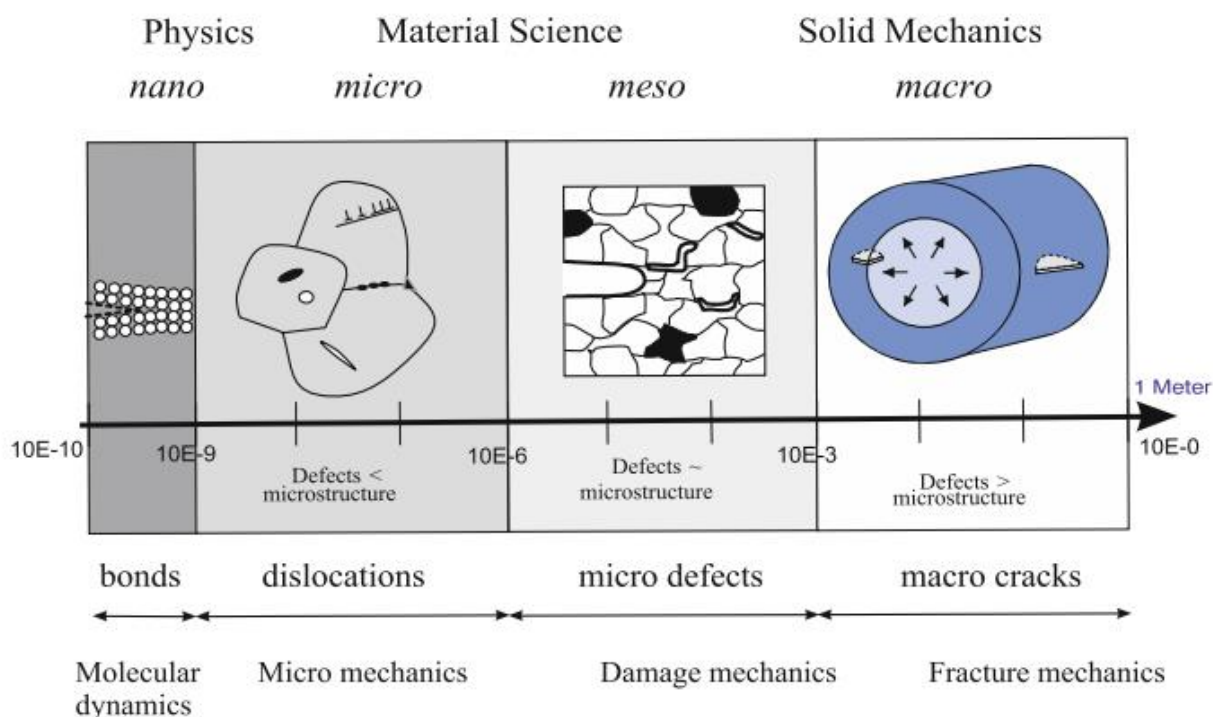


Рисунок 1.2 – Руйнування у різних масштабах і рівнях [2]

1.2 Кінетична діаграма втомного руйнування матеріалів

Кінетична діаграма втомного руйнування матеріалів відображає залежність тривалості життя матеріалу від циклічного навантаження та є важливим інструментом для розуміння механічної поведінки матеріалів під умовами навантаження, котре може призвести до втомного руйнування [5].

Для передбачення довговічності тіл з тріщинами при циклічному навантаженні необхідно аналізувати залежність швидкості РВТ від параметра, що визначає НДС в околі вістря тріщини. Графічне представлення цієї залежності називають ДВР.

Загалом, швидкість РВТ у логарифмічних координатах $lgV - lg\Delta K (K_{max})$ представляє собою S-подібну криву. Ця крива обмежена зліва максимальним пороговим коефіцієнтом інтенсивності напружень КІН (пороговим ΔK_{th}) і справа - критичним КІН K_{fc} (циклічною в'язкістю руйнування) (рис.1.3).




Рисунок 1.3 – Діаграма втомного руйнування [1]

Діаграма складається з трьох ділянок:

- ділянка I, де швидкість V приблизно $10^{-10} \dots 10^{-8}$ м/цикл;
- ділянка II з прямолінійною формою при $10^{-8} \dots 10^{-6}$ м/цикл;
- ділянка III з прискореним ростом при $V > 10^{-6}$ м/цикл.

Ці ділянки називають відповідно: низькоамплітудна, середньоамплітудна і високоамплітудна.

Відомо, що на ділянках I і III мікроструктура сплавів, рівень середніх напружень, температура і корозійне середовище значно впливають на РВТ. Тоді як ділянка II менш чутлива до цих факторів. В загальному випадку, моделі швидкості РВТ поділяють на силові, енергетичні і деформаційні, в залежності від використаних критеріїв.

ДВР є основним інструментом для інженерів та матеріалознавців при проектуванні і оцінці втомної міцності матеріалів, особливо там, де діють

циклічні навантаження, такі як у випадку металевих конструкцій, авіаційної техніки або інших високо навантажених систем.

1.3 Огляд основних рівнянь для опису швидкості РВТ

Врахування рівнянь та концепцій дозволяє інженерам та науковцям розуміти та прогнозувати РВТ в матеріалах під впливом циклічних навантажень. Однак слід зазначити, що реальні умови можуть бути складнішими, і враховують багато інших факторів, таких як температура, середовище, форма тріщини та мікроструктура матеріалу [6].

Швидкість РВТ описується різними рівняннями та законами, залежно від конкретних умов, матеріалу та середовища.

Розглянемо моделі, котрі є найпоширеніші у застосуванні. Швидкість РВТ описують такою 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} – найменше та найбільше напруження циклу навантаження; a – довжина тріщини, N – кількість циклів навантаження. $\Delta K = K_{max} - K_{min}$; тут K_{max} , K_{min} – найбільший і найменший КІН. Тобто, $\Delta K = \sigma\sqrt{\pi a} \cdot Y$, де Y – функція, котра визначається геометрією конструкції та тріщини.

Уперше такий підхід запропоновано Перісом [34]:

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

де C і m – параметри матеріалу.

Формулою (1.2) найчастіше описують швидкість РВТ. Загалом, вона добре описує II ділянку ДВР. Додатково, параметри C та m для різних матеріалів

можуть значно змінюватись. Однак, у формулі 1.2 не враховано вплив асиметрії циклу навантаження R на швидкість РВТ, збільшення якого призводить до збільшення швидкості РВТ.

Ріст втомних тріщин на II ділянці ДВР також описують рівнянням Уолкера, де враховано вплив асиметрії циклу навантаження R на швидкість РВТ:

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

де C, m, n – параметри матеріалу, визначені експериментально.

Зокрема, лінійну ділянку ДВР матеріалів описують модифікованою формулою С.Я. Яреми:

$$V = 10^{-7} \left(\frac{\Delta K}{\Delta K^*} \right)^m \quad (1.4)$$

де ΔK^* - розмах КІН на ділянці, що відповідає швидкості РВТ 10^{-7} мм/цикл.

Зокрема, Форман запропонував рівняння для опису залежності швидкості РВТ від КІН, враховуючи високі значення ΔK , що приблизно рівне циклічній в'язкості руйнування K_{fc} :

$$\frac{da}{dN} = \frac{C(\Delta K)^m}{(1-R)K_c - \Delta K} \quad (1.5)$$

Відомо, що для рівняння (1.5) потрібно отримати експериментальним шляхом параметри: C, m , і критичне значення коефіцієнта інтенсивності напруги K_{fc} .

Загалом, визначення швидкості РВТ включає в себе послідовне вимірювання характерного розміру тріщини l , а саме довжини або глибини у зразку через задані проміжки часу, виражені кількістю циклів навантаження (ΔN). Далі обчислюється швидкість РВТ, котра представляє собою середній приріст тріщини за один цикл. Отримані значення швидкості РВТ пов'язують з

параметром руйнування, який контролює стан матеріалу та руйнівний процес неподалік фронту тріщини.

Метод визначення втомної тріщиностійкості застосовується для вивчення впливу технологічних факторів. Зокрема, ці дані використовують для оцінки працездатності матеріалу і конструкцій під час експлуатації та на етапі виготовлення. Вони дозволяють проводити оцінку допустимості виявлених дефектів та визначати методи контролю.

1.4 Роль асиметрії циклу навантаження

Асиметрія циклу навантаження R є одним із ключових експлуатаційних факторів, які значно впливають на швидкість РВТ. Тому параметр R здебільшого є у формулах, котрими моделюють РВТ. Цей термін вказує на нерівномірність або неоднаковість умов циклічного навантаження, котрі впливають на матеріал чи конструкцію. Асиметрія може виникати внаслідок низьких амплітуд циклічних навантажень, різниці пасивних і активних фазах циклу, або інших змін у характері навантаження. У випадку аналізу залежності швидкості РВТ від максимальної інтенсивності напружень (K_{max}), збільшення коефіцієнта асиметрії циклу навантаження R від 0,1 до 0,9 суттєво зменшує швидкість РВТ у сталях та зварних швах [1].

Асиметричні цикли можуть викликати дисбаланс напружень та деформацій в матеріалі, що сприяє розвитку та росту втомних тріщин. Зокрема, в області, де сприймається негативний ефект асиметрії циклу, може спостерігатися прискорення росту тріщин.

Інтенсивність циклічних навантажень може змінюватися внаслідок асиметрії циклу, що впливає на швидкість РВТ. Такі зміни можуть враховуватися при визначенні параметрів для рівнянь втомної тріщиностійкості, в таких як рівняння Періса або інші, які враховують вплив умов циклічного навантаження на матеріал.

З одного боку, асиметрія циклу важливий аспект для розуміння та прогнозування втомної тріщиноустійкості матеріалів і конструкцій в умовах реальної експлуатації.

З іншого, в алюмінієвих сплавах асиметрія циклу може бути особливо важливою, оскільки ці матеріали мають свої унікальні властивості та чутливість до циклічних навантажень. Під впливом асиметрії, яка може виникати внаслідок різниці в температурі, середовищі експлуатації, та інших факторів, може спостерігатися збільшення напруги та деформацій в матеріалі.

Збільшення асиметрії циклу може привести до змін в інтенсивності напружень та розподілу деформацій в алюмінієвих сплавах, що, в свою чергу, впливає на швидкість росту втомних тріщин. Такі тріщини можуть виникати та розширюватися під впливом навантаження, особливо при циклічних навантаженнях з нерівномірними параметрами.

Отже, асиметрія циклу в експлуатаційних умовах може бути значущим чинником, що впливає на тріщиноутворення та швидкість РВТ в алюмінієвих сплавах.

РОЗДІЛ 2. ТЕХНОЛОГІЧНА ЧАСТИНА

2.1 Огляд сучасних досягнень у використанні машинного навчання для аналізу втоми матеріалів

Машинне навчання – це галузь штучного інтелекту, що вивчає побудову алгоритмів, які можуть навчатися на основі наявних даних. Задача МН полягає у знаходженні прихованих залежностей між прикладами та відповідями для прогнозування на основі нових даних [7,8].

Огляд сучасних досягнень у використанні машинного навчання для аналізу втоми матеріалів відображає значний прогрес у цій області та розширення можливостей вирішення проблем, пов'язаних із втомою матеріалів. Здобутки в цьому напрямку включають:

- прогнозування залишкової довговічності: машинне навчання дозволяє розробляти моделі, які точно прогнозують залишкову довговічність матеріалів під впливом втомних навантажень;
- аналіз великих обсягів даних: сучасні методи машинного навчання ефективно обробляють великі обсяги експериментальних та обчислених даних, що стосуються втоми матеріалів;
- визначення взаємозв'язків між параметрами: машинні моделі дозволяють виявляти складні взаємозв'язки між різними параметрами матеріалів та їхньою схильністю до втоми⁴
- оптимізація процесів проектування: використання машинного навчання спрощує процес проектування, дозволяючи швидше та точніше враховувати фактори втоми при створенні нових матеріалів;
- автоматизація пошуку оптимальних рішень: методи оптимізації, засновані на машинному навчанні, допомагають знаходити оптимальні параметри матеріалів для максимальної стійкості до втоми;

- розпізнавання руйнування: алгоритми машинного навчання виявляють патерни та особливості руйнування матеріалів, що дозволяє попереджати потенційні проблеми;
- ефективне використання експериментальних даних: використання машинного навчання дозволяє максимально використовувати експериментальні дані та підвищує їхню інформативність.

Загалом, огляд сучасних досягнень свідчить про те, що застосування методів машинного навчання значно розширює можливості вивчення та прогнозування втоми матеріалів, використовуючи комплексний підхід до аналізу даних та моделювання.

2.2 Роль машинного навчання у дослідженні втоми матеріалів

Застосування машинного навчання у дослідженні втоми матеріалів визначає новий рівень аналізу та розуміння матеріальних характеристик, сприяючи розвитку більш точних та передбачуваних методів оцінки та управління втомою конструкційних матеріалів. Зокрема, роль машинного навчання у дослідженні втоми матеріалів є вирішальною для вдосконалення розуміння та прогнозування поведінки матеріалів під впливом циклічних навантажень.

З одного боку, машинне навчання дозволяє автоматизувати аналіз великих обсягів експериментальних та обчислених даних, пов'язаних з втомою матеріалів. З іншого, алгоритми машинного навчання можуть виявляти складні взаємозв'язки в поведінці матеріалів, спрощуючи розуміння факторів, що впливають на втому.

Тому, застосування машинного навчання дозволяє створювати прогностичні моделі, котрі точно передбачають зміни властивостей матеріалів у процесі циклічного навантаження та допомагають визначати оптимальні параметри експериментів, що веде до більш ефективного використання ресурсів

Відомо, що автоматизовані інструменти для тренування моделей роблять процес більш ефективним та швидким, зменшуючи час, необхідний для створення високоякісних прогностичних систем. Тому, машинне навчання дозволяє враховувати багатфакторні впливи та неоднорідності у матеріалах, поліпшуючи точність прогнозування втоми.

Загалом, машинне навчання полегшує виявлення складних взаємодій між різними властивостями матеріалів та їх впливом на втому та може виявляти нелінійні та складні залежності, котрі можуть залишатися непоміченими за допомогою традиційних статистичних методів.

Отже, методи машинного навчання дозволяють вченим та інженерам ефективно моделювати та розуміти процеси втомного руйнування матеріалів, що веде до розвитку більш точних та передбачуваних стратегій управління матеріалами та ресурсами.

РОЗДІЛ 3. КОНСТРУКТОРСЬКА ЧАСТИНА

3.1 Опис алгоритмів штучного інтелекту

Машинне навчання являє собою спрощений аналог процесу навчання, що відбувається у людини. Зазвичай, воно базується на конкретному наборі прикладів, спостережень та реакцій на ці спостереження. Основне завдання полягає в створенні моделей, які належним чином адаптуються до наданих даних та можуть здійснювати точні прогнози.

Відомо, що метою МН є навчити комп'ютер самостійно вчитися. Загалом, розрізняють такі типи навчання як індуктивне та дедуктивне:

- індуктивне навчання полягає у спостереженнях та побудові різних моделей для пояснення причин явищ. Після цього моделі перевіряються, оптимізуються або відкидаються за потреби;
- дедуктивне навчання передбачає надання учням готових правил, принципів чи концепцій, а потім вивчення та застосування цих знань для вирішення конкретних завдань чи ситуацій. У цьому підході учні отримують вже структуровану інформацію та використовують її для вивчення нових понять або розв'язання конкретних завдань. Дедуктивне навчання може включати логічне мислення та вивчення принципів на основі конкретних прикладів чи вказівок. Отже, машинне навчання, в основному, є індуктивним, оскільки воно вчить машину на прикладах, аналізуючи велику кількість реальних сценаріїв, будуючи моделі та використовуючи їх для прогнозування.

На відмінно від індуктивного навчання, де студенти вивчають принципи, спостерігаючи за конкретними прикладами та будуючи загальні правила, дедуктивний підхід включає в себе передачу готових знань з метою їх застосування.

Загалом, МН ділять на такі типи як навчання з учителем, без учителя та навчання з підкріпленням [9]:

- навчання з учителем. Тут модель навчається на основі набору прикладів, де до кожного прикладу є відома правильна відповідь або мітка. У цьому типі навчання алгоритм отримує дані, в яких вже визначено, які відповіді вірні, і завданням є навчитися визначати відповіді для нових, раніше не бачених даних;
- навчання без учителя. Алгоритм намагається виявити природні структури, закономірності чи шаблони в наборі даних, не маючи попередньо визначених міток чи правильних відповідей;
- навчання з підкріпленням. Розглядається як взаємодія з певним середовищем, де присутній агент, керований комп'ютером. Агент здійснює певні дії, які призводять до позитивних або негативних відгуків.

Завдання МН включають класифікацію, кластеризацію, регресію та зниження розмірності даних. Застосування МН широко поширюється в різних сферах, де можливий аналіз даних та прогнозування. Задачі в галузі машинного навчання поділяються на кілька типів залежно від характеру проблеми, яку вони вирішують [10]:

- задача кластеризації: алгоритм повинен самостійно виявляти закономірності серед фотографій і розділяти їх на кластери;
- задача регресії: тут маємо набір точок, через які потрібно побудувати лінію, яка найкращим чином відображає взаємозв'язок між ними. У випадку багатовимірних даних це стає складнішою задачею, ніж при роботі з двовимірними даними;
- задача зниження розмірності: припустимо, що маємо дані, представлені у великій кількості вимірів (наприклад, результати опитування з тисяч питань для сотень тисяч опитаних). Мета - виявити приховані закономірності в цих даних, скоротивши їхню розмірність, наприклад, з 1000 вимірів до 3.

Це полегшить подальший аналіз даних або застосування інших методів МН.

3.2 Вибір та обґрунтування методів МН

Вибір підходів МН є критичним етапом у розробці моделі для прогнозування діаграм втомного руйнування алюмінієвих сплавів. Враховуючи специфіку завдання та особливості даних, існує ряд нижче обґрунтованих методів МН, а саме, нейронних мереж, підсилених дерев, випадкових лісів, опорно-векторних машин, метод k -найближчих сусідів.

Розглянемо найпоширеніші методи МН з учителем [7] :

- нейронні мережі: НМ є потужними у виявленні складних залежностей та нелінійних взаємодій у великих наборах даних. Вони підходять для моделювання складних фізико-хімічних властивостей матеріалів та можуть адаптуватися до різноманітних форм даних;
- метод опорно-векторних машин: ефективно працює в умовах обробки великої кількості характеристик та може бути використаний для класифікації та регресії. Здатність даного алгоритму добре прогнозувати на невеликих обсягах даних робить його потужним інструментом для досліджень втому матеріалів;
- підсилені дерева: алгоритм підсилених дерев дозволяє легко інтерпретувати результати та виявляти ключові фактори, що впливають на втому матеріалів. Вони також добре пристосовані для аналізу даних, що містять категоріальні змінні;
- випадкові ліси: базується на ансамблевому підході, об'єднуючи кілька дерев рішень. Це дозволяє отримувати стабільні та точні результати, спрощуючи виявлення складних залежностей в даних про втому матеріалів;
- метод k -найближчих сусідів: даний алгоритм дозволяє враховувати схожість між сусідніми точками у просторі характеристик. Це може бути важливим для визначення аналогій, котрі підходять для дослідження втому матеріалів.

Використання комбінації цих методів може забезпечити більшу гнучкість та точність при моделюванні втоми алюмінієвих сплавів, враховуючи різноманіття фізико-хімічних властивостей матеріалів та умов експлуатації.

3.3 Архітектура нейронних мереж

Намагання відтворити здатність навчання та коригування помилок призвело до створення нейронних мереж - моделей, побудованих на основі принципів організації та функціонування біологічних НМ у живих організмах. Зазвичай мережа складається з електронних компонентів або моделюється у програмному забезпеченні на цифровому комп'ютері, який здійснює необхідні обчислення на основі процесу навчання. Для досягнення ефективності, НМ використовують взаємозв'язок між простими клітинами – нейронами [9].

Щоб відобразити суть біологічних нейронних систем, штучний нейрон будується за наступним принципом. Кожен вхід нейрона, на який подається певна кількість сигналів, є виходом іншого. Кожен вхідний сигнал множиться на вагу, аналогічну синаптичній силі, що призводить до зміни вхідної інформації при передачі від одного до іншого нейрона. Результати додаються, щоб визначити рівень активації нейрона. Сигнал активації піддається обробці функцією активації, що призводить до отримання вихідного сигналу нейрона.

НМ являють собою систему з'єднаних штучних нейронів, котрі взаємодіють між собою. Зокрема, вектор вхідних сигналів $\mathbf{x} = (x_1, x_2, \dots, x_n)$ надходить до штучного нейрона. Далі кожен сигнал множиться на вагу w_1, w_2, \dots, w_n і передається на суматор Σ . Тоді суматор, аналог тіла біологічного елемента, додає зважені входи, створюючи вихід, що називається NET. Кожен нейрон мережі працює тільки з сигналами, котрі він отримує періодично, і сигналами, котрі він періодично висилає іншим нейронам. З'єднані у велику мережу з керованою взаємодією, такі локально прості нейрони здатні виконувати складні завдання.

Сигнал NET піддається подальшій обробці за допомогою активаційної функції F , результатом чого є вихідний сигнал нейрона (Out).




Рисунок 3.1 – Модель штучного нейрону [9]

Робота нейрона визначається за допомогою наступних виразів:

$$NET_{jl} = \sum_i w_{ijl} \times x_{ijl},$$

$$Out_{jl} = F(NET_{jl} - \theta_{jl}), \quad (3.1)$$

$$x_{ij(l+1)} = Out_{il}$$

де i – номер входу у шар ; j – номер нейрона у шарі; l – номер шару; x_{ijl} – i -й вхідний сигнал j -го нейрона у шарі l ; w_{ijl} – ваговий коефіцієнт i -го входу j -го нейрона шару l ; NET_{jl} – сигнал NET j -го нейрона шару l ; Out_{jl} – вихідний сигнал; F – нелінійна функція активації; θ_{jl} – пороговий рівень даного нейрона.

Основні активаційні функції нейронів включають у себе:

- порогову функцію, котру визначають за допомогою наступної формули:

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

- сигмоїдальну функцію, яку часто використовують у багатошарових нейронних та інших мережах з безперервними сигналами:

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

Логарифмічна функція може слугувати прикладом сигмоїдальної функції;

- гіперболічний тангенс, який також використовують у мережах з безперервними сигналами. Її особливістю є те, що вона може повертати негативні значення результату:

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

На рис.3.2 показано основні види активаційних функцій.




Рисунок 3.2 – Відображення функцій активації нейронів (а) порогова, (б) сигмоїдальна, (в) гіперболічний тангенс

НМ являють собою групу нейронів, які взаємодіють один з одним. Зокрема, при створенні НМ для вирішення певної задачі важливо обрати, яким чином будуть з'єднані нейрони та налаштовані параметри ваг на їхніх зв'язках. Їх архітектура пов'язана із використанням алгоритмів навчання. Узагальнено, існують три основні класи НМ:

- одношарові мережі прямого поширення є типом НМ, у яких нейрони розташовані лише у одному шарі, який іноді називають вхідним шаром. У таких мережах немає прихованих шарів або зв'язків між нейронами в

одному шарі. Кожен нейрон у вхідному шарі пов'язаний з вихідним шаром, і кожен зв'язок між нейронами має вагу. Одношарові мережі прямого поширення часто використовуються для задач класифікації або регресії, де вхідні дані подаються через вхідний шар, а вихід — це результат обчислень, проведених з використанням ваг і активаційних функцій. Ці мережі мають обмежену потужність у розв'язанні складних завдань, оскільки вони обмежені лінійною комбінацією вхідних змінних. У випадку складніших завдань, зазвичай, використовують багатошарові мережі прямого поширення з прихованими шарами для вивчення складніших залежностей у даних;




Рисунок 3.3 – Архітектура НМ прямого поширення [9]

- багатошарові мережі прямого поширення є типом НМ, у яких інформація рухається від вхідного шару до вихідного шару без циклічних зв'язків. Такі мережі є простими та прозорими в плані передачі сигналів. Основна структура багатошарових мереж прямого поширення включає вхідний шар, один чи декілька прихованих шарів і вихідний шар. Кожен нейрон у шарі пов'язаний з кожним нейроном у наступному шарі, і кожен зв'язок має свій власний ваговий коефіцієнт. Мережа може називатись 10-2-1, де 10

вхідних, 2 прихованих та 1 вихідний нейрон. Цей тип мережі використовується для розв'язання різноманітних задач, а саме, класифікація, регресія, апроксимація функцій та інші, де важлива передача інформації в одному напрямку. Навчання багат шарових мереж прямого поширення зазвичай виконується за допомогою алгоритму зворотнього поширення помилок, який допомагає вагам мережі адаптуватися для правильної передачі інформації та вирішення конкретного завдання.




Рисунок 3.4 – Архітектура НМ прямого поширення з прихованим та вихідним шаром нейронів [9]

- рекурентні мережі - це тип НМ, у яких відбувається обмін інформацією між нейронами через часові кроки. Відмінно від багат шарових мереж прямого поширення, рекурентні мережі можуть зберігати попередні стани та використовувати їх для обробки нових вхідних даних. Важливою відмінністю рекурентних мереж є те, що вони мають циклічні зв'язки між нейронами, що дозволяє інформації переміщатися через час. Це дозволяє їм ефективно працювати з послідовними даними, такими як текст, часові ряди, аудіозаписи тощо. Однак у рекурентних мережах є певні труднощі, такі як проблема зникнення градієнту, коли інформація може затухати або вибухати під час тривалого навчання. Для розв'язання цих проблем були

розроблені складніші архітектури, такі як Long Short-Term Memory (LSTM) і Gated Recurrent Unit (GRU), які здатні ефективно працювати з довгостроковими залежностями в даних.

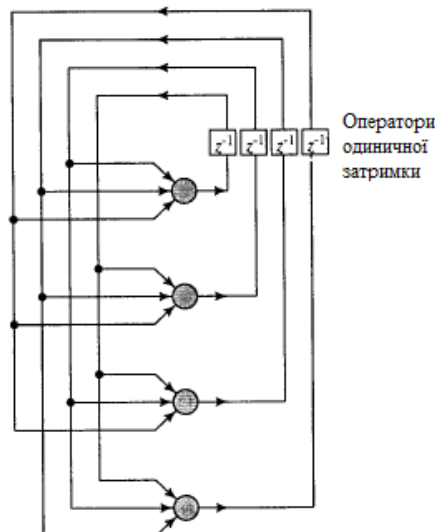


Рисунок 3.5 – НМ без прихованих нейронів, а також зі зворотними зв'язками всіх інших нейронів цього шару [9]

Метод зворотного поширення помилки в НМ є алгоритмом навчання, який використовується для апроксимації функцій або вирішення задач класифікації. Цей метод базується на ідеї корекції ваг нейронів відповідно до величини помилки між фактичним та очікуваним виходом мережі. У процесі зворотного поширення помилки спочатку визначається помилка мережі, порівнюючи фактичний вихід з очікуваним. Потім ця помилка розповсюджується назад через мережу, враховуючи ваги зв'язків між нейронами. Ваги оновлюються таким чином, щоб помилка зменшилася.

Процес триває ітеративно, знову та знову коригуючи ваги, поки помилка не стане достатньо мала. Цей метод є одним із найпоширеніших для навчання НМ, оскільки він дозволяє мережі самостійно вивчати закономірності в наборі даних.

3.4 Алгоритм підсилених дерев

Підсилені дерева є моделлю МН з учителем, за допомогою якої локальна область ідентифікується в послідовності рекурсивних розбиттів за меншу кількість кроків [7,11,12]. Рішення приймається деревом, яке складається з внутрішніх вузлів прийняття рішень та термінальних листків (рис. 3.6). Кожен вузол прийняття рішення m реалізує тестову функцію $f_m(x)$ із дискретними результатами, котрі маркують гілки. При отриманні вхідних даних у кожній вершині застосовується тест, і в залежності від результату обирається одна з гілок. Цей процес починається в корені і повторюється рекурсивно, доки не буде досягнуто вузол листка, а в цей момент значення, записане в листку, становить вихід.




Рисунок 3.6 – Приклад набору даних та відповідного дерева рішень [7]

Дерево рішень також є непараметричною моделлю, а структура дерева не є фіксованою апріорі, але дерево росте, гілки та листя додаються під час навчання в залежності від складності задачі притаманної даним.

Кожна $f_m(x)$ визначає дискримінант у d -вимірному вхідному просторі розбиваючи його на менші області, які далі розбиваються, коли ми йдемо шлях від кореня вниз. $f_m(x)$ є простою функцією, а якщо записати її у вигляді дерева, складна функція розбивається на ряд простих рішень. Різні методи дерев рішень

припускають різні моделі для $f_m(x)$, а клас моделі визначає форму дискримінанта та форму областей. Кожен вузол листка має вихідну мітку, яка у випадку класифікації є кодом класу, а в регресії – числове значення. Листковий вузол визначає локалізовану область у вхідному просторі, де екземпляри, що потрапляють в цю область, мають однакові мітки (у випадку класифікації) або дуже схожі числові результати (у випадку регресії). Межі областей визначаються дискримінантами, які закодовані у внутрішніх вузлах на шляху від кореня до листового вузла.

Ієрархічне розміщення рішень дозволяє швидко локалізувати області, що покриває вхідні дані. Наприклад, якщо рішення є бінарними, то в кращому випадку кожне рішення виключає половину випадків. Якщо є b регіонів, то в кращому випадку правильний регіон можна знайти за $\log_2 b$ рішень. Ще однією перевагою дерева рішень є інтерпретованість. Зокрема, дерево рішень можна перетворити на набір правил *IF-THEN*, які легко зрозуміти. З цієї причини дерева рішень дуже популярні і іноді їм надають перевагу перед більш точними, але менш інтерпретованими методами.

З одного боку, базову модель, котру використовують у підсилених деревах, часто є моделлю, такою як поверхневе дерево рішень.

З іншого, дерева будуються послідовно, при цьому кожне дерево виправляє помилки, зроблені комбінованим ансамблем попередніх дерев. Ідея полягає в коригуванні помилок попередніх моделей.

Під час процесу навчання помилковим точкам даних надають вищі ваги, тому наступні моделі акцентуються на цих точках. Це надає більше уваги областям, де модель має труднощі з точними прогнозами. Зокрема, прогнози всіх моделей комбінуються для формування кінцевого прогнозу. Кожна модель вносить зважену частину в кінцевий прогноз, а ваги коригуються під час навчання. Щоб запобігти перенавчанню, часто застосовують техніки регуляризації. Це включає в себе обмеження складності окремих моделей і використання стиснення, що передбачає використання частини обчисленого градієнта в кожній ітерації. Темп навчання контролює внесок кожної моделі в

кінцевий прогноз. Нижчий темп навчання робить оптимізацію більш стійкою, але вимагає більше ітерацій у процесі бустингу.

Підсилені дерева з популярними реалізаціями, такими як Gradient Boosting Machines (GBM), XGBoost та LightGBM, довели свою потужність і широке використання. Вони володіють високою точністю прогнозування та ефективно вирішують складні відносини в даних.

Дерево регресії будується майже так само, як і дерево класифікації, за винятком того, що міра домішок, яка підходить для класифікації, замінюється на міру, яка підходить для регресії. Нехай скажімо, для вузла m , X_m - це підмножина X , що досягає вузла m ; а саме, це множина всіх $x \in X$, що задовольняють усім умовам у вузлах прийняття рішень на шляху від кореня до вершини m . У регресії якість розбиття вимірюється середньоквадратичною середньоквадратичною похибкою від оціненого значення.

Часто вузол не розбивається далі, якщо кількість навчальних екземплярів, що досягають вершини, менша за певний відсоток від навчальної множини - наприклад, 5% - незалежно від домішок або помилок. Ідея полягає у тому, що будь-яке рішення, засноване на занадто малій кількості прикладів, викликає дисперсію і, таким чином помилку узагальнення. Зупинка побудови дерева на ранній стадії, до того, як воно буде повним називається попереднім обрізанням дерева.

Ще однією можливістю отримати простіші дерева є після обрізка, яка на практиці працює краще, ніж попереднє обрізання дерева. На кожному кроці ми приймаємо рішення, а саме, генеруємо вузол рішення, і продовжуємо рухатись далі, ніколи не відступаючи і не пробуючи альтернативу. Єдиний виняток – після обрізка, коли ми намагаємося знайти і обрізати непотрібні піддерева.

Під час після обрізки ми вирощуємо дерево до тих пір, поки всі листки не стануть чистими, і ми не матимемо жодної помилки навчання. Потім ми знаходимо піддерева, які викликають перенавчання, і обрізаємо їх. З початкової маркованої множини ми виділяємо множину для обрізки, невикористану під час навчання.

Для кожного піддерева ми замінюємо його листковою вершиною, позначеною навчальними прикладами, які охоплює піддерево (відповідно для класифікації або регресії). Якщо листовий вузол не працює гірше, ніж піддерево на множині обрізки, ми обрізаємо піддерево і залишаємо листовий вузол, оскільки додаткова складність піддерева не є виправданою; у протилежному випадку - залишаємо піддерево. Наприклад, у третьому дереві на рис. 3.6 є піддерево, яке починається з умови $x < 6.31$. Це піддерево можна замінити листком з вершиною $y = 0.9$ (як у другому дереві), якщо помилка на множині обрізання не збільшиться під час заміни, зокрема, множину обрізання не слід плутати з перевіркою множиною (і вона відрізняється від неї).

Порівнюючи попереднє та наступне обрізання, можна сказати, що попереднє обрізання є швидше, але після обрізка, як правило, призводить до більш точних дерев.

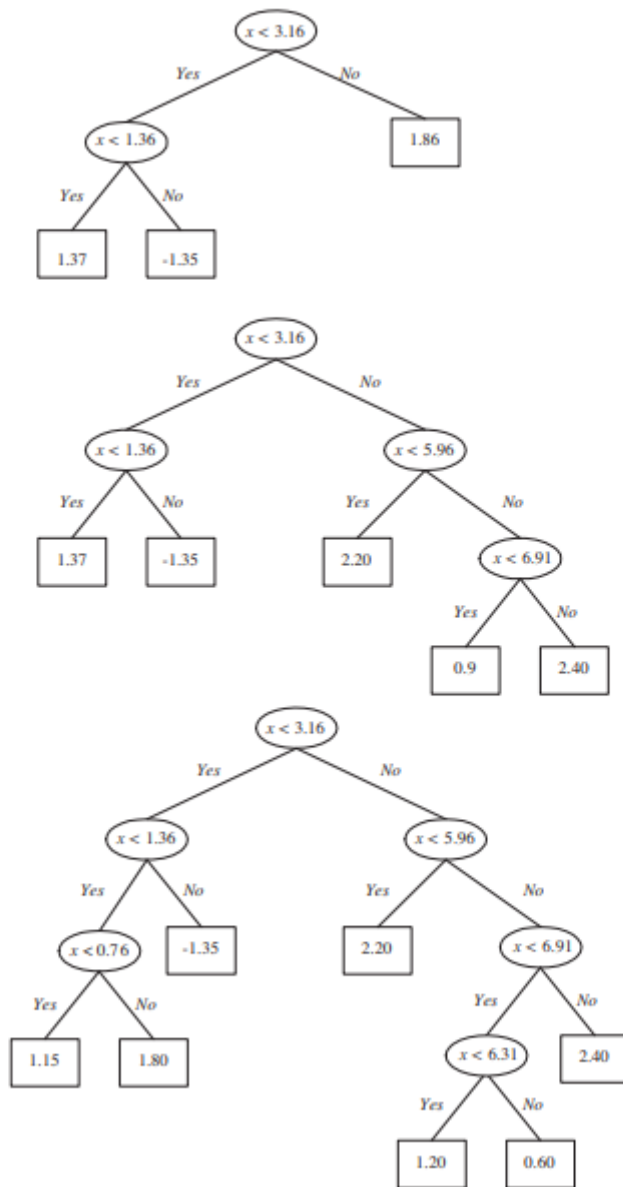


Рисунок 3.7 – Приклад побудови дерева рішень [11]

3.5 Метод випадкових лісів

Метод випадкових лісів є ансамблевим методом МН, який використовується для класифікації та регресії. Основна ідея полягає в тому, щоб побудувати кілька дерев прийняття рішень та об'єднати їх для зменшення схильності до перенавчання та покращення загальної ефективності моделі. Важливим є елемент випадковості у створенні кожного дерева. Якщо створити багато однакових дерев, то їх результат матиме точність одного дерева [13].

Основні етапи методу випадкових лісів:

- замість використання повного набору даних для навчання кожного дерева, випадковим чином обирається підвибірка. Це допомагає забезпечити різноманітність між деревами та зменшує схильність до перенавчання;
- при побудові кожного дерева не використовуються всі можливі ознаки. Замість цього випадковим чином обирається певна кількість ознак. Це додає ще один рівень випадковості та допомагає забезпечити незалежність між деревами;
- для кожної підвибірки та вибраних ознак побудовано окреме дерево прийняття рішень. Кожне дерево у методі випадкових лісів є слабким вчителем, але ансамбль дерев стає потужним класифікатором чи регресором;
- прогнози, отримані від кожного дерева, комбінуються для отримання кінцевого прогнозу. У випадковому лісі для класифікації це може бути рішення голосування (багато голосів), а для регресії - середнє значення;
- метод випадкових лісів також дозволяє визначити важливість кожної ознаки в процесі класифікації чи регресії. Це може бути корисним для подальшого аналізу даних.

Метод випадкових лісів добре справляється з багатьма типами даних і може ефективно вирішувати завдання класифікації та регресії. Він є одним з популярних методів в ансамблевому навчанні та використовується в різних сферах, включаючи фінанси, медицину та інші галузі.

Алгоритм побудови випадкових лісів можна описати наступним чином (рис. 3.8):

1. Обрання випадкового піднабору даних: для кожного дерева в лісі випадковим чином обирається піднабір даних із заміщенням. Це означає, що деякі приклади можуть входити в піднабір декілька разів, тоді як інші можуть не входити зовсім;

2. Обрання випадкового піднабору ознак: для кожного спліту в дереві випадковим чином обирається піднабір ознак. Це допомагає робити модель менш корельованою і більш стійкою до випадкових вхідних змін;
3. Побудова дерева рішень: для кожного випадкового піднабору даних і ознак будується дерево рішень. Спліти в дереві рішень визначаються таким чином, щоб якнайкраще розділити дані на класи або прогнозувати числове значення;
4. Повторення процесу: кроки 1-3 повторюються кілька разів для побудови багатьох дерев у лісі;
5. Сполучення результатів: прогнози, зроблені кожним деревом, комбінуються в один прогноз. У випадкових лісах, зазвичай, це виконується шляхом узяття середнього значення для задач регресії або проведення голосування для задач класифікації.

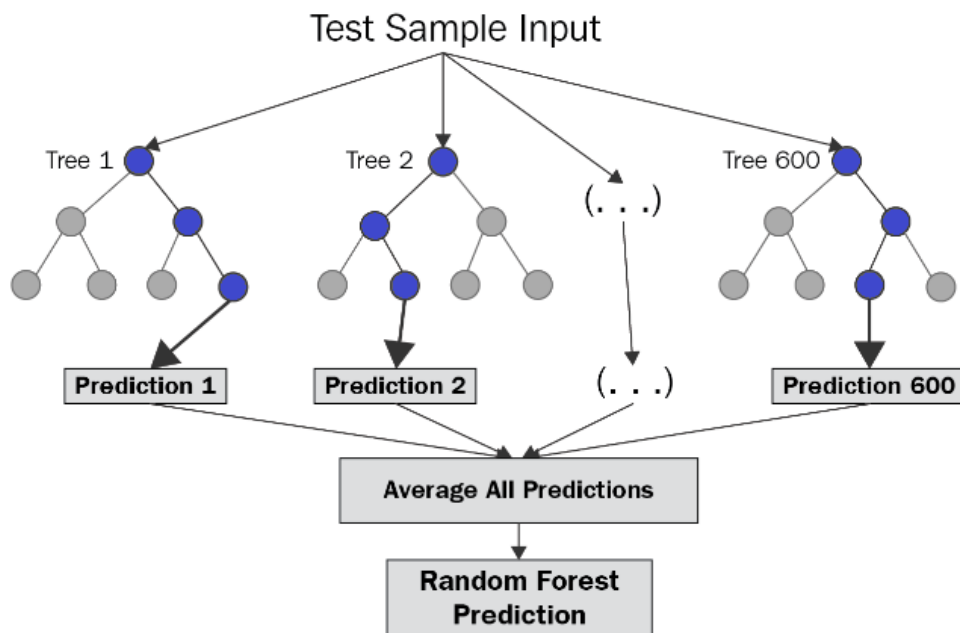


Рисунок 3.8 – Приклад побудови випадкових лісів

Цей алгоритм дозволяє створювати композиції дерев рішень, які виявляють велику гнучкість та стійкість до перенавчання. Основна ідея полягає в тому, що кожне дерево у лісі може виявити випадкові властивості даних, і, комбінувавши їх, можна отримати більш точні та стійкі прогнози.

3.6 Метод k -найближчих сусідів

Алгоритм k -найближчих сусідів ґрунтується на порівнянні відомих елементів з новими. Зазвичай, його основна ідея полягає в тому, що новий об'єкт, який потрібно прогнозувати, належить до класу, який є найбільш поширеним серед k -найближчих сусідів у навчальному наборі даних. Відстань між цими k -найближчими сусідами часто вимірюється за допомогою евклідової метрики. Цей метод МН є алгоритмом навчання з учителем та потребує наявності розміченого набору даних [7,14].

Для наочності аналізу методу k -найближчих сусідів розглянемо задачу класифікації нового об'єкта (точки запиту) серед численних відомих прикладів. Це зображено на рис.3.9, де приклади відображені знаками плюс і мінус, а точку запиту позначено синім трикутником. Наше завдання полягає в тому, щоб оцінити (класифікувати) результат точки запиту на основі обраної кількості її k -найближчих сусідів. Іншими словами, нам потрібно визначити, чи можна віднести точку запиту до класу плюс або мінус.




Рисунок 3.9 – Приклад побудови k -найближчих сусідів [14]

Алгоритм k -найближчих сусідів базується на наступних кроках:

1. Обрання значення k : визначте кількість найближчих сусідів (k), яку необхідно використовувати для класифікації або регресії;
2. Визначення відстаней: розрахуйте відстані між новим об'єктом (точкою запиту) і усіма елементами навчального набору даних. Зазвичай, використовується евклідова відстань, але інші метрики можуть використовуватися в залежності від потреб;
3. Сортування за відстанями: розташуйте навчальні приклади в порядку зростання їх відстаней до точки запиту;
4. Виберіть k -найближчих сусідів: оберіть перші k елементів, які мають найменші відстані до точки запиту;
5. Класифікація або регресія: якщо вирішуєте задачу класифікації, визначте клас, який найчастіше зустрічається серед обраних k -найближчих сусідів. Це стане передбаченням для нового об'єкта. Для задачі регресії використовуйте середнє значення відповідей обраних сусідів.

Цей алгоритм є простим, але ефективним методом класифікації та регресії, особливо в тих випадках, коли дані не мають складної структури або великої кількості ознак.

3.7 Метод опорно-векторних машин

Метод опорно-векторних машин є алгоритмом машинного навчання, який використовується для задач класифікації та регресії. Алгоритм навчання створює гіперплощину або пряму лінію, яка розділяє навчальні дані на два класи. Головною метою алгоритму є знаходження коефіцієнтів, які найкращим чином визначають роздільну пряму, та оптимізація різноманітних параметрів для досягнення високої точності класифікації [14].

Алгоритм опорно-векторних машин побудований так, що точки, котрі розташовані найближче одна до одної, мають більшу вагу при прийнятті

рішення. Це відбувається завдяки правильному виборі параметрів, що дозволяє показати високу ефективність. Для задачі з двома класами, де екземпляри класів показано знаками плюс і крапками, товста лінія є межею, а пунктирні лінії визначають поля по обидва боки. Обведені екземпляри є опорними векторами. (рис. 3.10).




Рисунок 3.10 – Приклад методу опорно-векторних машин [7]

Важливим тут є параметр регуляризації, який визначає баланс між гладкістю роздільної прямої та точністю класифікації. Збільшення цього параметра робить пряму менш хвилястою, але точніше класифікує тренувальні дані. Важливо підібрати оптимальні параметри моделі для конкретного датасету для досягнення найвищої точності.

Функція втрат визначає помилки лише для прогнозованих значень, що віддалені від тренувальних даних на відстань, більшу за ϵ . Параметр ядра γ визначає вплив кожного елемента навчальних даних на формування роздільної прямої. Зменшення γ включає більше об'єктів у визначення роздільної прямої, тоді як його збільшення призводить до врахування лише об'єктів, що знаходяться найближче до прямої.

Основні кроки використання метод опорно-векторних машин:

- навчання з учителем: метод опорно-векторних машин використовує розмічений набір даних, де для кожного об'єкта відомий його клас (який ми хочемо передбачити);
- вибір ядра: ядро визначає спосіб перетворення простору признаков. Ядро може бути лінійним або не лінійним. Лінійне ядро використовується для лінійно роздільних даних, тоді як не лінійні ядра, такі як поліноміальне або радіальне базисне ядро (RBF), використовуються для нелінійно роздільних даних;
- побудова оптимальної гіперплощини: метод опорно-векторних машин шукає оптимальну гіперплощину, котра максимально відділяє об'єкти різних класів. У випадку лінійного ядра це просто лінійна гіперплощина;
- класифікація нових об'єктів: після побудови моделі SVM можна класифікувати нові об'єкти, визначаючи до якого класу вони належать в залежності від того, з якої сторони гіперплощини вони знаходяться.

Основні переваги методу опорно-векторних машин включають ефективність в просторах високої розмірності, здатність працювати з обмеженим обсягом тренувальних даних та ефективність у вирішенні задач класифікації, особливо при наявності складних залежностей між признаками. Однак важливо враховувати, що метод опорно-векторних машин може бути чутливим до великої кількості наборів даних та налаштування параметрів ядра.

РОЗДІЛ 4. НАУКОВО-ДОСЛІДНА ЧАСТИНА

4.1 Процес збору, обробки та підготовки даних для моделювання

Представлення даних в МН є одним із найважливіших параметрів ефективної роботи моделей. Тобто, одним із перших кроків роботи в МН для того, щоб створити модель є представлення даних для комп'ютера в такому вигляді, щоб він їх зрозумів. Процес збору, обробки та підготовки даних для моделювання методами МН включає кілька ключових етапів:

- збір даних: якщо задача моделювання вже визначена, необхідно з'ясувати, які дані потрібні для її вирішення. Важливим є вибір джерела або джерел, з яких можна отримати відповідні дані: бази даних, АРІ, веб-скрапінг, сенсорні дані тощо;
- очистка та обробка даних: необхідно виявити та видалити аномальні значення або викиди. Важливим є рішення проблем при відсутності даних шляхом заповнення пропущених значень або видалення відповідних записів. Зокрема, нормалізація або стандартизація числових даних для однорідності шкали дозволяє досягти кращого результату;
- інженерія ознак: додавання нових ознак, які можуть поліпшити здатність моделі. Зокрема, вибір найбільш інформативних ознак для покращення ефективності моделі;
- розділення даних: для ефективного прогнозування даних важливим є їх розділ на дві частини – тренувальну вибірку для навчання моделі і тестову для її оцінки;
- моделювання: вибір відповідної моделі для вирішення конкретної задачі;
- оцінка та налаштування: включає визначення ефективності моделі за допомогою тестового набору даних. Важливим є вдосконалення моделі шляхом оптимізації гіперпараметрів;

- використання та розгортання моделі: використання навченої моделі для прогнозування нових даних та інтеграція моделі у реальне середовище або платформу.

Цей процес є ітеративним, і під час виконання моделювання може виникати необхідність повертатися до попередніх етапів для корекції та вдосконалення результатів.

4.2 Поділ даних на навчальну та тестову вибірки 44

Поділ даних на навчальну та тестову вибірки є важливим етапом у МН і спрямований на валідацію та оцінку ефективності побудованої моделі. Даний процес забезпечує те, що модель може ефективно узагальнювати до нових, раніше не бачених даних. Опис цього процесу:

- визначення мети;
- збір та підготовка даних;
- оцінка розміру тестового набору: зазвичай, використовують 70-80% даних для навчальної вибірки і 20-30% для тестової;
- випадковий відбір даних;
- створення навчальної та тестової вибірок;
- перевірка рівноваги класів: необхідно, щоб обидва набори містили приблизно однакову кількість прикладів для кожного класу, щоб уникнути вибіркового спотворення;
- додаткові перевірки на дублікат даних;
- збереження та захист даних.

Цей процес дозволяє ефективно використовувати дані для навчання моделі та перевіряти її ефективність на незалежній тестовій вибірці.


4.3 Прогнозування діаграм втомного руйнування алюмінієвого сплаву Д16Т

Експериментальне дослідження має високу складність та вимагає значних витрат. З цієї причини важливо використовувати числове моделювання за допомогою методів машинного навчання, замість проведення фізичних експериментів [15,16]. Основна метою цього дослідження полягає в прогнозуванні ДВР алюмінієвого сплаву Д16Т під час регулярного навантаження за $R = 0,2; 0,4; 0,6$. Це виконується різноманітними методами машинного навчання, уникаючи явного визначення аналітичних моделей РВТ та порівняння отриманих результатів [17,18].

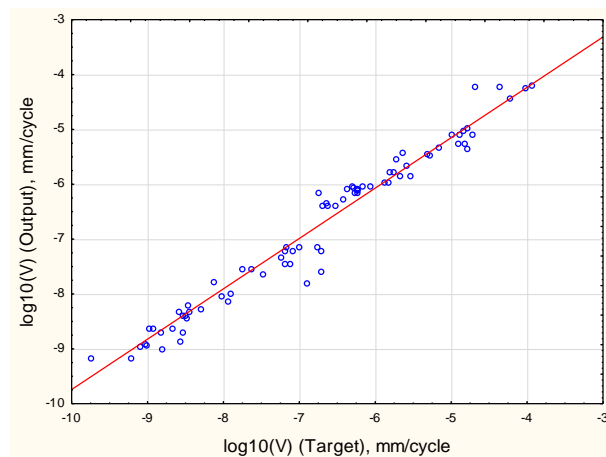
Швидкість РВТ прогнозували за експериментальними даними, отриманими у статті [19] за $R = 0,2; 0,4; 0,6$.

Загальна вибірка містила 225 елементів, з яких 70% були випадковим чином обрані для навчальної, а решта 30% залишили для тестової вибірки, з метою оцінки якості прогнозування. Виявилось, що результати прогнозування узгоджуються з експериментальними. Найточнішим методом є НМ з похибкою прогнозування 2,3%. Похибка методу підсилених дерев 9,7%, випадкових лісів - 9,5%, опорно-векторних машин - 2,8%, k -найближчих сусідів - 6,8%. Важливо зауважити, що точки на рис. 4.1 знаходяться близько до бісектриси першого координатного кута, що свідчить про високу узгодженість між прогнозованими та експериментальними даними.

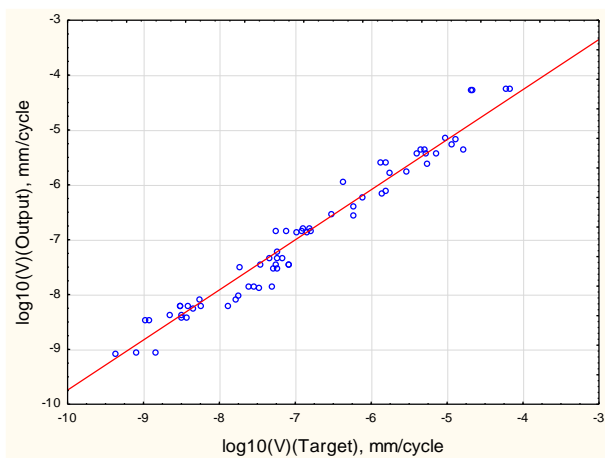
Для прогнозування швидкості РВТ методом НМ побудовано MLP 2-4-1 з тангенціальною функцією активації прихованого шару та логарифмічною функцією вихідного шару. Зокрема, коефіцієнт кореляції рівний 0,99 у тестовій вибірці. Тоді як застосовано 200 дерев для побудови алгоритмів підсилених дерев та випадкових лісів, кількість опорних векторів методу SVM рівна 20, а відстань у методі k -найближчих сусідів була евклідова.




а)




б)



в)




г)

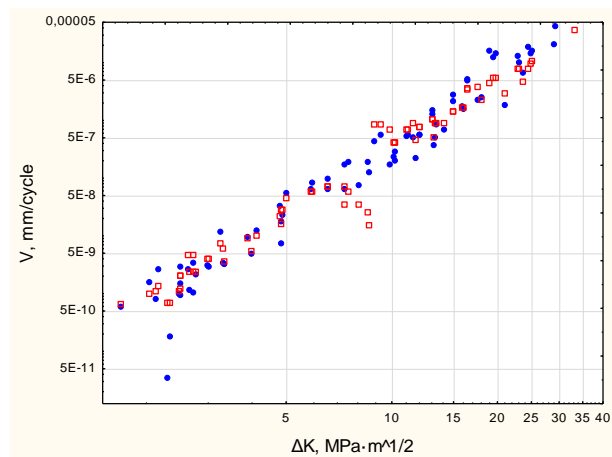


д)


Рисунок 4.1 – Прогнозовані (V) (*Output*) та експериментальні (V) (*Target*) швидкості РВТ отримані методом НМ (а), підсилених дерев (б), випадкових лісів (в), опорно-векторних машин (г) та k -найближчих сусідів (д)



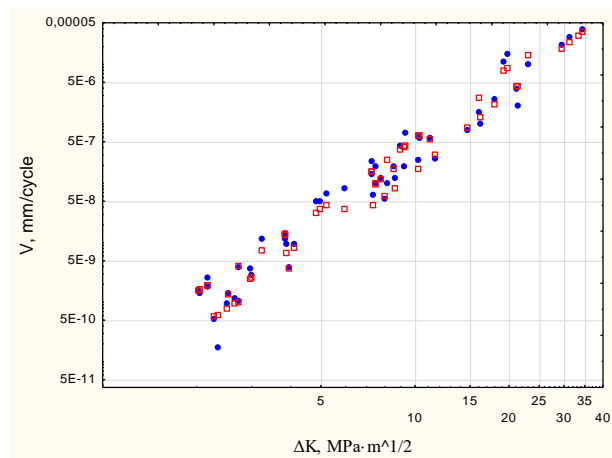
а)



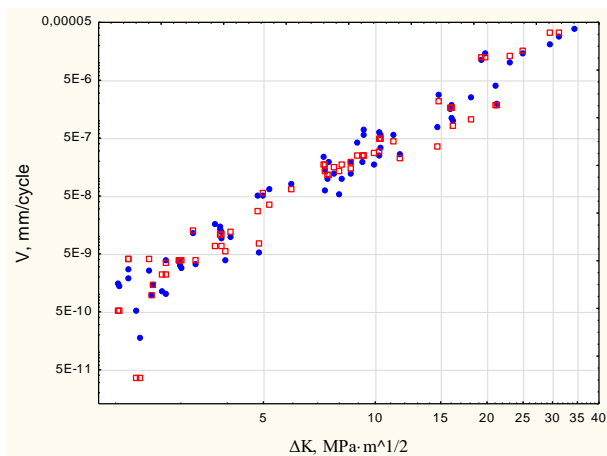
б)



в)



г)



д)

Рисунок 4.2 – Прогнозовані (□) та експериментальні (•) залежності швидкості РВТ від КІН отримані методом НМ (а), підсиленних дерев (б), випадкових лісів (в), опорно-векторних машин (г) та k -найближчих сусідів (д).

Залежність середньоквадратичної похибки від кількості дерев у




Рисунок 4.3 – Розрахована похибка в залежності від кількості дерев, отримана за допомогою методу підсилених дерев

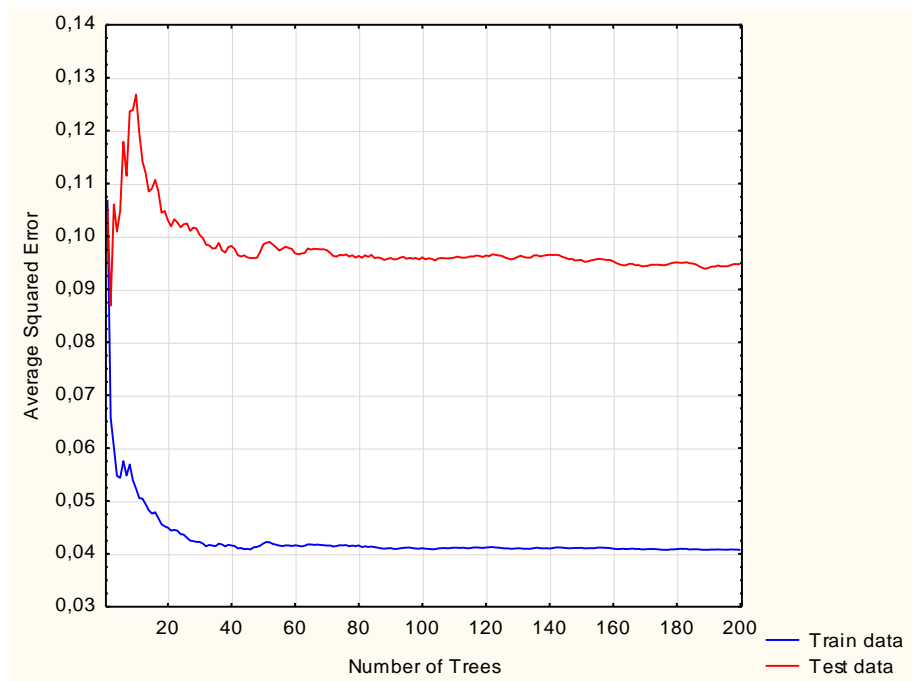


Рисунок 4.4 – Розрахована похибка в залежності від кількості дерев, отримана за допомогою методу випадкових лісів

підсилених деревах та випадкових лісах показано на рис. 4.3 та 4.4. Похибка навчання та тестової вибірки стабілізується після побудови 200 дерев. Зокрема, найбільший вплив вхідних параметрів показано на рис. 4.5 та 4.6.




Рисунок 4.5 – Вплив вхідних параметрів за допомогою методу підсилених дерев




Рисунок 4.6 – Вплив вхідних параметрів за допомогою методу випадкових лісів

4.4 Аналіз результатів якості прогнозування

Аналіз результатів якості прогнозування включає в себе оцінку ефективності моделі та порівняння прогнозованих значень з експериментальними. Основними етапами для проведення аналізу є:

- метрики якості, такі як середня квадратична помилка (Mean Squared Error), коефіцієнт детермінації (R-squared), або інші, щоб оцінити точність моделі;
- графічний аналіз дозволяє порівняти графічно прогнозовані та експериментальні значення;
- аналіз залишкових помилок, тобто різницю між прогнозованими та фактичними даними. Визначення патернів у залишкових помилках може допомогти вдосконалити модель;
- крос-валідація, котру застосовують для перевірки стабільності та узагальнюючої здатності моделі на різних підвбірках даних;
- аналіз важливості ознак, тобто необхідно досліджувати важливість ознак, які модель визначає для прогнозів. Це може вказати на те, які параметри найбільше впливають на результати;
- статистичні тести, наприклад, *t*-тест чи аналіз варіації, для перевірки статистичної значущості різниці між прогнозованими та фактичними значеннями;
- оцінка загальної продуктивності моделі повинна враховувати не лише точність прогнозів, але і ефективність в реальних умовах застосування.

Ці етапи аналізу допоможуть визначити ефективність моделі, виявити можливість вдосконалення та забезпечити достовірні результати прогнозування.

РОЗДІЛ 5. СПЕЦІАЛЬНА ЧАСТИНА

5.1 Реалізація та навчання моделей на підготовлених даних

На сьогодні існує багато програмних пакетів, котрі застосовують для вирішення різноманітних інженерних задач. Зокрема, для прогнозування ДВР алюмінієвих сплавів, зокрема, сплаву Д16чТ, методами машинного навчання використовували середовище статистичного аналізу STATISTICA, розроблене компанією StartSoft ("<https://www.statsoft.com>", n.d.). STATISTICA Machine Learning надає ряд передових статистичних методів для вирішення завдань регресії та класифікації з декількома залежними та незалежними змінними.

Для прикладу, побудова моделей для прогнозування ДВР, тобто швидкості РВТ алюмінієвого сплаву, за допомогою різних методів машинного навчання, зокрема, нейронними мережами виконана у такій послідовності, як показано на рис. 5.1-5.10.

Після запуску програмного пакету STATISTICA потрібно ввести або імпортувати дані з іншого файлу, котрі будуть аналізуватись. Далі необхідно заповнити таблицю в системі STATISTICA для прогнозування ДВР. Для цього створюють три змінні: перша і друга - це нормалізовані експериментальні дані швидкості РВТ за допомогою десяткового логарифма, такі як коефіцієнт інтенсивності напружень ΔK і швидкість РВТ V , третя - коефіцієнт асиметрії циклу навантаження R (рис. 5.1). Після введення даних у таблицю, їх редагування та збереження, починається аналіз даних.

Першим методом є алгоритм нейронних мереж.

Обираємо пункт *Data Mining / Нейронні мережі*. У діалоговому вікні, що з'явиться після виконання цього кроку, слід вибрати команду *Regression* як тип аналізу (рис. 5.2), щоб розпочати прогнозування ДВР.

	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 – Вікно з вихідними даними у програмі STATISTICA

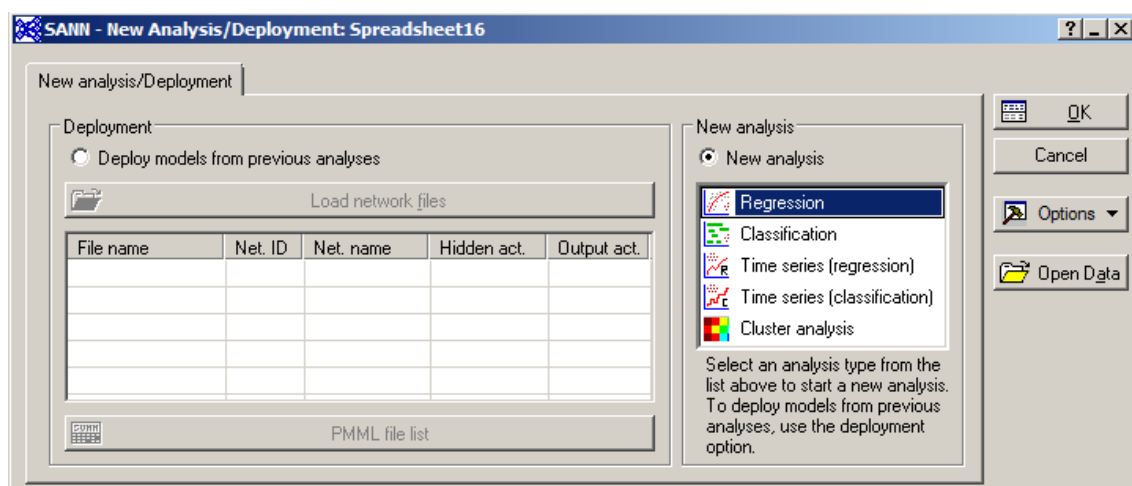


Рисунок 5.2 – Команда *Regression* у програмі STATISTICA

Далі у меню потрібно вибрати змінні, натиснувши кнопку *Variables*. Наприклад (рис. 5.3), для прогнозування ДВР у першій колонці обираємо змінну, що відповідає вихідному параметру (другий стовбець вихідних даних), тоді як у

другій колонці вибираємо вхідні параметри (перший та третій стовбець). Після обрання змінних отримуємо заповнене вікно меню *Quick* (рис. 5.4).

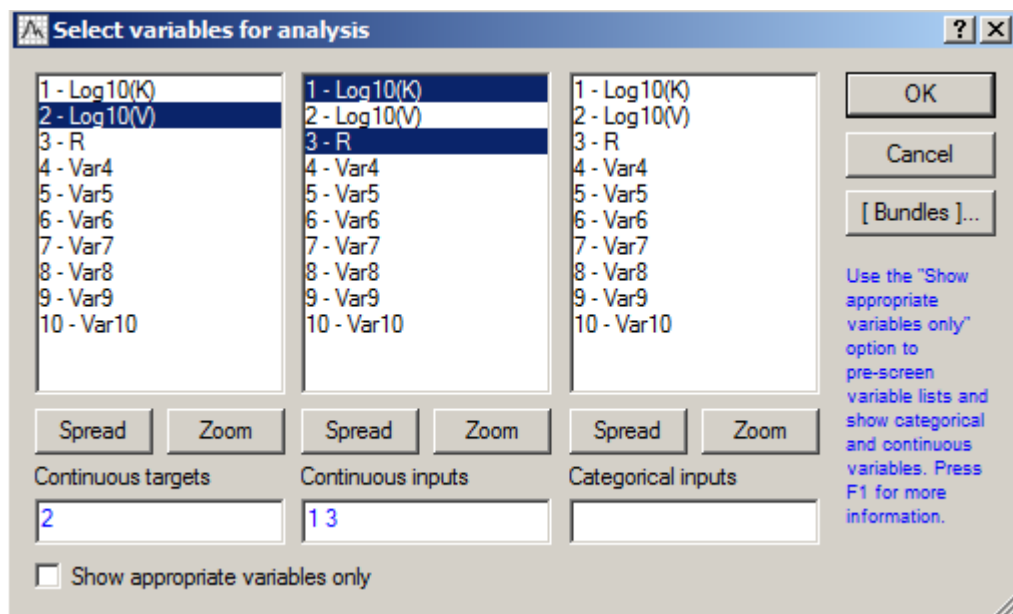


Рисунок 5.3 – Меню *Variables* у програмі STATISTICA

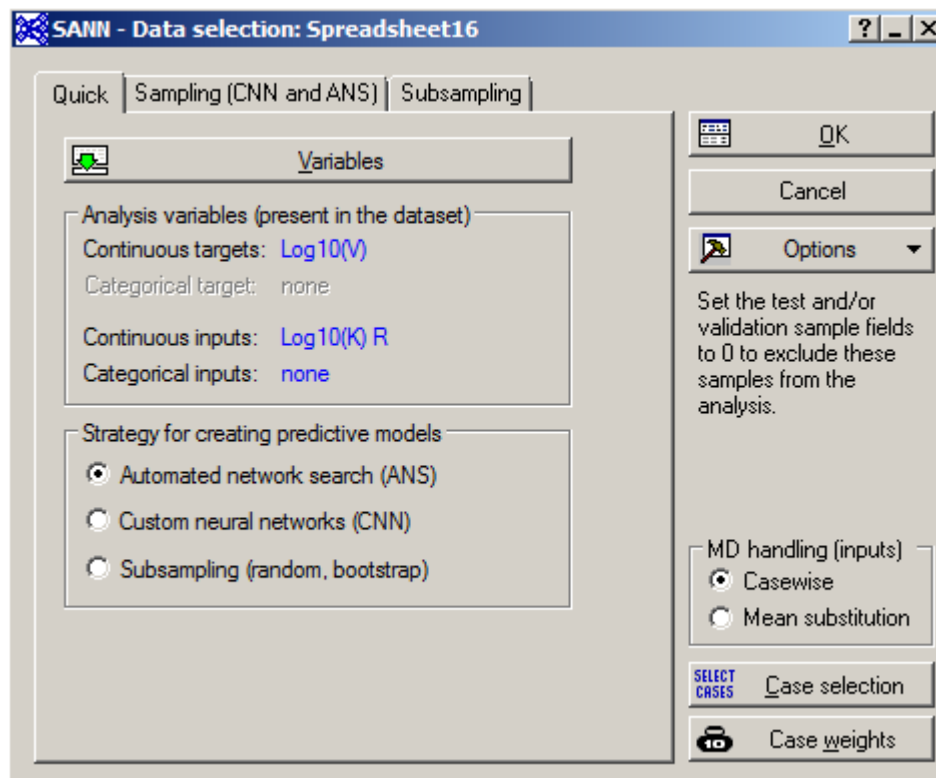


Рисунок 5.4 – Меню *Quick* у програмі STATISTICA

Після цього переходимо до меню *Sampling*, щоб розділити дані на дві нерівні частини, тобто на навчальну та тестову вибірки (рис. 5.5).

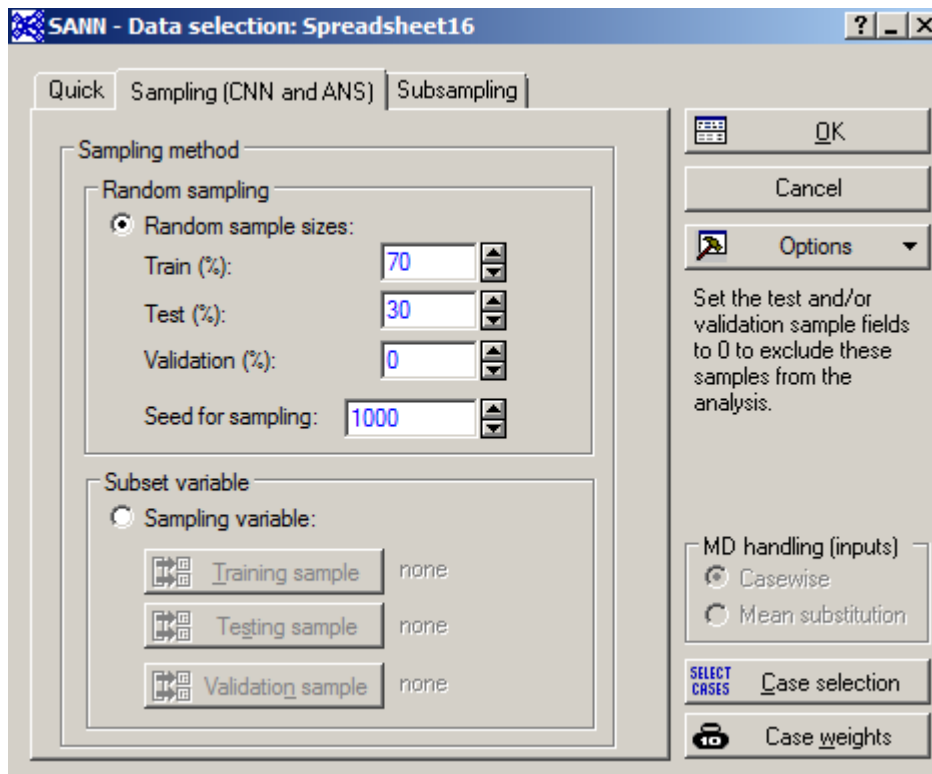


Рисунок 5.5 – Меню *Sampling* у програмі STATISTICA

Після встановлення відповідних позначень навпроти параметрів НМ у меню *Quick*, таких як *Network types* та *Train/Retain networks*, починається побудова мережі (рис. 5.6). Процес навчання НМ показано на рис. 5.7.

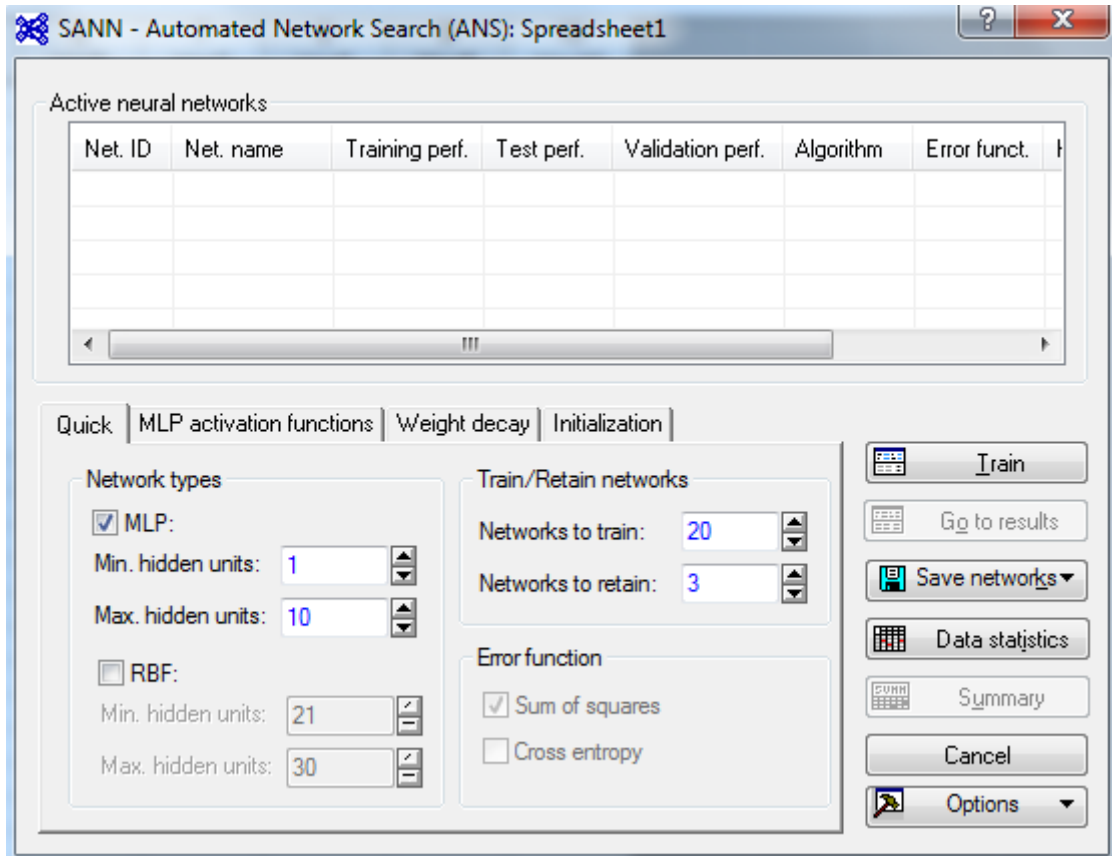


Рисунок 5.6 – Автоматизований пошук мережі

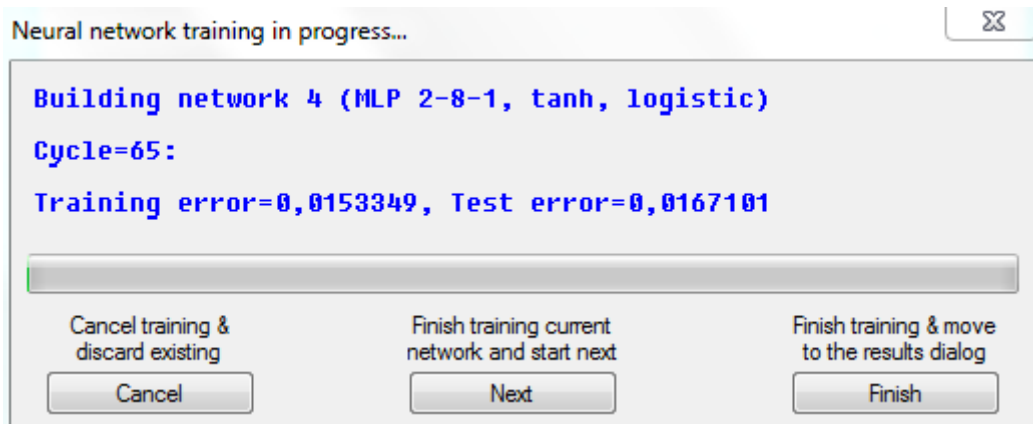


Рисунок 5.7 – Процес навчання НМ у програмі STATISTICA

Результати роботи побудованих нейронних мереж показано на рис. 5.8.

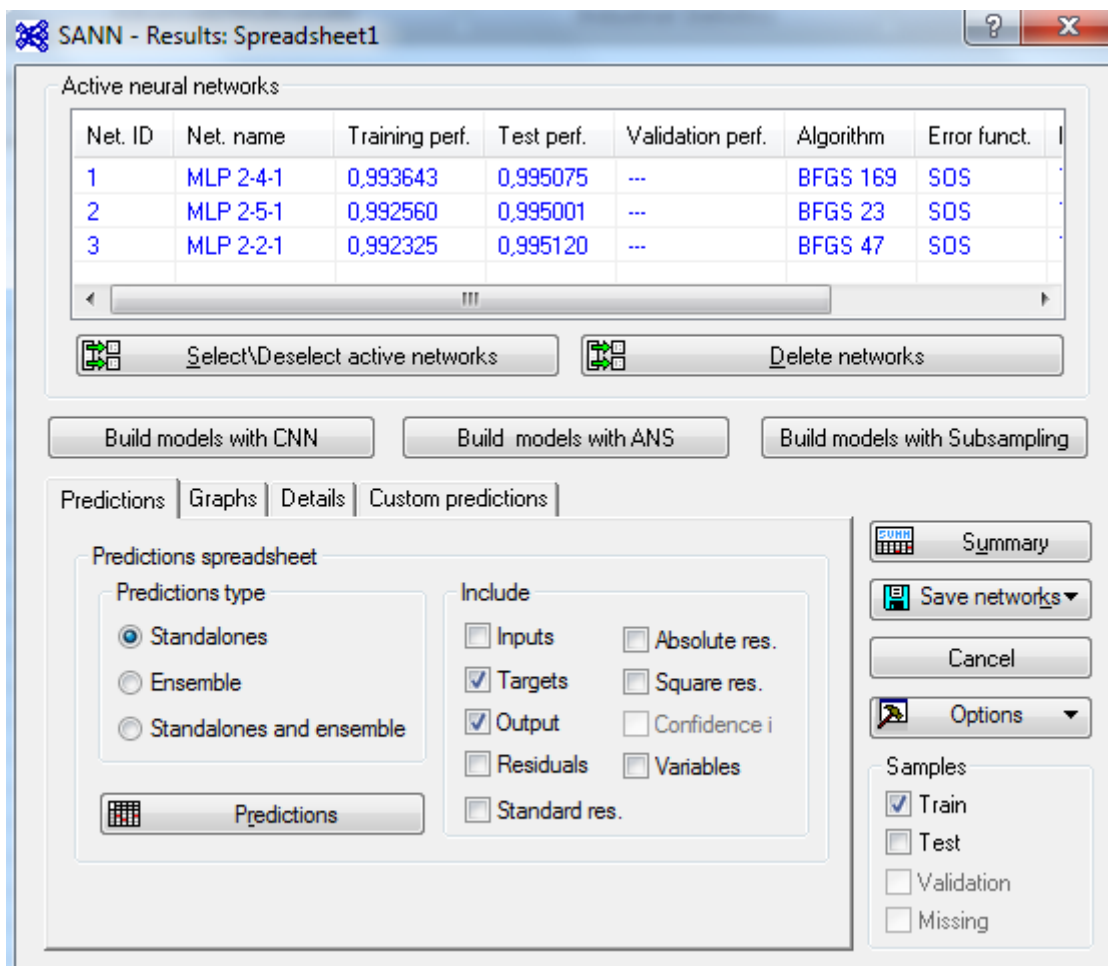


Рисунок 5.8 – Результати роботи побудованих нейронних мереж

Результати прогнозування відображаються у спеціальному вікні після натискання кнопки *Predictions*. На рис. 5.9 показано результати прогнозування швидкості РВТ. Інші параметри можна вибрати в меню *Graphs*, *Details* or *Custom predictions*.

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 2-4-1	Log10(V) - Output 2. MLP 2-5-1	Log10(V) - Squared Res. 2. MLP 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	0,024588	-9,31172	0,191742	-9,28530	0,215574
6	-9,02090	-9,19856	0,031563	-9,19387	0,029917	-9,16082	0,019577
7	-8,93550	-8,96411	0,000819	-9,08253	0,021619	-9,04513	0,012019
8	-8,98300	-8,89621	0,007532	-9,03852	0,003083	-8,99990	0,000285
12	-8,62160	-8,52862	0,008646	-8,65816	0,001337	-8,61988	0,000003
14	-8,48280	-8,41084	0,005178	-8,50413	0,000455	-8,47083	0,000143
17	-8,41230	-8,25751	0,023959	-8,30609	0,011281	-8,28233	0,016892
19	-8,52290	-8,24756	0,075814	-8,29351	0,052618	-8,27046	0,063726
20	-8,30100	-8,23794	0,003976	-8,28141	0,000384	-8,25904	0,001760
21	-8,41230	-8,22830	0,033855	-8,26932	0,020445	-8,24764	0,027112
25	-8,27160	-7,90403	0,135105	-7,88610	0,148612	-7,88934	0,146124
32	-6,87290	-7,05182	0,032011	-7,04399	0,029270	-7,07758	0,041893
34	-6,89960	-7,04217	0,020326	-7,03521	0,018390	-7,06862	0,028568
35	-6,90310	-6,93696	0,001146	-6,93970	0,001340	-6,97034	0,004521
43	-6,58170	-6,49360	0,007762	-6,52458	0,003262	-6,53473	0,002206
45	-6,41910	-6,31498	0,010842	-6,34161	0,006004	-6,34582	0,005370
50	-6,36750	-6,15084	0,046941	-6,16311	0,041777	-6,16657	0,040375
54	-5,87610	-5,93229	0,003157	-5,91611	0,001601	-5,92586	0,002476
56	-5,97880	-5,87358	0,011071	-5,84956	0,016702	-5,86200	0,013643
57	-5,59010	-5,85807	0,071810	-5,83205	0,058539	-5,84523	0,065092
58	-5,69900	-5,78637	0,007633	-5,75159	0,002766	-5,76838	0,004813
59	-5,73050	-5,58219	0,021996	-5,52951	0,040399	-5,55648	0,030283
60	-5,39790	-5,56815	0,028987	-5,51470	0,013642	-5,54231	0,020853

Рисунок 5.9 – Прогнозування швидкості РВТ нейронними мережами

Для обчислення похибки прогнозу необхідно виконати дії, показані на рис.

5.10.

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 2-4-1	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	-9,28530	0,21571
6	-9,02090	-9,19856					
7	-8,93550	-8,96411					
8	-8,98300	-8,89621					
12	-8,62160	-8,52862					
14	-8,48280	-8,41084					
17	-8,41230	-8,25751					
19	-8,52290	-8,24756					
20	-8,30100	-8,23794					
21	-8,41230	-8,22830					
25	-8,27160	-7,90403					
32	-6,87290	-7,05182					
34	-6,89960	-7,04217					
35	-6,90310	-6,93696					
43	-6,58170	-6,49360					
45	-6,41910	-6,31498					
50	-6,36750	-6,15084					
54	-5,87610	-5,93229					
56	-5,97880	-5,87358					
57	-5,59010	-5,85807					
58	-5,69900	-5,78637					
59	-5,73050	-5,58219					
60	-5,39790	-5,56815					
62	-5,34970	-5,34701					
70	-4,23210	-4,35793					
					21619	-9,04513	
					03083	-8,99990	
					01337	-8,61988	
					00455	-8,47083	
					11281	-8,28233	
					52618	-8,27046	
					00384	-8,25904	
					20445	-8,24764	
					48612	-7,88934	
					29270	-7,07758	
					18390	-7,06862	
					01340	-6,97034	0,004521
					03262	-6,53473	0,002206
					06004	-6,34582	0,005370
					41777	-6,16657	0,040375
					01601	-5,92586	0,002476
					16702	-5,86200	0,013643
					58539	-5,84523	0,065092
					02766	-5,76838	0,004813
					40399	-5,55648	0,030283
					13642	-5,54231	0,020853
					03638	-5,32484	0,000618
					07607	-4,29866	0,004430

Рисунок 5.10 – Прогнозування швидкості РВТ нейронними мережами

Після аналізу даних обирається модель, котра найточніше прогнозує швидкість РВТ на тестовій вибірці, тобто має найменшу похибку прогнозу. Зокрема, у вікні *Graph*, можна побудувати залежності експериментальних даних від прогнозованих, гістограми та інше (рис.5.11).

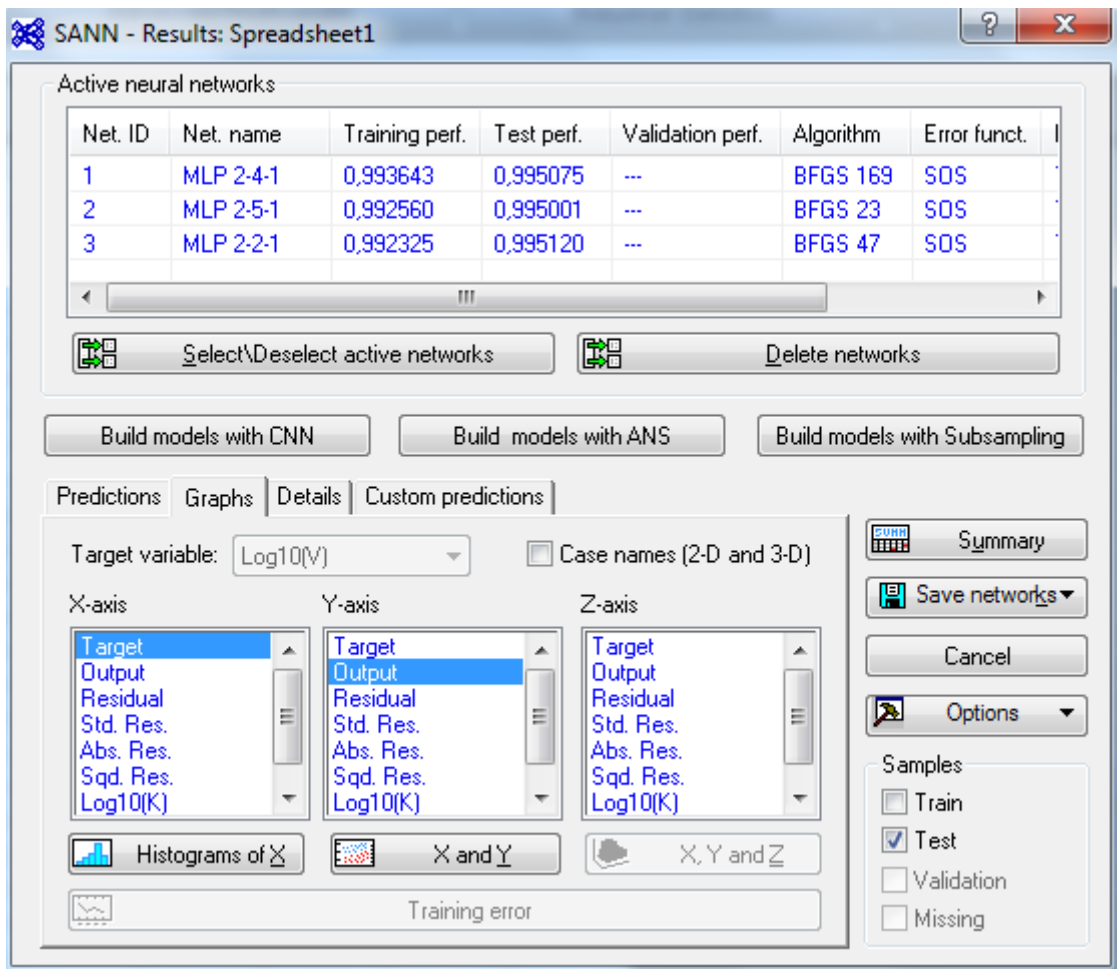


Рисунок 5.11 – Вікно *Graph* у програмі STATISTICA

Побудова моделей для прогнозування швидкості FCG методами *boosted trees*, виконана в послідовності, наведеній на рисунках 5.12-2.25, показана на рис. 2.22-2.25. Вибирається *Data Mining / Boosted Trees*. Потім у діалоговому вікні, що з'явилося, слід вибрати команду *Regression Analysis* (рис. 5.12).

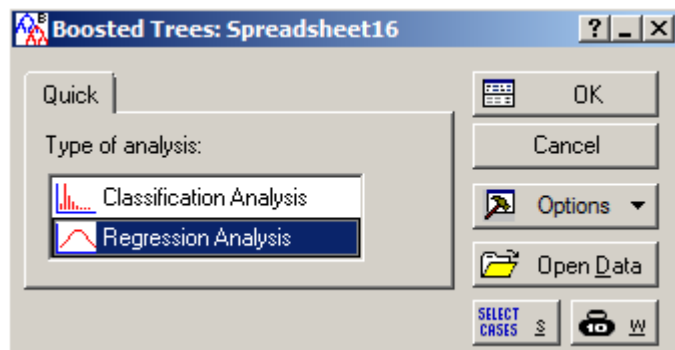


Рисунок 5.12 – Вікно *Boosted Trees* у програмі STATISTICA

У вікні, що відкривається після натискання кнопки *Variables*, необхідно задати *Dependent variable* та фактори *Covariates* для прогнозування швидкості РВТ (рис.5.13).

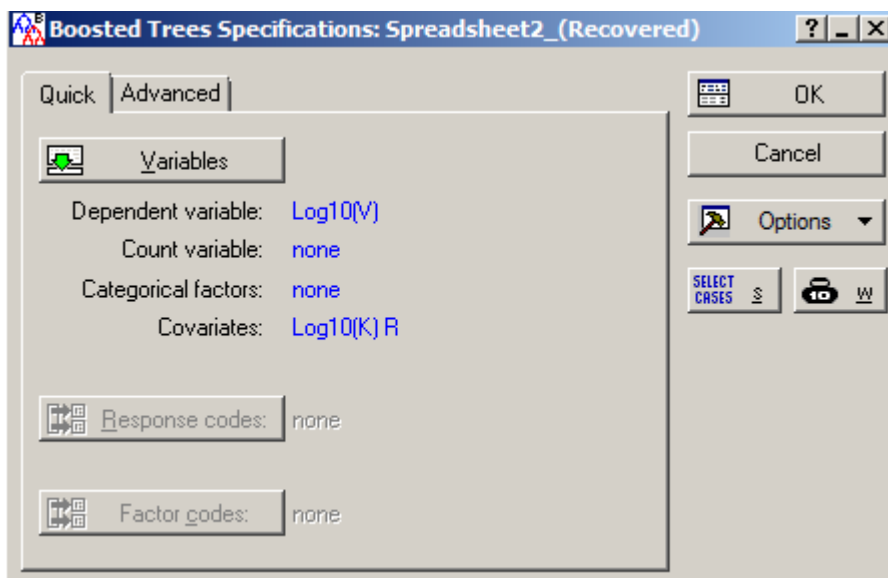


Рисунок 5.13 – Вікно вибору змінних

Далі в меню *Advanced* обираються параметри моделі (рис. 5.14).

Вікно відображення результатів оцінки моделі *Results* (рис. 5.15, а) складається з функціональних кнопок для комплексного перегляду результатів аналізу. Функціональні кнопки дозволяють представити результати у вигляді таблиць та графіків (рис. 5.15, б). Після цього розраховується середньоквадратична похибка, як показано на рис. 5.10.

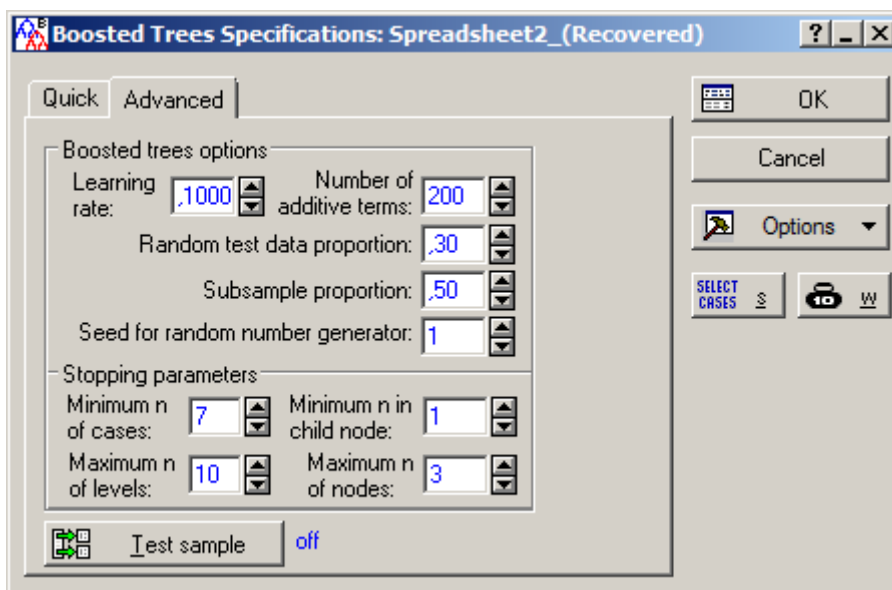
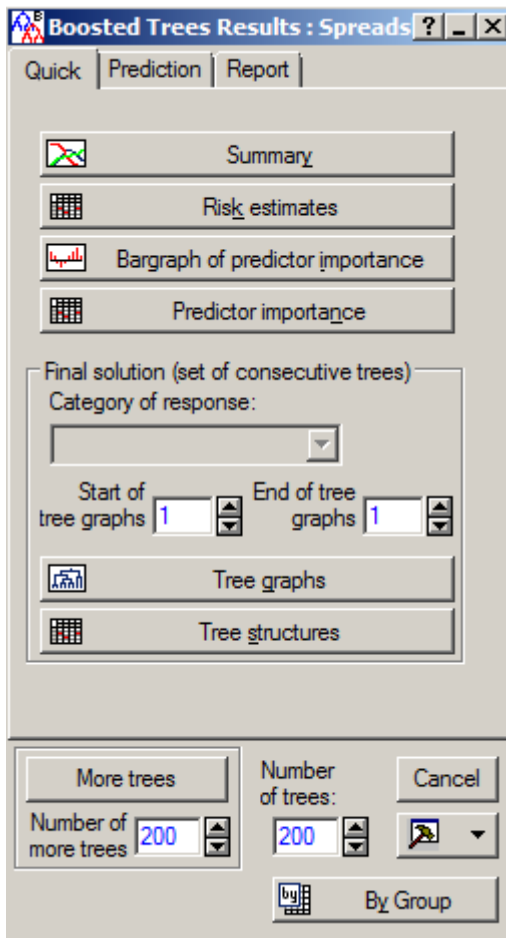
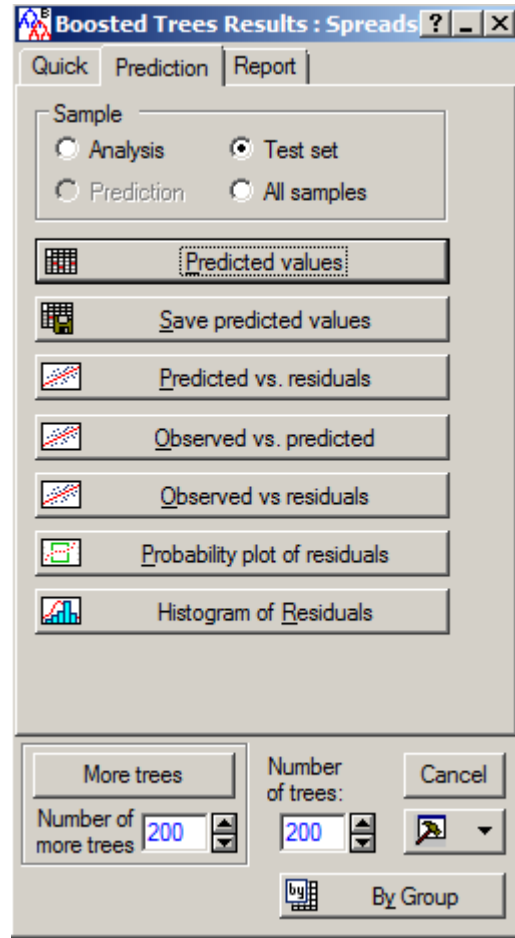


Рисунок 5.14 – Вікно *Advanced* для вибору параметрів



a)



б)

Рисунок 5.15 – Вікно аналізу результатів

Алгоритм побудови моделі для прогнозування швидкості РВТ методом випадкових лісів є аналогічним до методу підсилених дерев (рис.5.12-5.15).

Для прогнозування швидкості РВТ методом опорно-векторних машин, виконано в послідовності, наведеній на рис. 5.16-5.17.

Для початку необхідно вибрати *Data Mining / Machine Learning / Support Vector Machine*. У діалоговому вікні, що з'явилося, виберемо команду *Variables*, щоб розпочати новий аналіз. Швидкість РВТ V обрано як безперервну залежність, тоді як SIF ΔK та R - як безперервні предиктори. Інші параметри можна вибрати на вкладках меню *Sampling, SVM, Kernels, Cross-validation or Training* (рис. 5.16).

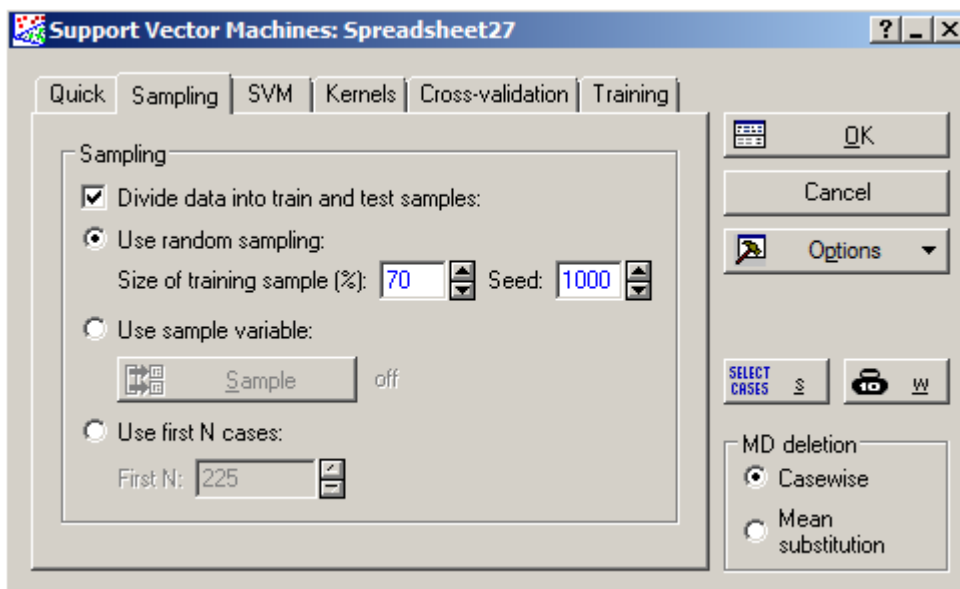


Рисунок 5.16 – Налаштування вікна методу опорно-векторних машин

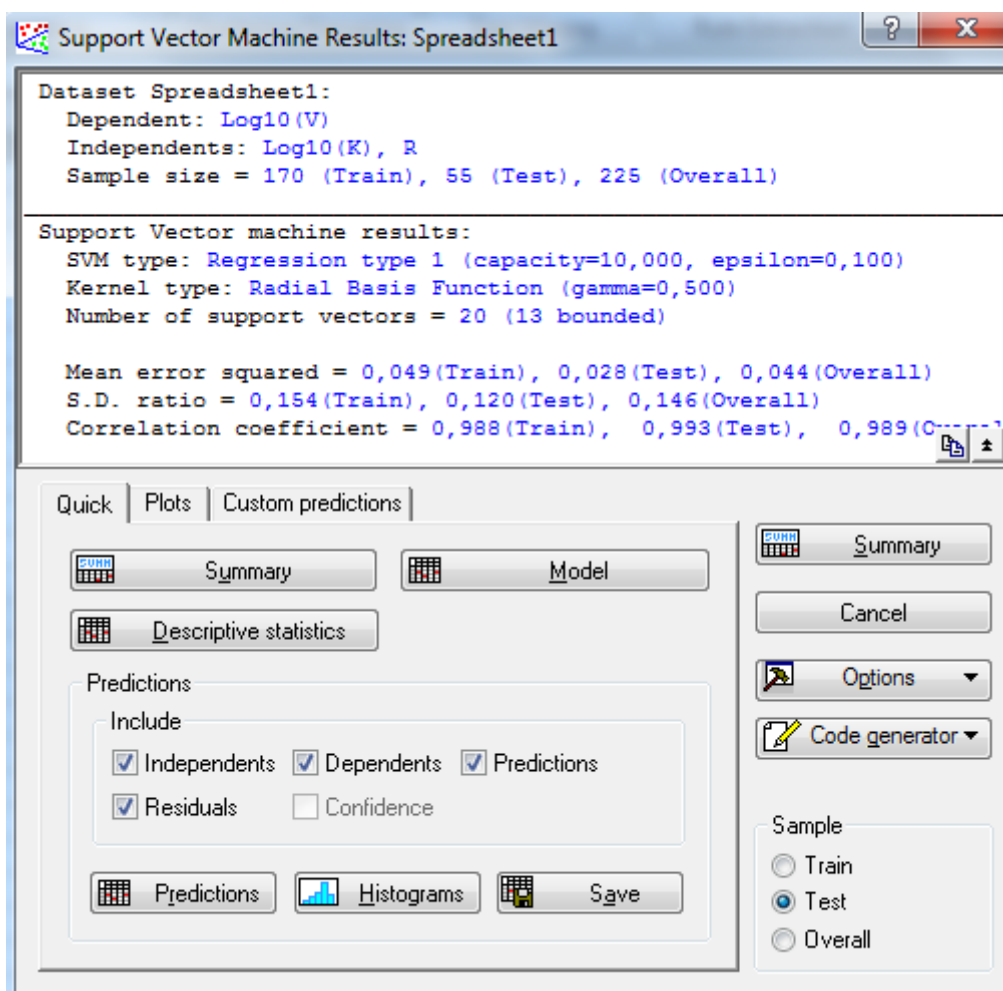


Рисунок 5.17 – Вікно результатів прогнозування швидкості РВТ методом опорно-векторних машин

Після натискання клавіші *Predictions* на екрані з'являється вікно з експериментальними та прогнозованими значеннями моделі, а також *Residual*. Далі створюємо стовпчик *Squared Residual* для обчислення середньоквадратичної похибки, за допомогою якої обчислюється похибка прогнозування швидкості РВТ.

Побудова моделей для прогнозування швидкості РВТ методом *k*-найближчих сусідів, виконується в послідовності, показаній на рис. 5.18.

Для початку необхідно вибрати *Data Mining / Machine Learning / K-Nearest Neighbors*. У діалоговому вікні, що з'явилося, слід вибрати команду *Variables*. Послідовність побудови моделі дуже схожа на метод опорних векторів.

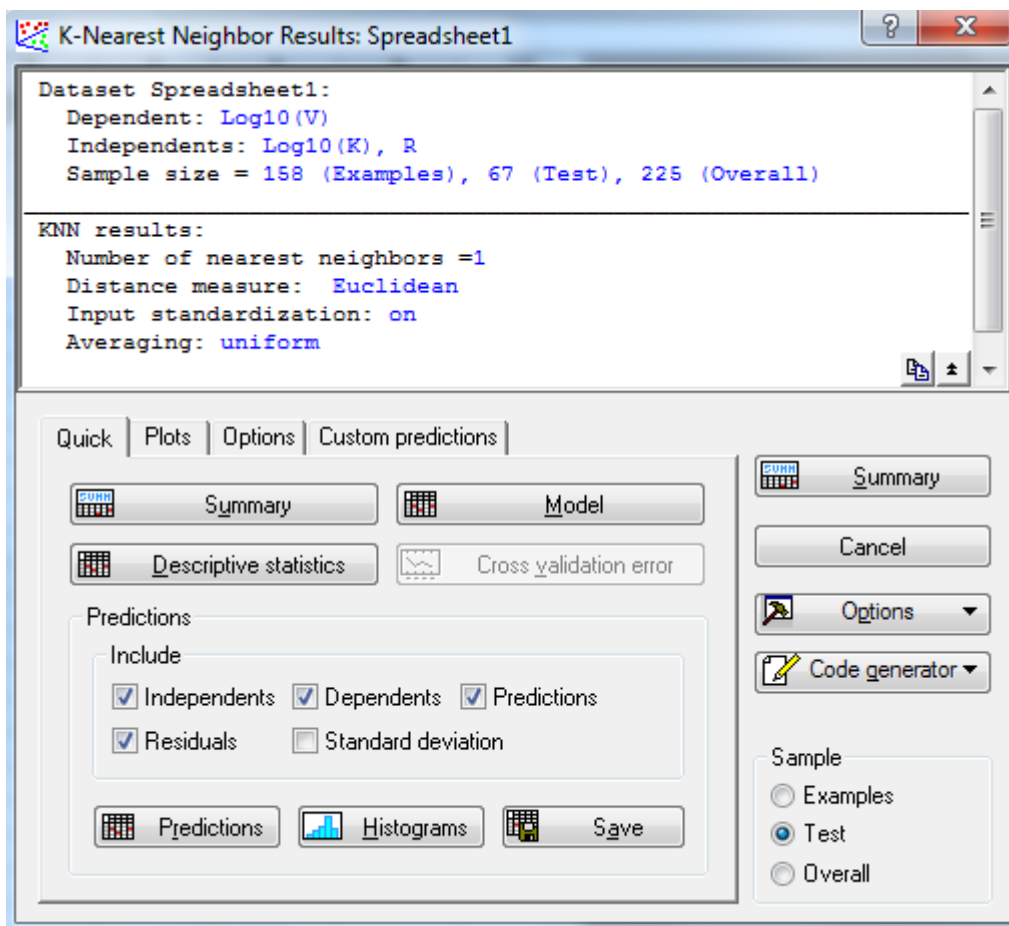


Рисунок 5.18 – Налаштування вікна методом *k*-найближчих сусідів

Результати реалізації відображаються у вигляді вікна (рис. 5.18), де після натискання клавіші *Predictions* відображаються результати прогнозування швидкості РВТ для тестової вибірки. Можна також проаналізувати швидкість РВТ графічно, використовуючи вікно *Plots*.

РОЗДІЛ 6. ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ

6.1 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 людина);
- 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 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

Можна зробити висновки, що робота включала в себе числове моделювання методами МН для прогнозування кінетичної діаграми втомного руйнування (КДВР) алюмінієвого сплаву Д16Т під час регулярного навантаження за асиметрії циклу навантаження $R = 0,2; 0,4; 0,6$. Замість експерименту, використовуючи інженерні дані, застосовувалися різноманітні методи МН для прогнозування втомної тріщини.

Отримані результати свідчать про успішність використаних методів штучного інтелекту. Зокрема, метод нейронних мереж продемонстрував найвищу точність з похибкою 2,5%. Інші методи, такі як підсилені дерева, випадкові ліси, опорно-векторні машини та k -найближчі сусіди, також виявилися ефективними з різними рівнями похибки.

Аналіз графіків розсіювання, залишкових помилок та важливості ознак допоміг визначити узгодженість прогнозованих та експериментальних даних.

У першому розділі кваліфікаційної роботи:

- Проаналізовано втомне руйнування.
- Розглянуто кінетичну ДВР матеріалів. З
- Зроблено огляд основних рівнянь для опису швидкості РВТ.
- Розглянуто роль асиметрії циклу навантаження.

У другому розділі кваліфікаційної роботи:

- Зроблено огляд сучасних досягнень у використанні машинного навчання для аналізу втоми матеріалів.
- Показано роль машинного навчання для дослідження втоми матеріалів.

У третьому розділі кваліфікаційної роботи:

- Проаналізовано та вибрано ефективні алгоритми штучного інтелекту.
- Описано архітектуру нейронних мереж.
- Розглянуто алгоритм підсилених дерев.

- Проаналізовано метод випадкових лісів.
- Описано метод k -найближчих сусідів.
- Розглянуто алгоритм опорно-векторних машин.

У четвертому розділі кваліфікаційної роботи:

- Висвітлено процес збору, обробки та підготовки даних для моделювання.
- Описано поділ даних на навчальну та тестову вибірки.
- Спрогнозовано ДВР алюмінієвого сплаву Д16Т.
- Проаналізовано результати якості прогнозування.

В п'ятому розділі кваліфікаційної роботи:

- Показано реалізацію та навчання моделей машинного навчання на підготовлених даних.

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

Узагальнюючи, результати свідчать про високий потенціал та ефективність застосування методів МН для прогнозування втомного руйнування алюмінієвих сплавів. Правильно підібрані методи дозволяють здійснювати точні та надійні прогнози, що може бути важливим у практиці інженерного дослідження та виробництва.

ПЕРЕЛІК ДЖЕРЕЛ

1. Ясній П.В. Пластично деформовані матеріали: в тома і тріщиностійкість. Львів: Світ, 1998. 292 р.
2. Kuna M. Finite Elements in Fracture Mechanics: Theory-Numerics-Applications. Springer, 2013. 446 р.
3. Варфоломеев І.В., Ясній.О.П. Моделювання руйнування імовірнісними методами елементів конструкцій з тріщинами // Фіз.-хім. механіка матеріалів. 2008. Vol. 44, № 1. Р. 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. Р. 63–68.
5. Paris P.C. The growth of fatigue cracks due to variations in load : Ph.D.Thesis. Lehigh University, 1962. 263 р.
6. Осташ О.П., Панасюк В.В. До питання про зародження втомних макротріщин у зразках із надрізом // Проблемы прочности. 2000. № 5. Р. 19–33.
7. Alpayndin E. Introduction to Machine Learning // The Knowledge Engineering Review. 2010. Vol. 25, № 3. Р. 353–353.
8. Robin C., Louagh M., Pluvinage G. Influence of an overload on the fatigue crack growth in steels // Fatigue of Eng. Mater. And Struct. 1983. Vol. 6, № 1. Р. 1–13.
9. Haykin S. Neural Networks - A Comprehensive Foundation - Simon Haykin. McMaster University, Hamilton, Ontario, Canada, 2006. Р. 823.
10. Wasserman Ph.D. Neural Computing: Theory and Practice. New York: Coriolis Group (Sd), 1989.
11. Gentleman R., Hornik K., Parmigiani G. Series Editors.
12. Mitchell T.M. Machine learning. London: McGraw-Hill Science/Engineering/Math, 1997.

13. Шаховська Н.Б., Камінський Р.М., Вовк О.Б. Системи штучного інтелекту: навч. посібник. Львів: Видавництво Львівської політехніки, 2018. 392 р.
14. Smola A., Vishwanathan S.V.N. Introduction to Machine Learning. Cambridge University Press, 2010.
15. 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.
16. 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.
17. 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.
18. Didych I. et al. Evaluation of structural elements lifetime by neural network // Acta Metallurgica Slovaca. 2018. Vol. 24, № 1. P. 82–87.
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.

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

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



УКРАЇНА
ТЕРНОПІЛЬ – 2023

12. **Р. В. Грицеляк, І. М. Дзьоба, О. Ласкевич** 28
ЗУСИЛЛЯ В ПОЗАЦЕНТРОВО СТИСНУТИХ ЕЛЕМЕНТАХ
ЗАЛІЗОБЕТОННИХ КОНСТРУКЦІЙ ПРИ ВИПАДКОВИХ
НАВАНТАЖЕННЯХ
13. **А. П. Грабовський** 29
ЗМІЦНЕННЯ ГВИНТОВИХ ЗАГОТОВОК
14. **А. Г. Микитишин, Р. З. Золотий, І. С. Дідич, Д. В. Черняк** 30
ЗАСТОСУВАННЯ МЕТОДІВ ШТУЧНОГО ІНТЕЛЕКТУ ДО
ПРОГНОЗУВАННЯ ДІАГРАМ ВТОМНОГО РУЙНУВАННЯ
15. **Петро Марущак, Н. Воробець, Б. Крушельницький, О. Мартинюк, Т. Лепкий, В. Дзюра, П. Марущак** 32
ДІГНОСТУВАННЯ ПОШКОДЖЕНОСТІ КОНУСНИХ ФРИКЦІЙНИХ
ВАРІАТОРІВ

СЕКЦІЯ: СУЧАСНІ ТЕХНОЛОГІЇ В БУДІВНИЦТВІ, МАШИНО- ТА ПРИБАДОБУДУВАННІ

1. **Д. М. Мороз, І. Г. Ткаченко** 33
СПЕЦІАЛЬНА ТОРЦЕВА ФРЕЗА
2. **В. О. Крушельницький** 34
МЕТОД ВИЗНАЧЕННЯ СИЛ РІЗАННЯ ПРИ ТОРЦЕВОМУ
ФРЕЗЕРУВАННІ
3. **А. Вовкотруб, В. Шанайда** 35
АНАЛІЗ ОСОБЛИВОСТЕЙ РОБОТИ ПРИВОДУ ГОЛОВНОГО РУХУ
ВЕРСТАТА
4. **О. О. Проданчук** 37
ПРОЕКТУВАННЯ ДОСЛІДНОЇ УСТАНОВКИ ДЛЯ ВИМІРЮВАННЯ
СИЛОВИХ ПАРАМЕТРІВ РІЗАННЯ ВАЖКООБРОБЛЮВАНИХ
МАТЕРІАЛІВ
5. **Б. В. Вітковський, І. Т. Ярема.** 39
СУЧАСНІ ТЕХНОЛОГІЇ В МАШИНОБУДУВАННІ
ВІБРАЦІЙНЕ СВЕРДЛІННЯ
6. **І. П. Домарецький, Д. Я. Мокрицький, О. В. Качуровський** 41
ДОСЛІДЖЕННЯ ДИНАМІКИ ШЛІФУВАННЯ ПЕРЕРИВЧАСТИМ
ШЛІФУВАЛЬНИМ КРУГОМ ПЛОСКОЇ ПОВЕРХНІ
7. **П. А. Сокіл, І. Р. Сокальський, М. В. Стаднійчук** 42
ДОСЛІДЖЕННЯ СИЛОВИХ ПАРАМЕТРІВ ПРОЦЕСУ ДОРНУВАННЯ
ПРОФІЛЬНОГО ОТВОРУ
8. **П. І. Тимчук, М. І. Шкварок, В. Ю. Грасовник** 43
ДОСЛІДЖЕННЯ ПАРАМЕТРІВ ПРОЦЕСУ ЗМІЦНЕННЯ ПОВЕРХНІ
ОТВОРУ КУЛЬКАМИ
9. **А. М. Хічій, В. М. Приказюк, В. М. Маслянка** 44
ДОСЛІДЖЕННЯ ВЕЛИЧИНИ ДЕФОРМАЦІЇ БАГАТОЛЕЗОВОЇ ОПРАВКИ
ДЛЯ РОЗТОЧУВАННЯ СТУПІНЧАСТОГО ОТВОРУ
10. **А. К. Шманін, В. В. Козішкурт, Н. І. Кицкай** 45
ДОСЛІДЖЕННЯ ШОРСТКОСТІ ЦИЛІНДРИЧНОЇ ПОВЕРХНІ ПІСЛЯ
ВИГЛАДЖУВАННЯ
11. **М. С Бутинський; Р. В. Комар** 46
ВИТІ ГНУЧКІ ВАЛИ ЗМІННОЇ ЖОРСТКОСТІ

УДК 539.42, 004.032.26,

А. Г. Микитишин, канд. техн. наук, доцент, Р. З. Золотий, канд. техн. наук, доцент,
І. С. Дідич, доктор філософії, Д. В. Черняк
(Тернопільський національний технічний університет імені Івана Пулюя, Україна)

ЗАСТОСУВАННЯ МЕТОДІВ ШТУЧНОГО ІНТЕЛЕКТУ ДО ПРОГНОЗУВАННЯ ДІАГРАМ ВТОМНОГО РУЙНУВАННЯ

A. H. Mykytyshyn., Ph.D., Assoc. Prof., R. Z. Zoloty, Ph.D., Assoc. Prof., I. S. Didych,
Ph.D., D. V. Cherniak

APPLICATION OF ARTIFICIAL INTELLIGENCE METHODS TO PREDICTION OF THE DIAGRAMS OF FATIGUE FRACTURE

Дослідження втоми матеріалів є актуальним завданням у галузі механіки руйнування. Для оцінки міцності та довговічності відповідальних елементів конструкцій необхідно враховувати велику кількість діючих чинників. Зокрема, нові технології дозволяють оптимізувати механічні системи з неймовірною точністю. Крім того, однією з причин широкого поширення методів штучного інтелекту є масштабування потоку даних в мережі та зростання рівня автоматизації. Тому застосування методів машинного навчання, а саме, нейронних мереж, випадкових лісів, підсилених дерев, опорно-векторних машин, k -найближчих сусідів, є сучасним підходом, котрим прогнозують діаграми втомного руйнування [1-2].

Нейронна мережа (НМ) є системою обчислень, котра моделює спосіб роботи людського мозку та складається зі з'єднаних клітин (нейронів), які обмінюються інформацією. Зокрема, кожен нейрон приймає вхідні сигнали, обчислює їх і видає вихідний сигнал [3]. Архітектуру багатошарової НМ показано на рис. 1.



Рисунок 1. Архітектура багатошарової нейронної мережі

Метод підсилених дерев відтворює природний процес мислення людини під час прийняття рішення. Зокрема, дерево рішень будує моделі у вигляді деревоподібної структури, котрі є легкими для інтерпретації. Тоді як алгоритм випадкових лісів складається з ансамблю простих дерев. Загалом, він усереднює результати їх передбачень.

Алгоритм опорно-векторних машин влаштований так, що точки, котрі знаходяться найближче одна до одної, мають найбільший вплив при ухваленні рішень [4]. Тому, при правильному виборі параметрів можна досягти високої ефективності цього методу (рис.2). Зокрема, метод k -найближчих сусідів базується на принципі віднесення нового об'єкта, який потрібно прогнозувати, до класу, який є найпоширенішим серед k – найближчих сусідів у навчальній вибірці.

Результати, зазначені у працях [5,6] показують, що методами машинного навчання можна достатньо точно оцінювати поведінку втомної тріщини. Це вказує на високий потенціал застосування машинного навчання у галузях, пов'язаних з аналізом та прогнозуванням втоми матеріалів.




Рисунок 2. Основна ідея методу опорно-векторних машин

Для розв'язування задач механіки, зокрема, прогнозування діаграм втомного руйнування, користувались експериментальними даними для алюмінієвого стопу Д16Т [7].

Загалом, отримані результати добре узгоджуються з експериментальними даними.

Література

1. Mohanty J. R. Application of artificial neural network for predicting fatigue crack propagation life of aluminum alloys / J. R. Mohanty, B. B. Verma, D. R. K. Parhi, D. R. Ray // Archives of Computational Materials Science and Surface Engineering. – 2009. –Vol. 1(3). – P. 133–138.
2. Pidaparti R. M. V. and Palakal M. Neural network approach to fatigue-crack-growth predictions under aircraft spectrum loadings // J. of Aircraft. – 1995. – № 4. – P. 825–831.
3. Haykin S. Neural Networks: A Comprehensive Foundation / S. Haykin. – Prentice Hall, 1999.
4. Smola, A., & Vishwanathan, S. V. N. (2010). Introduction to Machine Learning. Cambridge University Press.
5. О. П. Ясній, О. А. Пастух, Ю. І. Пиндус, Н. С. Луцик, І. С. Дідич. Прогнозування діаграм втомного руйнування алюмінієвого сплаву Д16Т методами машинного навчання, Фізико-хімічна механіка матеріалів, 2018, №3(54), 43 – 48 с.
О. Р. Ясній, О. А. Пастух, Ю. І. Пиндус, Н. С. Лутський, І. С. Дідич: Prediction of the Diagrams of Fatigue Fracture of D16T Aluminum Alloy by the Methods of Machine Learning, Materials Science, 3(54), 2018, 333 – 338.
6. О. Ясній, І. Дідич, Ю. Лапуста: Prediction of fatigue crack growth diagrams by methods of machine learning under constant amplitude loading, Acta Metallurgica Slovaca, 26(1), 2020, 31 –33.
7. Ясній П. Вплив асиметрії циклу навантаження на характеристики циклічної тріщинозміцності алюмінієвого сплаву Д16Т / П. Ясній, Ю. Пиндус, В. Фостик // Вісник Тернопільського державного технічного університету. – 2007 – Т.12, №1. – С.7–12.