

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

бакалавр

(назва освітнього ступеня)

на тему: **Застосування штучного інтелекту до прогнозування термічних властивостей композитних матеріалів**

Виконав: студент \_\_\_\_\_ 4 курсу, групи КТс-41

спеціальності \_\_\_\_\_ 151 – Автоматизація та комп'ютерно-

інтегровані технології

(шифр і назва спеціальності)

\_\_\_\_\_  
(підпис) **Строгуш В.Т.**  
(прізвище та ініціали)

Керівник \_\_\_\_\_  
(підпис) **Микитишин А.Г.**  
(прізвище та ініціали)

Нормоконтроль \_\_\_\_\_  
(підпис) **Левицький В.В.**  
(прізвище та ініціали)

Завідувач кафедри \_\_\_\_\_  
(підпис) **Микитишин А.Г.**  
(прізвище та ініціали)

Рецензент \_\_\_\_\_  
(підпис) **Микулик П.М.**  
(прізвище та ініціали)

Тернопіль  
2024

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

Факультет прикладних інформаційних технологій та електроінженерії  
(повна назва факультету)

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

ЗАТВЕРДЖУЮ

Завідувач кафедри

Микитишин А.Г

(підпис)

(прізвище та ініціали)

« 17 » травня 2024 р.

**ЗАВДАННЯ**  
**НА КВАЛІФІКАЦІЙНУ РОБОТУ**

на здобуття освітнього ступеня бакалавр  
(назва освітнього ступеня)

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

студенту Строгушу Володимиру Тарасовичу  
(прізвище, ім'я, по батькові)

1. Тема роботи Застосування штучного інтелекту до прогнозування термічних властивостей композитних матеріалів

Керівник роботи Микитишин Андрій Григорович, к.т.н., доцент

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

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

2. Термін подання студентом завершеної роботи 23.06.2024 р.

3. Вихідні дані до роботи Регресійні методи прогнозування, критерії їх оцінки, нейронні мережі, метод к-найближчих сусідів, опорно-векторних машин, датасет

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

1. Аналітична частина.

2. Проектна частина.

3. Спеціальна частина.

4. Безпека життєдіяльності, основи охорони праці.

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

1, 2. Актуальність теми та мета роботи. 3,4,5. Архітектура нейронних мереж. 6. Метод

к-найближчих сусідів. 7. Метод опорно-векторних машин. 8-9. Діаграма деформування.

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

11-16. Отримані результати прогнозування деформацій методами МН. 17. Висновки

6. Консультанти розділів роботи

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

7. Дата видачі завдання 17 травня 2024 р.

**КАЛЕНДАРНИЙ ПЛАН**

№ з/п	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1.	<i>Теоретичні основи прогнозування термічних властивостей композитних матеріалів</i>	<i>3.06.2024</i>	<i>Виконано</i>
2.	<i>Аналіз діаграми деформування матеріалу</i>	<i>4.06.2024</i>	<i>Виконано</i>
3.	<i>Методи МН для прогнозування діаграм деформування матеріалів</i>	<i>5.06.2024</i>	<i>Виконано</i>
4.	<i>Метод нейронних мереж, k-найближчих сусідів, опорно-векторних машин</i>	<i>7.06.2024</i>	<i>Виконано</i>
5.	<i>Підготовка даних до прогнозування</i>	<i>9.06.2024</i>	<i>Виконано</i>
6.	<i>Розробка програмного забезпечення для прогнозування термічних властивостей матеріалів</i>	<i>10.06.2024</i>	<i>Виконано</i>
7.	<i>Спеціальна частина</i>	<i>14.06.2024</i>	<i>Виконано</i>
8.	<i>Безпека життєдіяльності, основи охорони праці</i>	<i>15.06.2024</i>	<i>Виконано</i>
9.	<i>Оформлення графічної частини</i>	<i>18.06.2024</i>	<i>Виконано</i>
10.	<i>Захист кваліфікаційної роботи</i>	<i>28.06.2024</i>	<i>Виконано</i>

Студент

\_\_\_\_\_ (підпис)

***Строгуш В.Т.***

\_\_\_\_\_ (прізвище та ініціали)

Керівник роботи

\_\_\_\_\_ (підпис)

***Микитишин А.Г.***

\_\_\_\_\_ (прізвище та ініціали)

## АНОТАЦІЯ

У даній кваліфікаційній роботі бакалавра здійснено аналіз застосування штучного інтелекту до прогнозування термічних властивостей композитних матеріалів. Мета цієї роботи полягає в розробці та застосуванні методів машинного навчання, зокрема, нейронних мереж, к-найближчих сусідів та опорно-векторних машин для прогнозування термічних властивостей композитних матеріалів.

Основними завданнями дослідження є аналіз існуючих методів та алгоритмів прогнозування термічних властивостей композитних матеріалів, вибір оптимальних методів машинного навчання для моделювання термічних властивостей, розробка програмного забезпечення для реалізації обраних методів, проведення числових експериментів та порівняння отриманих результатів з експериментальними даними, а також оптимізація параметрів моделей машинного навчання для підвищення точності прогнозування.

Для реалізації задач прогнозування термічних властивостей композитних матеріалів у даному дослідженні використано програмне забезпечення STATISTICA, котре є важливим інструментом для того, аби проаналізувати дані. Воно включає широкий спектр методів машинного навчання та статистичного аналізу, а також дозволяє ефективно вирішувати такі задачі, забезпечуючи точність та надійність одержаних результатів.

**Ключові слова:** штучний інтелект, машинне навчання, нейронні мережі, метод к-найближчих сусіди, алгоритм опорно-векторних машин.

## ПЕРЕЛІК СКОРОЧЕНЬ І ТЕРМІНІВ

**ШІ** – штучний інтелект;

**МН** – машинне навчання;

**НМ** – нейронні мережі;

**k-NN** – k-найближчих сусідів;

**SVM** – опорно-векторних машин;

**MLP** – багатошаровий перцептрон;

## ЗМІСТ

ВСТУП.....	6
РОЗДІЛ 1. АНАЛІТИЧНА ЧАСТИНА.....	8
1.1 Теоретичні основи прогнозування термічних властивостей композитних матеріалів.....	8
1.2 Аналіз діаграми деформування матеріалу .....	10
РОЗДІЛ 2. ПРОЕКТНА ЧАСТИНА.....	14
2.1 Задача прогнозування термічних властивостей матеріалів .....	14
2.2 Методи МН для прогнозування діаграм деформування матеріалів.....	16
2.3 Алгоритм НМ.....	19
2.4 Парадигми навчання НМ .....	21
2.5 Зворотне поширення помилки НМ.....	25
2.6 Метод k-найближчих сусідів .....	26
2.7 Метод опорно-векторних машин .....	29
2.8 Підготовка даних до прогнозування.....	32
2.9 Нормалізація даних .....	34
2.10 Розробка програмного забезпечення для прогнозування термічних властивостей матеріалів.....	37
РОЗДІЛ 3. СПЕЦІАЛЬНА ЧАСТИНА .....	47
3.1 Аналіз результатів прогнозування діаграм деформування Al-6061 .....	47
3.2 Порівняння результатів прогнозування з експериментальними даними .....	51
РОЗДІЛ 4. БЕЗПЕКА ЖИТТЄДІЯЛЬНОСТІ, ОСНОВИ ОХОРОНИ ПРАЦІ .....	55
4.1 Характеристика шкідливих факторів виробничого середовища .....	55
4.2 Забезпечення безпеки життєдіяльності при роботі з ПК.....	57
ВИСНОВКИ.....	62
ПЕРЕЛІК ПОСИЛАНЬ .....	63

## ВСТУП

Композитні матеріали займають важливе місце в сучасній індустрії завдяки своїм унікальним властивостям, таким як висока міцність, легкість та здатність витримувати екстремальні температури. Прогнозування термічних властивостей композитних матеріалів є критично важливим для їх успішного застосування в різних галузях, включаючи авіацію, автомобілебудування, енергетику та будівництво. Сучасні методи машинного навчання, зокрема нейронні мережі, k-найближчі сусіди та опорно-векторні машини, відкривають нові можливості для точного та ефективного прогнозування цих властивостей, що знижує необхідність вартісних та тривалих експериментальних досліджень.

Практична цінність роботи полягає в можливості застосування розроблених моделей та програмного забезпечення для прогнозування термічних властивостей композитних матеріалів у промислових умовах. Це дозволить знизити витрати на експериментальні дослідження, підвищити точність прогнозів та оптимізувати процеси виробництва та експлуатації композитних матеріалів.

Відомо, що однією з найважливіших переваг автоматизації процесу прогнозування термічних властивостей композитних матеріалів є зменшення впливу людського фактору. Використання методів машинного навчання дозволяє мінімізувати помилки, які можуть виникати через людський фактор, забезпечуючи більш точні та надійні результати. Програмне забезпечення, як-от STATISTICA, автоматизує процеси збору, аналізу та обробки даних, що значно підвищує ефективність досліджень. Зокрема, дозволяє проводити числові експерименти набагато швидше, ніж фізичні експерименти. Це забезпечує швидке отримання результатів, що є критично важливим у промислових умовах, де час є одним з найважливіших ресурсів. Крім того, автоматизація дозволяє паралельно обробляти великі обсяги даних, що підвищує ефективність процесу моделювання.

Загалом, впровадження методів машинного навчання в процес прогнозування термічних властивостей композитних матеріалів дозволяє

оптимізувати виробничі процеси. Точне прогнозування властивостей матеріалів дає можливість краще планувати виробничі цикли, вибирати оптимальні режими обробки матеріалів та знижувати кількість відходів. Це також сприяє підвищенню якості готової продукції та зниженню її собівартості.

Важливим є те, що автоматизовані системи на основі машинного навчання надають цінну інформацію для підтримки прийняття рішень у реальному часі. Інтеграція таких систем з існуючими виробничими процесами дозволяє швидко реагувати на зміни умов та коригувати параметри виробництва для досягнення оптимальних результатів. Це забезпечує більш гнучке та адаптивне управління виробництвом.

Тому застосування програмного забезпечення STATISTICA дозволяє ефективно вирішувати задачі прогнозування термічних властивостей композитних матеріалів, забезпечуючи високу точність та надійність отриманих результатів. Використання STATISTICA має кілька важливих переваг, зокрема, підтримує різні методи машинного навчання, включаючи нейронні мережі, k-найближчі сусіди та опорно-векторні машини. Це дозволяє швидко та ефективно реалізувати необхідні алгоритми для моделювання термічних властивостей. Зокрема, програмне забезпечення є зрозумілим, що полегшує процес налаштування та виконання моделювання, а також візуалізації результатів. Загалом, STATISTICA забезпечує широкий набір інструментів для попередньої обробки даних, їх аналізу та візуалізації, що є необхідним для ефективного машинного навчання. Програма дозволяє легко налаштовувати параметри моделей, експериментувати з різними конфігураціями та масштабувати моделювання для великих обсягів даних.

**Об'єкт дослідження** – композитні матеріали, зокрема алюмінієві композити, які широко використовуються в промисловості.

**Предмет дослідження** – методи машинного навчання, застосовані для прогнозування термічних властивостей цих матеріалів.



## РОЗДІЛ 1. АНАЛІТИЧНА ЧАСТИНА

### 1.1 Теоретичні основи прогнозування термічних властивостей композитних матеріалів

Композитні матеріали складаються з двох чи більше матеріалів, які разом надають кінцевому продукту унікальні властивості, яких не має жоден з компонентів окремо [1]. Найчастіше композити складаються з матриці (основного матеріалу) і армуючої фази (наприклад, волокна), які забезпечують високу міцність і жорсткість. Термін "композитний матеріал" охоплює широкий спектр матеріалів, від полімерних композитів до металокерамічних та вуглецевих композитів.

Термічні властивості композитних матеріалів включають:

- теплопровідність: здатність матеріалу проводити тепло. Для композитів теплопровідність залежить від теплопровідності компонентів та їх об'ємної доли;
- теплоємність: кількість тепла, необхідного для підвищення температури матеріалу на одиницю. Це властивість визначає, наскільки швидко матеріал нагрівається або охолоджується;
- коефіцієнт термічного розширення: показує, як змінюються розміри матеріалу при зміні температури. Композити можуть мати анізотропні властивості, тобто їх властивості можуть відрізнятися в різних напрямках.
- термічна стійкість: здатність матеріалу витримувати високу температуру без значних змін властивостей або руйнування.

Прогнозування термічних властивостей композитних матеріалів є складним завданням через складну структуру та поведінку композитів під впливом температури. Існує кілька основних методів прогнозування:

- аналітичні методи: включають теоретичні моделі та рівняння, які використовуються для розрахунку термічних властивостей на основі

властивостей компонентів. Прикладом є правило сумішей для прогнозування теплопровідності та теплоємності композитів;

- числові методи: використовують комп'ютерні симуляції для прогнозування термічних властивостей. Одним з найбільш поширених числових методів є метод кінцевих елементів, який дозволяє моделювати теплові процеси в складних геометричних структурах композитів;
- експериментальні методи: передбачають проведення лабораторних експериментів для визначення термічних властивостей. Це може бути трудомісткий та дорогий процес, особливо для нових матеріалів;
- методи МН: включають застосування алгоритмів штучного інтелекту для аналізу великих обсягів даних та прогнозування термічних властивостей на основі наявних експериментальних даних. До таких методів належать НМ, k-найближчі сусіди, опорно-векторні машини та інші алгоритми машинного навчання.

МН є галуззю штучного інтелекту, яка вивчає побудову алгоритмів, здатних навчатися на основі наявних даних. Задача МН полягає у знаходженні прихованих залежностей між вхідними даними (прикладами) та вихідними значеннями (відповідями) для прогнозування на основі нових даних. Основними типами МН є:

- навчання з вчителем: мета полягає у навчанні моделі на основі маркованих даних, де кожен приклад має відомий вихідний результат. Наглядове навчання використовується для задач класифікації та регресії;
- навчання без вчителя: використовується для задач, де марковані дані відсутні. Модель навчається знаходити приховані структури в даних, такі як кластеризація або зменшення розмірності;
- змішане навчання: комбінація навчання з вчителем та без вчителя, коли використовується невелика кількість маркованих даних разом з великою кількістю немаркованих.

Загалом, прогнозування термічних властивостей композитних матеріалів за допомогою методів МН є перспективним напрямком досліджень, що дозволяє

значно підвищити ефективність та точність прогнозів. Застосування НМ, к-найближчих сусідів та опорно-векторних машин відкриває нові можливості для аналізу та прогнозування складних властивостей композитних матеріалів, що сприяє їх широкому використанню в промисловості.

## 1.2 Аналіз діаграма деформування матеріалу

Алюмінієвий сплав Al-6061 є одним з найбільш широко використовуваних матеріалів у різних галузях промисловості завдяки його високим механічним властивостям, низькій щільності та відмінній корозійній стійкості. Вивчення його деформування при високих температурах, є важливим для розуміння його поведінки у виробничих процесах, які передбачають нагрівання [2-3]. Автоматизація процесу аналізу діаграм деформування цього сплаву може значно підвищити ефективність і точність виробничих процесів. Зокрема, при високих температурах сплав демонструє зміну своїх механічних властивостей, що необхідно враховувати при проектуванні і виготовленні виробів. При високій температурі спостерігаються такі основні явища:

- зниження міцності: механічні властивості, такі як межа міцності і межа плинності, знижуються;
- збільшення пластичності: висока температура сприяє збільшенню пластичності матеріалу, що дозволяє більшу деформацію без руйнування;
- повзучість: тривала дія високих температур може призвести до повзучості, тобто постійної пластичної деформації під дією постійного навантаження.

Дослідження діаграми деформування сплаву Al-6061 включає наступні етапи:

- підготовка зразків;
- нагрівання: зразки нагріваються до високих температур у контрольованих умовах;
- механічні випробування: виконуються механічні випробування, такі як розтягування, при сталій температурі;

- збирання даних: реєстрація деформації та відповідного навантаження для побудови діаграми деформування.

Відомо, що діаграма деформування відображає залежність між напруженням  $\sigma$  та деформацією  $\epsilon$  матеріалу під час механічного навантаження (рис.1.1).




Рисунок 1.1 – Схематична діаграма деформування матеріалу [1]

Діаграма деформування може мати наступні етапи:

- початкова лінійна область (еластичний режим): в цій області матеріал деформується пружно. При навантажуванні зразка від точки А до точки В зберігається пропорційна залежність між напруженням  $\sigma$  і деформацією  $\epsilon$ ;
- плинність (межа плинності): точка, де матеріал починає деформуватися пластично. На ділянці ВС залежність між напруженням  $\sigma$  і деформацією  $\epsilon$  нелінійною. Точка С відповідає умовній границі текучості  $\sigma_{0,2}$ , тобто напруженню за якого залишкова деформація дорівнює 0,2 %;
- пластична деформація: після межі плинності матеріал продовжує деформуватися при постійному або зростаючому напруженні;

- максимальне напруження (міцність на розрив): найбільше напруження, яке матеріал може витримати. Точка E відповідає початку утворення шийки в зразку. Ордината E відповідає найбільшій рівномірній деформації, яку може витримати зразок. Початок шийкоутворення залежить не тільки від матеріалу і температури випробувань, але і від типу перерізу зразка;
- руйнування: точка, де матеріал руйнується. В F відбувається руйнування зразка.

Основні параметри, які можна визначити з діаграми деформування:

- модуль пружності (E): Визначає пружні властивості матеріалу;
- межа плинності: напруження, при якому починається пластична деформація;
- міцність на розрив: максимальне напруження перед руйнуванням;
- відносне подовження: пластичність матеріалу.

Загалом, використання сучасних систем автоматизації дозволяє значно прискорити і спростити процес збирання даних з випробувань. Системи можуть автоматично реєструвати деформацію і відповідне навантаження, обробляти ці дані в реальному часі і будувати діаграми деформування.

Тому, завдяки методам МН і штучного інтелекту, таким як НМ, метод k-найближчих сусідів та опорно-векторних машин, можна створювати моделі, які прогнозують поведінку матеріалу при різних умовах. Це дозволяє уникнути тривалих і дорогих експериментів, замінюючи їх числовими моделюваннями.

Зокрема, автоматизація дозволяє інтегрувати результати аналізу діаграм деформування в системи управління виробничими процесами. Це дозволяє оперативно коригувати параметри технологічних процесів, забезпечуючи оптимальні умови для виготовлення виробів з необхідними властивостями. А також, автоматизовані системи можуть використовуватися для контролю якості виробів, виявлення дефектів і попередження руйнувань. Це забезпечує високий рівень надійності і безпеки готових виробів.

Отже, вивчення діаграми деформування алюмінієвого сплаву Al-6061 при високих температурах є важливим для розуміння його поведінки у

високотемпературних умовах. Автоматизація цього процесу дозволяє значно підвищити ефективність і точність досліджень, знизити витрати на експериментальні випробування і оптимізувати виробничі процеси. Використання методів МН для прогнозування термічних властивостей композитних матеріалів є перспективним напрямом, що дозволяє створювати високоякісні і надійні вироби з оптимальними характеристиками.

Загалом, прогнозування діаграм деформування композитних матеріалів є важливим завданням для розуміння їх поведінки під навантаженням. Діаграма деформування показує залежність напруження-деформація матеріалу при різних умовах навантаження і температури, а також дозволяють оцінити міцність, пластичність та жорсткість матеріалів. Зокрема, їх також використовують для прогнозування терміну служби матеріалів і визначення їх придатності для конкретних застосувань.

## РОЗДІЛ 2. ПРОЕКТНА ЧАСТИНА

### 2.1 Задача прогнозування термічних властивостей матеріалів

Постановка задачі моделювання є першим і одним з найважливіших етапів у розробці системи прогнозування термічних властивостей композитних матеріалів. Цей етап включає в себе визначення конкретних цілей, завдань та умов, необхідних для успішного вирішення задачі. У даному випадку, основна мета дослідження полягає в прогнозуванні термічних властивостей композитних матеріалів за допомогою методів МН.

Головна мета цього дослідження полягає у створенні ефективних моделей для прогнозування термічних властивостей композитних матеріалів. До таких властивостей можуть належати:

- теплопровідність: здатність матеріалу проводити тепло;
- теплоємність: здатність матеріалу зберігати тепло;
- коефіцієнт теплового розширення: зміна об'єму матеріалу при зміні температури.

Загалом, для прогнозування термічних властивостей необхідно визначити, які параметри матеріалів є ключовими. До таких параметрів можуть належати:

- склад матеріалу: відсотковий вміст різних компонентів у композитному матеріалі;
- структурні характеристики: мікроструктура матеріалу, розмір зерен, пористість;
- механічні властивості: міцність, жорсткість, модуль пружності;
- фізичні властивості: густина, теплоємність.

Для побудови моделей МН необхідно зібрати значний обсяг даних, які включають характеристики матеріалів та результати експериментальних вимірювань термічних властивостей. Основними кроками є:

- збір даних з різних джерел: наукові статті, лабораторні експерименти, виробничі звіти;
- аналіз і очищення даних: видалення шуму, заповнення пропущених значень;
- стандартизація та нормалізація даних: приведення даних до єдиного масштабу.

Для ефективного прогнозування термічних властивостей композитних матеріалів застосовано кілька методів МН:

- НМ: виявлення складних нелінійних залежностей;
- метод k-найближчих сусідів: простота реалізації та здатність до швидкої адаптації;
- опорно-векторні машини: висока точність у випадку з високорозмірними даними.

Розробка спеціалізованого програмного забезпечення для реалізації моделей машинного навчання. Основні задачі включають:

- інтерфейс користувача: для введення даних та налаштування параметрів моделей;
- алгоритми для навчання моделей: реалізація навчання, тестування та оцінки моделей;
- візуалізація результатів: інструменти для графічного представлення результатів моделювання.

Проведення числових експериментів для оцінки точності та надійності моделей включає:

- налаштування експериментів: вибір параметрів та налаштування моделей
- запуск експериментів: виконання навчання та тестування моделей;
- аналіз результатів: збір та аналіз результатів для визначення найбільш ефективних моделей.

Оцінка ефективності моделей включає:

- порівняння результатів прогнозування з експериментальними даними, а саме, визначення точності моделей;



- аналіз похибок: виявлення та аналіз систематичних помилок;
- оптимізація параметрів моделей: налаштування моделей для досягнення максимальної точності.

Отже, розробка рекомендацій щодо впровадження результатів дослідження в практичну діяльність, включаючи:

- використання моделей для прогнозування властивостей матеріалів у виробничих умовах;
- напрямки для подальшого вдосконалення моделей та методів прогнозування.

Таким чином, постановка задачі моделювання включає визначення конкретних цілей та завдань дослідження, збір та підготовку даних, вибір та реалізацію методів МН, проведення числових експериментів та оцінку ефективності моделей. Цей етап є критично важливим для успішного прогнозування термічних властивостей композитних матеріалів і має забезпечити основу для всіх наступних етапів дослідження.

## **2.2 Методи МН для прогнозування діаграм деформування матеріалів**

Вибір методів МН для прогнозування термічних властивостей композитних матеріалів є вирішальним етапом у побудові ефективної та надійної моделі [4]. У цьому розділі розглянемо детально, чому було обрано саме НМ, метод k-найближчих сусідів та опорно-векторних машин. Крім того, буде показано, як ці методи пов'язані з автоматизацією процесів моделювання за допомогою програмного забезпечення STATISTICA.

Зокрема, НМ є потужним інструментом для моделювання складних нелінійних залежностей між вхідними даними і вихідними параметрами. Вони здатні адаптуватися до різних типів даних і виявляти приховані закономірності, які можуть бути неочевидними при використанні традиційних методів. Для прогнозування термічних властивостей композитних матеріалів НМ є особливо корисними через наступні причини:

- гнучкість і універсальність: можуть розраховувати великі дані та навчатися складним функціональним залежностям;
- адаптивність: можуть адаптуватися до нових даних без необхідності повного перенавчання;
- автоматизація: можуть автоматично генерувати прогнози для нових наборів даних, що є важливим для інтеграції в автоматизовані системи.

Метод k-NN є простим і ефективним. Він базується на пошуку найближчих сусідів у багатовимірному просторі ознак. Причини вибору k-NN включають:

- простота реалізації: легко реалізується і не потребує складної моделі навчання;
- інтерпретованість результатів: результати легко інтерпретувати, оскільки вони базуються на найближчих сусідах у тренувальних даних;
- автоматизація: після налаштування k-NN може швидко генерувати прогнози для нових даних, що спрощує його інтеграцію в автоматизовані системи.

Метод SVM є одним з найпотужніших методів для задач класифікації та регресії. Вони використовують гіперплощини для розділення даних у просторі ознак. Причини вибору SVM:

- висока точність: демонструють високу точність у випадках з високорозмірними даними;
- стабільність: моделі SVM є стійкими до перенавчання, особливо при правильному виборі гіперпараметрів;
- автоматизація: моделі SVM можуть бути автоматизовані для масового прогнозування і легко інтегруються в програмні пакети, такі як STATISTICA.

Отже, STATISTICA є потужним програмним забезпеченням для аналізу даних, яке підтримує різні методи МН. Воно забезпечує інтуїтивний інтерфейс користувача, широкий набір інструментів для аналізу даних та моделювання, а також можливості для автоматизації процесів.

STATISTICA також пропонує вбудовані інструменти для налаштування і навчання НМ. Ці інструменти дозволяють:

- визначати архітектуру мережі: а саме, вибір кількості шарів і нейронів у кожному шарі;
- налаштовувати параметри навчання: тобто, вибір алгоритмів навчання, функцій активації, темпу навчання;
- автоматизувати процес навчання: зокрема, використання функцій автоматичного налаштування параметрів для оптимізації моделі;
- генерувати прогнози: можливість автоматичного генерування прогнозів для нових наборів даних без втручання користувача.

Метод k-NN у STATISTICA реалізований таким чином, що користувач може:

- налаштувати параметр k: тобто, вибір оптимального значення k на основі даних навчання;
- аналізувати результати: Візуалізувати результати та інтерпретувати прогнози;
- автоматизувати процес прогнозування: застосовувати налаштовану модель для автоматичного прогнозування нових даних.

SVM у STATISTICA мають наступні можливості:

- налаштування гіперпараметрів: вибір ядра, параметрів регуляризації, гама-параметрів тощо;
- навчання моделі: зокрема, використання оптимізаційних алгоритмів для навчання моделі на тренувальних даних;
- автоматизація: тобто, автоматичне застосування налаштованої моделі для прогнозування нових даних, що робить SVM зручним для інтеграції в автоматизовані системи.

Загалом, вибір НМ, методу k-найближчих сусідів та опорно-векторних машин для прогнозування термічних властивостей композитних матеріалів обґрунтований їх високою точністю, гнучкістю та можливістю автоматизації. Програмне забезпечення STATISTICA забезпечує всі необхідні інструменти для

налаштування, навчання та автоматизації цих методів, що дозволяє інтегрувати моделі МН у виробничі процеси з мінімальними зусиллями.

## 2.3 Алгоритм НМ

Теорія нейромереж є міждисциплінарною галуззю, котра тісно пов'язана з нейробиологією, математикою, психологією, фізикою та інженерією. Зокрема, основою НМ є штучний нейрон, що імітує нервову клітину мозку (рис. 2.1 та 2.2). НМ, зазвичай, моделюють у програмному забезпеченні або будуються з електронних компонентів для виконання обчислень на основі навчання. Для досягнення високої продуктивності вони використовують взаємозв'язок простих нейронів [5].




Рисунок 2.1 – Схематичне зображення нейронів та мозку

НМ схожі на людський мозок у двох аспектах:

- знання надходять у мережу з навколишнього середовища і використовуються в процесі навчання;
- для збереження знань використовують міцні з'єднання нейронів, відомі як синаптичні ваги.




Рисунок 2.2 – Модель нейрона

Основними формулами функціонування нейрона є:

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

$$Out_{jl} = F(NET_{jl} - \theta_{jl}), \quad (2.1)$$

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

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;  $\theta_{jl}$  – пороговий рівень даного нейрона.

Важливими властивостями НМ є:

- нелінійність: НМ складається з нелінійних нейронів, що важливо для обробки нелінійних сигналів;
- відображення входу-виходу: нагадує навчання з учителем, де синаптичні ваги налаштовуються на основі навчальних прикладів;

- адаптивність: можуть адаптувати свої синаптичні ваги до змін у середовищі;
- очевидність відповіді: НМ може надавати впевненість у прийнятому рішенні, що важливо для класифікаційних задач;
- контекстна інформація: кожен нейрон потенційно залежить від глобальної активності інших нейронів;
- відмовостійкість: НМ має потенціал витримувати несприятливі умови експлуатації з незначним падінням продуктивності.

Загалом, людську нервову систему розглядає як трирівневу структуру з мозком, що обробляє інформацію, та синапсами, що передають імпульси між нейронами. Тому штучний нейрон моделюється за допомогою синапсів із вагами, суматора та функції активації.

Математичний опис нейрона включає ваги синапсів, суматор і функцію активації, що визначає вихідний сигнал. Подаються різні види активаційних функцій, серед яких сигмоїдальна є найбільш поширеною у НМ.

Зворотний зв'язок у НМ, що є характерним для динамічних систем, розглядається через приклади рекурентних мереж. Такі мережі використовуються для дослідження стабільності та навчання систем із зворотним зв'язком.

У підсумку, символічні моделі ШІ базуються на алгоритмах і представленні даних "зверху вниз", тоді як НМ працюють за принципом "знизу вгору". Об'єднання цих підходів створює гібридні системи, що поєднують адаптивність і універсальність НМ з інтелектуальними властивостями штучного інтелекту.

## **2.4 Парадигми навчання НМ**

МН розділяється на кілька основних парадигм, кожна з яких має свої особливості, методи та області застосування [5]. Загалом, розглянемо детально три фундаментальні парадигми навчання: навчання з учителем, навчання без учителя та змішане навчання (рис. 2.3).

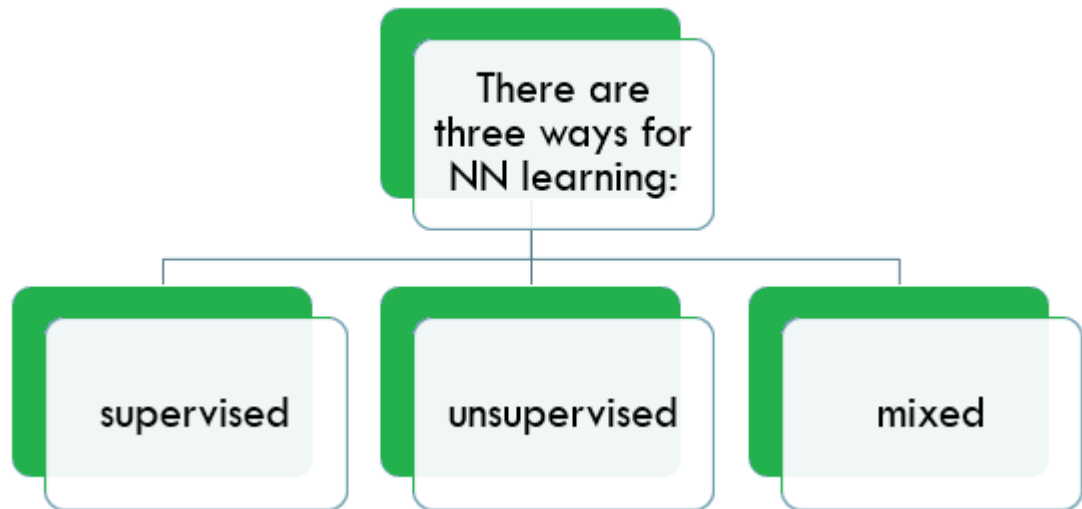


Рисунок 2.3 – Парадигми навчання

### 1. Навчання з учителем (supervised learning)

Навчання з учителем є однією з найбільш розповсюджених і вивчених парадигм МН. Тут модель навчається на основі даних, які містять вхідні значення та відповідні їм вихідні мітки (мічені дані).

Основними компонентами є:

- вхідні дані (Features): вектор характеристик  $x$ , що описує об'єкт;
- мітка (Label): вихідне значення  $y$ , що відповідає вхідним даним. Це може бути клас (для задач класифікації) або числове значення (для задач регресії);
- функція втрат (Loss Function): визначає різницю між передбаченнями моделі та реальними мітками. Мета навчання полягає в мінімізації цієї функції;
- алгоритм оптимізації: використовується для мінімізації функції втрат шляхом оновлення вагів моделі.

Прикладами таких алгоритмів є:

- лінійна регресія: використовується для прогнозування числових значень;

- логістична регресія: використовується для бінарної класифікації;
- дерева рішень: використовуються для класифікації та регресії;
- НМ: використовуються для складних задач регресії;
- SVM: застосовують для класифікації та регресії.

Основними етапами процесу навчання є:

- збір даних: формування набору мічених даних;
- розділення даних: розділення набору даних на тренувальну та тестову частини;
- навчання: модель навчається на тренувальних даних, мінімізуючи функцію втрат;
- оцінка: перевірка продуктивності моделі на тестових даних.

Переваги:

- висока точність при наявності великої кількості мічених даних;
- прямий контроль над процесом навчання завдяки міченим даним.

Недоліки:

- необхідність великої кількості мічених даних, які можуть бути складними та дорогими у збиранні;
- можливість перенавчання, коли модель добре працює на тренувальних даних, але погано на нових.

## 2. Навчання без учителя (Unsupervised Learning)

Навчання без учителя працює з неміченими даними, де модель має самостійно виявляти структури, закономірності та групи в даних.

Основними компонентами є:

- вхідні дані: Вектор характеристик  $x$ , що описує об'єкт;
- моделі: використовуються для виявлення схованих структур у даних.

Прикладами таких алгоритмів є:

- кластеризація

Процес навчання:

- збір даних: формування набору немічених даних;



- навчання: модель аналізує дані та виявляє сховані структури без явних міток;
- оцінка: верифікація знайдених структур і закономірностей, інтерпретація результатів.

Переваги:

- можливість виявлення схованих структур та закономірностей у даних;
- не потребує мічених даних, що знижує витрати на збирання даних.

Недоліки:

- важко оцінити якість знайдених структур та результатів;
- відсутність контролю над процесом навчання.

### 3. Змішане навчання (mixed)

Змішане навчання поєднує елементи навчання з учителем і без нього.

Використовується, коли наявна обмежена кількість мічених даних разом з великою кількістю немічених даних.

Основними компонентами є:

- мічені дані: вхідні дані з відповідними мітками;
- немічені дані: вхідні дані без міток.

Приклади алгоритмів:

- Co-training: використовує два або більше моделей, які навчаються на різних частинах даних та взаємно допомагають одна одній;
- Self-training: модель навчається на мічених даних, потім використовує свої передбачення для міток немічених даних;
- Transductive Learning: мета — передбачити мітки конкретного набору немічених даних, який доступний під час навчання.

Процес навчання:

- збір даних: формування набору мічених та немічених даних;
- навчання: модель спочатку навчається на мічених даних, потім використовує немічені дані для подальшого вдосконалення;
- оцінка: верифікація продуктивності моделі на тестових даних, що можуть містити як мічені, так і немічені частини.

Переваги:

- ефективне використання великої кількості немічених даних для покращення продуктивності;
- зниження витрат на збирання та міткування даних.

Недоліки:

- складність у налаштуванні моделей та виборі оптимальних параметрів;
- можливість помилок при використанні немічених даних для подальшого навчання.

Фундаментальні парадигми навчання — це основа сучасних методів МН. Навчання з учителем забезпечує високу точність при наявності достатньої кількості мічених даних. Навчання без учителя дозволяє виявляти сховані структури в немічених даних. Змішане навчання комбінує переваги обох підходів, що дозволяє ефективно використовувати обмежену кількість мічених даних разом з великою кількістю немічених. Кожна з цих парадигм має свої переваги та недоліки, що робить їх застосування залежним від конкретної задачі та наявних даних.

## 2.5 Зворотне поширення помилки НМ

Зворотне поширення помилки – це один з ключових алгоритмів для тренування штучних нейронних мереж. Він використовується для мінімізації функції втрат шляхом коригування вагів мережі на основі помилки між передбаченнями моделі та фактичними мітками. Зворотне поширення є важливою складовою процесу градієнтного спуску.

Основними компонентами та етапами алгоритму зворотного поширення є:

- архітектура НМ:
  - вхідний шар: отримує початкові дані;
  - приховані шари: один або більше шарів, де відбувається обробка та трансформація даних;
  - вихідний шар: видає кінцевий результат моделі.

- вхідні дані передаються через мережу від вхідного шару до вихідного. На кожному нейроні виконується лінійне перетворення, після чого застосовується активаційна функція.
- обчислення функції втрат:
  - визначає різницю між передбаченнями моделі та фактичними мітками;
  - популярні функції втрат включають середньоквадратичну помилку (MSE) для регресії та перехресну ентропію (Cross-Entropy) для класифікації.
- зворотне поширення помилки:
  - алгоритм починається з вихідного шару, де обчислюється похибка для кожного нейрона;
  - похибка зворотно передається через шари мережі, і ваги коригуються на основі градієнта функції втрат.
- оновлення вагів:
  - ваги оновлюються за допомогою алгоритму оптимізації, такого як градієнтний спуск.

Алгоритм зворотного поширення помилки є основним інструментом для навчання НМ. Він дозволяє ефективно коригувати ваги мережі на основі похибки між передбаченнями та фактичними значеннями, що забезпечує мінімізацію функції втрат і покращення продуктивності моделі. Зворотне поширення використовується у поєднанні з градієнтним спуском та іншими методами оптимізації, що робить його потужним і гнучким інструментом для широкого спектра задач машинного навчання.

## 2.6 Метод k-найближчих сусідів

Метод k-найближчих сусідів є одним з найпростіших і найбільш інтуїтивно зрозумілих алгоритмів МН [6-7], котрий застосовують для вирішення задач регресії. Основна ідея k-NN полягає в тому, що передбачення для нового зразка

базується на його близькості до інших зразків у навчальній вибірці (рис. 2.4). Зокрема, всі зразки представлені як точки у багатовимірному просторі ознак. Відстань між точками визначається за допомогою метрики відстані, найчастіше використовується евклідова відстань.




Рисунок 2.4 – Приклад методу  $k$ -найближчих сусідів []

Для нового зразка визначаються його  $k$  найближчих сусідів у навчальній вибірці. Тому новий зразок класифікується в той клас, який є найбільш поширеним серед його  $k$  сусідів. Для регресійних моделей прогнозоване значення вихідної змінної обчислюється як середнє значення вихідних змінних його  $k$  найближчих сусідів.

Важливим є вибір параметра  $k$ :

- значення параметра  $k$  є критично важливим для роботи алгоритму:
  - мале значення  $k$  (наприклад,  $k=1$ ): алгоритм буде дуже чутливий до шуму у навчальній вибірці, що може призвести до перенавчання;
  - велике значення  $k$ : алгоритм може стати занадто гладким, що може призвести до недонавчання.

Оптимальне значення  $k$  зазвичай визначається експериментально за допомогою перехресної перевірки.

Перевагами є:

- простота реалізації та розуміння: алгоритм  $k$ -NN легко реалізувати та зрозуміти;

- гнучкість: алгоритм може використовувати різні метрики відстані та легко адаптується до нових даних;
- немає необхідності в навчанні: Алгоритм є «випадковим», тобто не вимагає етапу навчання, лише зберігає всі навчальні дані.

Недоліками є:

- високі обчислювальні витрати: пошук найближчих сусідів для нового зразка може бути обчислювально інтенсивним, особливо для великих навчальних вибірок;
- висока пам'яттєва складність: алгоритм потребує зберігання всієї навчальної вибірки в пам'яті;
- чутливість до шуму: наявність шуму в даних може сильно вплинути на точність алгоритму, особливо при малих значеннях  $k$ .

Для того, аби поліпшити алгоритм  $k$ -NN необхідно:

- нормалізувати дані: оскільки  $k$ -NN базується на обчисленні відстаней, важливо нормалізувати ознаки, щоб вони мали однаковий масштаб. Наприклад, можна використовувати мін-макс нормалізацію;
- використання вагів: можна враховувати відстань сусідів при прийнятті рішення, надаючи ближчим сусідам більшу вагу;
- пошук найближчих сусідів: для пришвидшення пошуку найближчих сусідів використовують структури даних, такі як  $kd$ -дерева або метод LSH.

Приклади застосування:

- класифікація зображень:  $k$ -NN може використовуватися для класифікації зображень на основі схожості між піксельними значеннями;
- рекомендаційні системи: алгоритм застосовується для прогнозування уподобань користувачів на основі схожості з іншими користувачами;
- аналіз текстів:  $k$ -NN можна використовувати для класифікації текстових документів на основі схожості між векторизованими представленнями текстів.

Загалом, метод  $k$ -найближчих сусідів є потужним інструментом для задач класифікації та регресії. Його простота та інтуїтивність роблять його популярним вибором у багатьох прикладних задачах машинного навчання. Однак високі обчислювальні витрати та чутливість до шуму вимагають уважного підходу до його застосування та оптимізації. Його основна сила полягає в інтуїтивній простоті та гнучкості у використанні різних метрик відстані. Однак для досягнення високої точності необхідно враховувати оптимальний вибір параметра  $k$ , нормалізацію даних, використання вагів і оптимізацію процесу пошуку сусідів. Завдяки своїй універсальності,  $k$ -NN залишається популярним вибором у багатьох прикладних задачах МН.

## **2.7 Метод опорно-векторних машин**

Метод опорно-векторних машин є одним із найбільш потужних та популярних алгоритмів МН для задач класифікації та регресії [8-9]. SVM використовують геометричний підхід до знаходження гіперплощини, яка найкраще розділяє дані в просторі ознак. Основна ідея алгоритму полягає в максимізації відстані між гіперплощиною та найближчими зразками з кожного класу, що забезпечує кращу узагальнювальну здатність моделі.




Рисунок 2.5 – Приклад методу опорно-векторних машин []

Основними концепціями є:

- гіперплощина:
- опорні вектори — це ті зразки з навчальної вибірки, які знаходяться найближче до гіперплощини та визначають її положення. Вони відіграють ключову роль у побудові оптимальної гіперплощини.
- межа (маржа) відокремлення: маржа — це відстань між гіперплощиною та найближчими зразками з кожного класу. SVM намагається максимізувати цю маржу, щоб забезпечити кращу узагальнювальну здатність моделі.

Кроки алгоритму SVM:

- вибір ядрової функції та параметрів моделі;
- обчислення матриці ядра для всіх пар зразків у навчальній вибірці;
- розв'язання задачі оптимізації для знаходження вектора коефіцієнтів та зміщення;
- класифікація нових зразків на основі знаку функції рішення.

Вибір параметрів та ядрової функції:

- вибір параметра  $C$  визначає компроміс між шириною маржі та кількістю допущених помилок. Високе значення  $C$  призводить до меншої кількості помилок, але вузької маржі;
- параметр  $\gamma$  у RBF ядрі визначає вплив кожного окремого зразка: високе значення  $\gamma$  призводить до вузької зони впливу;
- оптимальні значення параметрів часто визначаються за допомогою перехресної перевірки.

До поліпшення та оптимізації SVM належить:

- масштабування даних: важливо нормалізувати ознаки, щоб забезпечити, що всі ознаки мають однаковий масштаб. Це особливо важливо при використанні ядрових функцій;
- вибір ядрової функції: вибір ядра значно впливає на результати моделі. Радіально-базисне функціональне ядро є універсальним вибором, але в деяких задачах поліноміальне або сигмоїдне ядро можуть дати кращі результати;
- розв'язання задачі оптимізації: для розв'язання задачі оптимізації використовуються методи квадратичного програмування. Одним з ефективних методів є алгоритм SMO (Sequential Minimal Optimization);
- перехресна перевірка: для вибору оптимальних параметрів моделі (наприклад,  $C$  та  $\gamma$ ) використовується метод перехресної перевірки, який дозволяє оцінити узагальнювальну здатність моделі на незалежних вибірках.

Прикладами застосування SVM є:

- розпізнавання образів: SVM широко використовується для задач розпізнавання образів, таких як класифікація рукописних цифр або розпізнавання обличчя;
- аналіз текстів: SVM використовується для класифікації текстових документів, таких як спам-фільтрація або тематична класифікація;



- біоінформатика: у біоінформатиці SVM застосовуються для аналізу ДНК, прогнозування білкових структур та класифікації біомедичних даних.

SVM є потужним інструментом для задач класифікації та регресії завдяки своїй здатності ефективно працювати з нелінійними залежностями і забезпечувати хорошу узагальнювальну здатність. Використання різних ядрових функцій дозволяє адаптувати алгоритм до широкого спектра задач. Однак, для досягнення оптимальних результатів необхідно ретельно вибирати параметри моделі та проводити масштабування даних. Завдяки своїй універсальності та потужності, SVM залишається популярним вибором у багатьох прикладних задачах МН.

## **2.8 Підготовка даних для прогнозування**

Збір і підготовка даних є критичними етапами в процесі створення моделі МН. Без якісних і добре підготовлених даних навіть найкращі алгоритми МН не здатні дати задовільні результати. Цей розділ присвячений опису процесів збору, очищення, трансформації та розподілу даних для подальшого моделювання. Зокрема, збір даних включає в себе процес виявлення, збирання та об'єднання даних з різних джерел.

Основні етапи збору даних включають:

- визначення джерел даних: визначення джерел, з яких будуть зібрані дані. Це можуть бути бази даних, API, веб-сайти, файли (CSV, Excel), сенсори, тощо;
- автоматизований збір даних: використання скриптів або інструментів для автоматизованого збору даних з веб-сторінок (веб-скрапінг), API (за допомогою запитів), баз даних (SQL-запити), тощо;
- ручний збір даних: у випадках, коли автоматизація неможлива або недоцільна, дані можуть збиратися вручну через опитування, анкети, інтерв'ю, тощо.

Очищення даних є необхідним кроком для забезпечення якості та надійності моделі. Основні етапи очищення даних включають:

- обробка пропущених значень: заповнення пропущених значень (імпутація) середніми, медіанними значеннями або спеціальними алгоритмами. Видалення записів з пропущеними значеннями (за умови, що це не впливає на репрезентативність даних);
- виявлення та видалення аномалій: використання статистичних методів (наприклад, Z-оцінки) або методів МН для виявлення та видалення аномальних значень, які можуть негативно вплинути на модель;
- обробка дубльованих записів: видалення або об'єднання дубльованих записів для уникнення викривлення результатів;
- корекція помилок у даних: виправлення помилок, таких як орфографічні помилки, неправильні формати дат, невірні значення, тощо.

Трансформація даних включає процеси перетворення даних у форму, яка є більш придатною для аналізу та моделювання. Основні етапи трансформації даних включають:

- масштабування та нормалізація: масштабування даних (наприклад, мін-макс нормалізація) для приведення значень до певного діапазону. Нормалізація даних (наприклад, стандартизація) для приведення розподілу ознак до нормального розподілу;
- кодування категоріальних ознак: використання методів One-Hot Encoding, Label Encoding або інших підходів для перетворення категоріальних ознак у числові значення;
- генерація нових ознак: створення нових ознак на основі існуючих даних (наприклад, поєднання кількох ознак, обчислення статистичних характеристик);
- зменшення розмірності: використання методів, таких як PCA (Principal Component Analysis), для зменшення кількості ознак, що дозволяє зменшити обчислювальні витрати та уникнути перенавчання.

Розподіл даних на навчальну, валідаційну та тестову вибірки є важливим кроком для оцінки та налаштування моделі. Основні етапи включають:

- розподіл на навчальну та тестову вибірки: відділення певної частини даних (зазвичай 20-30%) для тестування моделі, а решти даних — для навчання;
- стратифікований розподіл: забезпечення однакового розподілу класів у навчальній та тестовій вибірках для уникнення дисбалансу;
- розподіл на навчальну, валідаційну та тестову вибірки: розділення даних на три частини: навчальна вибірка для побудови моделі, валідаційна вибірка для налаштування гіперпараметрів, тестова вибірка для остаточної оцінки моделі;
- перехресна перевірка (cross-validation): використання методів перехресної перевірки (наприклад, k-fold cross-validation) для більш надійної оцінки узагальнювальної здатності моделі.

Збір і підготовка даних є фундаментальними етапами процесу моделювання, які значно впливають на якість та точність моделі. Дотримання кращих практик під час збору, очищення, трансформації та розподілу даних забезпечує створення надійних і ефективних моделей МН. Успішне виконання цих етапів дозволяє отримати коректні результати та приймати обґрунтовані рішення на основі аналізу даних.

## 2.9 Нормалізація даних

Нормалізація даних — це важливий етап підготовки даних, який полягає в перетворенні ознак у набір даних у такий спосіб, щоб їхні значення були приведені до певного масштабу або розподілу. Це дозволяє уникнути проблем, пов'язаних із різними діапазонами значень ознак, і покращити продуктивність алгоритмів машинного навчання.

Причинами для нормалізації даних є:

- зменшення впливу великого масштабу одних ознак над іншими: ознаки з більшими числовими значеннями можуть домінувати під час обчислення відстаней або градієнтів, що впливає на навчання моделі;
- покращення швидкості та стабільності алгоритмів: нормалізація дозволяє алгоритмам швидше сходитися до оптимального рішення, зменшуючи числову нестабільність;
- уніфікація ознак для методів, що базуються на відстані: алгоритми, такі як к-найближчі сусіди (кNN) або кластеризація, покладаються на обчислення відстаней між точками, і нормалізація забезпечує коректне обчислення цих відстаней.

Методами нормалізації даних є:

- мін-макс нормалізація (Min-Max Normalization): мін-макс нормалізація приводить значення ознак до заданого діапазону, зазвичай від 0 до 1.

Формула для мін-макс нормалізації:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}$$

де  $x$  — початкове значення ознаки,  $x_{min}$  і  $x_{max}$  — мінімальне та максимальне значення ознаки відповідно.

Переваги:

- зберігає співвідношення між значеннями. Підходить для даних, які мають відомі межі.

Недоліки:

- чутлива до викидів (аномальних значень).

Z-оцінка (Z-score Normalization) або стандартизація:

- стандартизація приводить значення ознак до розподілу з середнім значенням 0 і стандартним відхиленням 1. Формула для стандартизації:

$$x' = \frac{x - \mu}{\sigma}$$

де  $x$  — початкове значення ознаки,  $\mu$  — середнє значення ознаки,  $\sigma$  — стандартне відхилення ознаки.

Переваги:

- добре працює з даними, які мають нормальний розподіл;
- менш чутлива до викидів порівняно з мін-макс нормалізацією.

Недоліки:

- може бути складно інтерпретувати стандартизовані значення.

Практичними аспектами нормалізації є:

- вибір методу нормалізації: вибір методу нормалізації залежить від типу даних і вимог до моделі. Наприклад, для методів, що базуються на відстані, краще використовувати мін-макс нормалізацію або стандартизацію;
- збереження параметрів нормалізації: параметри нормалізації (середнє значення, стандартне відхилення, мінімум, максимум) потрібно зберігати і застосовувати однаково до навчальних і тестових даних;
- вплив на інтерпретацію результатів: після нормалізації важливо правильно інтерпретувати результати моделі, оскільки нормалізовані значення можуть мати інше значення.

Нормалізація даних є важливою частиною підготовки даних для МН. Вона допомагає забезпечити стабільність і ефективність роботи алгоритмів, зменшує числову нестабільність і робить навчання моделей більш ефективним. Правильний вибір і застосування методів нормалізації дозволяють отримати більш точні та надійні моделі.

## **2.10 Розробка програмного забезпечення для прогнозування термічних властивостей матеріалів**

Розробка програмного забезпечення для моделювання у STATISTICA включає кілька важливих етапів. STATISTICA є потужним інструментом для статистичного аналізу, який також надає можливості для моделювання та застосування алгоритмів МН.

Першим кроком у розробці програмного забезпечення для моделювання є інсталяція та налаштування STATISTICA. Це включає:

- завантаження і встановлення програмного забезпечення;
- налаштування робочого середовища відповідно до потреб проекту;
- інтеграція необхідних модулів і плагінів для виконання специфічних задач моделювання.

Наступним кроком є завантаження та підготовка даних для моделювання.

Це включає:

- імпорт даних: STATISTICA підтримує імпорт даних з різних джерел, таких як файли CSV, Excel, бази даних (SQL, Oracle), текстові файли та інші формати. Необхідно вибрати відповідний формат і здійснити імпорт даних у середовище STATISTICA (рис.2.6 та 2.7);

	1 log10 Stress	2 T (F)	3 log10 Strain	4 Var4	5 Var5	6 Var6	7 Var7	8 Var8	9 Var9	10 Var10
1	2,311014	775	-2,86328							
2	2,61207	775	-2,87943							
3	2,788077	775	-2,88941							
4	2,913029	775	-2,8962							
5	3,009901	775	-2,89963							
6	3,089096	775	-2,90658							
7	3,156064	775	-2,90658							
8	3,214049	775	-2,91009							
9	3,265214	775	-2,91009							
10	3,310952	775	-2,91009							
11	3,35237	775	-2,91364							
12	3,390166	775	-2,91721							
13	3,424922	775	-2,91721							
14	3,457114	775	-2,91721							
15	3,487066	775	-2,91364							
16	3,515096	775	-2,91009							
17	3,541423	775	-2,90658							

Рисунок 2.6 – База з даними у STATISTICA

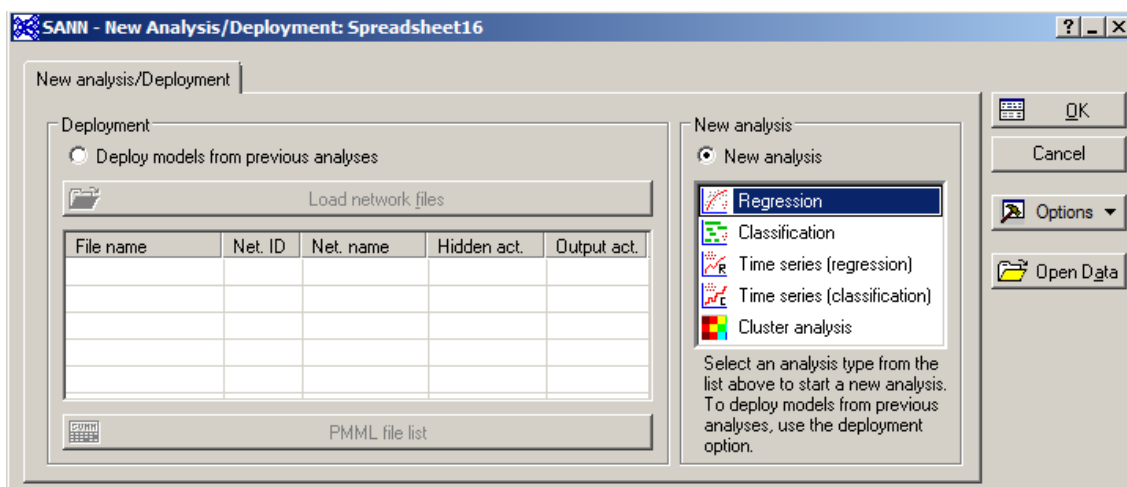


Рисунок 2.7 – Команди Regression у STATISTICA

- очищення даних: на цьому етапі необхідно очистити дані від помилок та пропущених значень. Це включає видалення або заміну пропущених значень, виправлення помилок у даних, обробку аномалій.
- перетворення даних: може бути необхідним перетворення даних у потрібний формат для подальшого аналізу. Наприклад, категоріальні дані

можуть бути перетворені в числові, застосування методів нормалізації та масштабування.

Після підготовки даних можна перейти до вибору та налаштування моделей. STATISTICA підтримує різноманітні моделі МН:

- ММ: на рис.2.8 та 2.9 показано задання вхідних і вихідних значень моделі;
- ММ: налаштування архітектури мережі (кількість шарів, кількість нейронів у кожному шарі, функції активації);

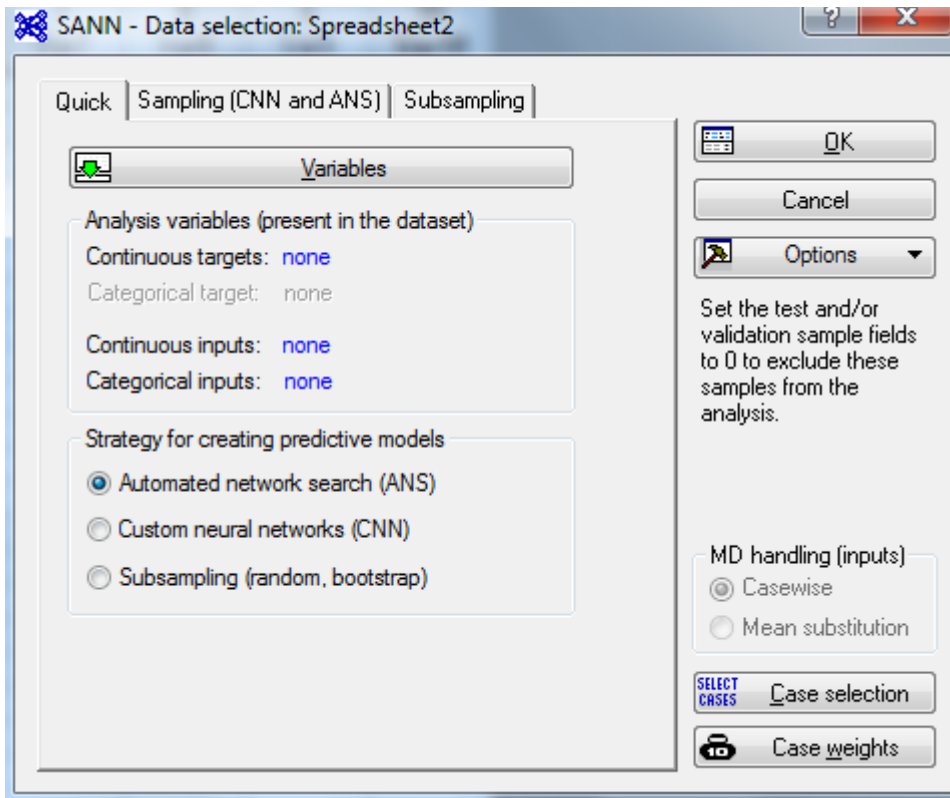


Рисунок 2.8 – Вікно задання змінних у STATISTICA



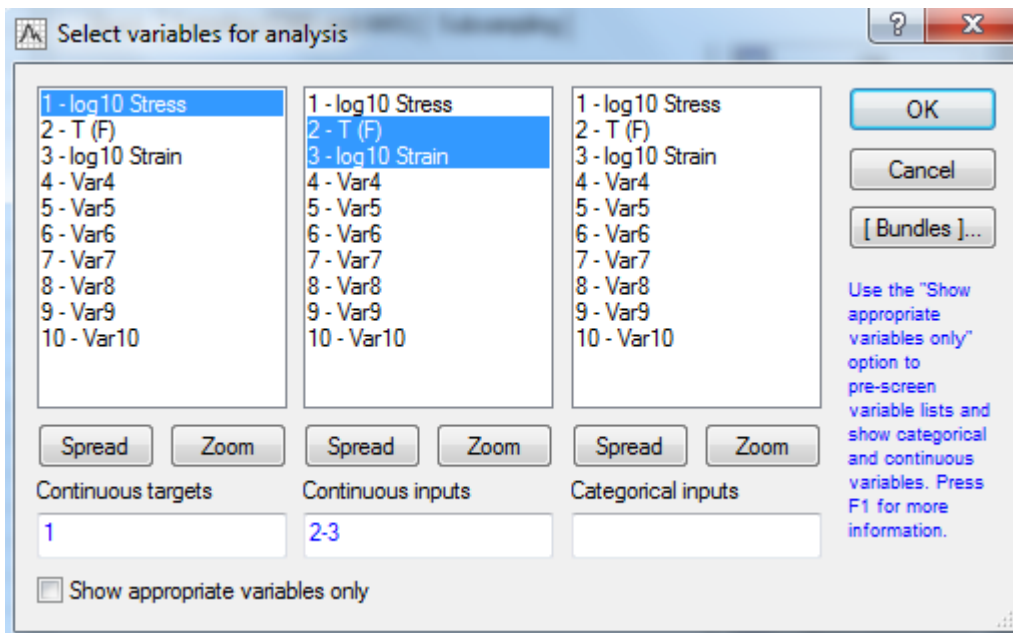


Рисунок 2.9 – Вікно присвоєння змінних у STATISTICA

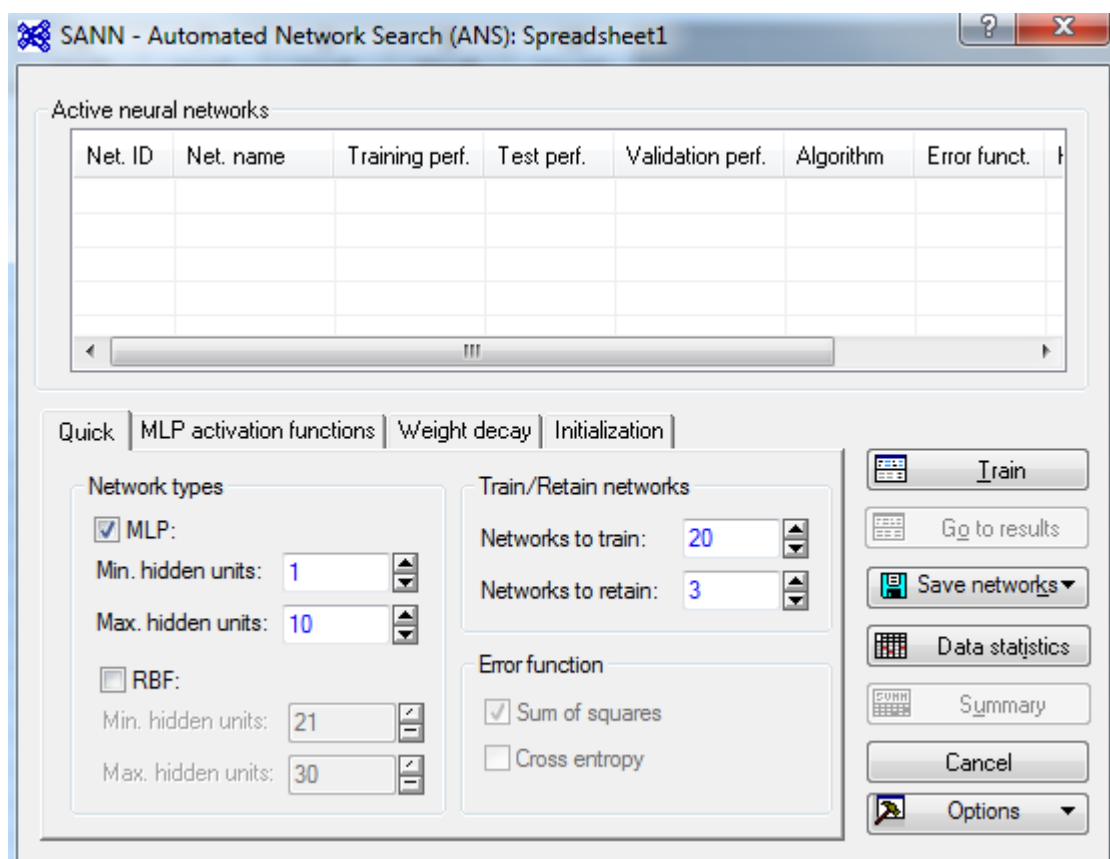


Рисунок 2.10 – Налаштування параметрів НМ

- метод  $k$ -найближчих сусідів: вибір кількості сусідів  $k$ , метрики відстані (рис.2.11) (евклідова, мангеттенська тощо);

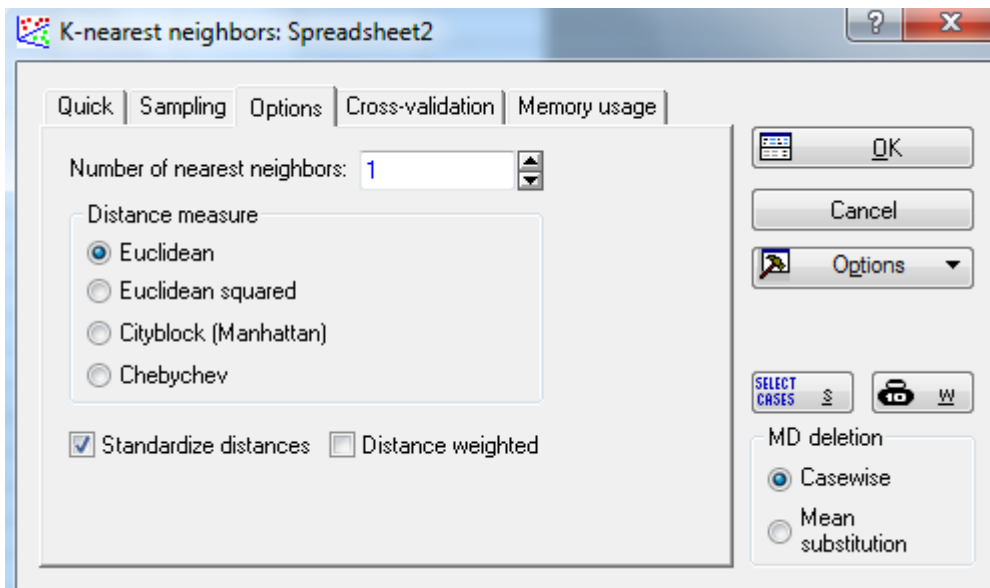


Рисунок 2.11 – Вікно вибору кількості сусідів у STATISTICA

- опорно-векторні машини: вибір ядра (лінійне, поліноміальне, радіальна базисна функція), налаштування параметрів регуляризації (рис.2.12).

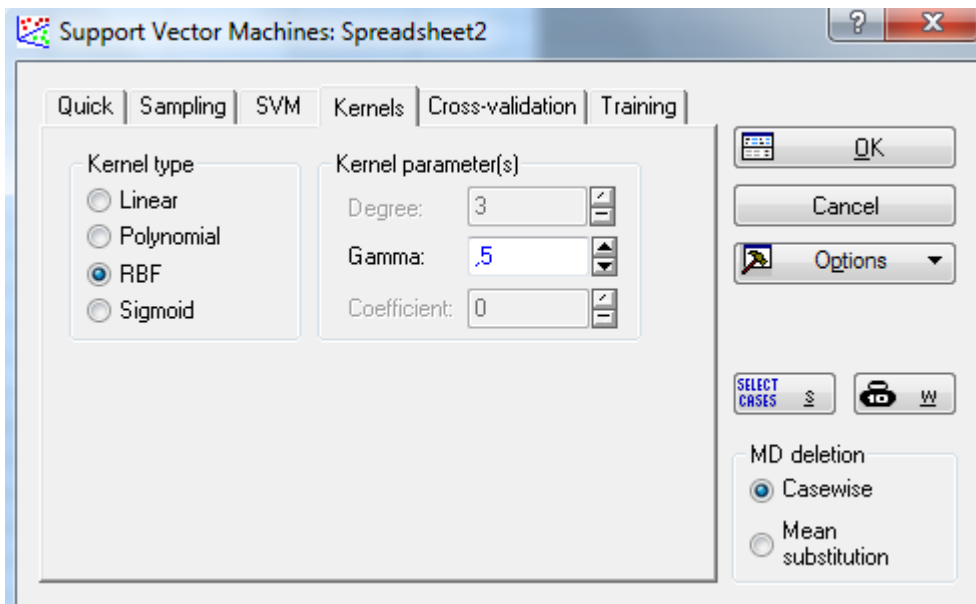


Рисунок 2.12 – Вікно вибору ядра у STATISTICA

Розробка моделей МН включає:

- вибір алгоритмів: вибір відповідних алгоритмів МН на основі поставлених задач. Це можуть бути нейронні мережі, дерева рішень, регресійні моделі, методи кластеризації тощо;
- створення моделей: створення моделей у STATISTICA з використанням інтерфейсу або мов програмування, таких як R або Python, інтегрованих у середовище STATISTICA;
- налаштування параметрів: налаштування параметрів та гіперпараметрів моделей для досягнення оптимальної продуктивності. Це може включати налаштування кількості шарів і нейронів у нейронній мережі, критеріїв розгалуження у дереві рішень тощо.

Оцінка та валідація моделей включає:

- розподіл даних: розподіл даних на навчальні та тестові вибірки для перевірки моделі на нових, невідомих даних (рис.2.13);

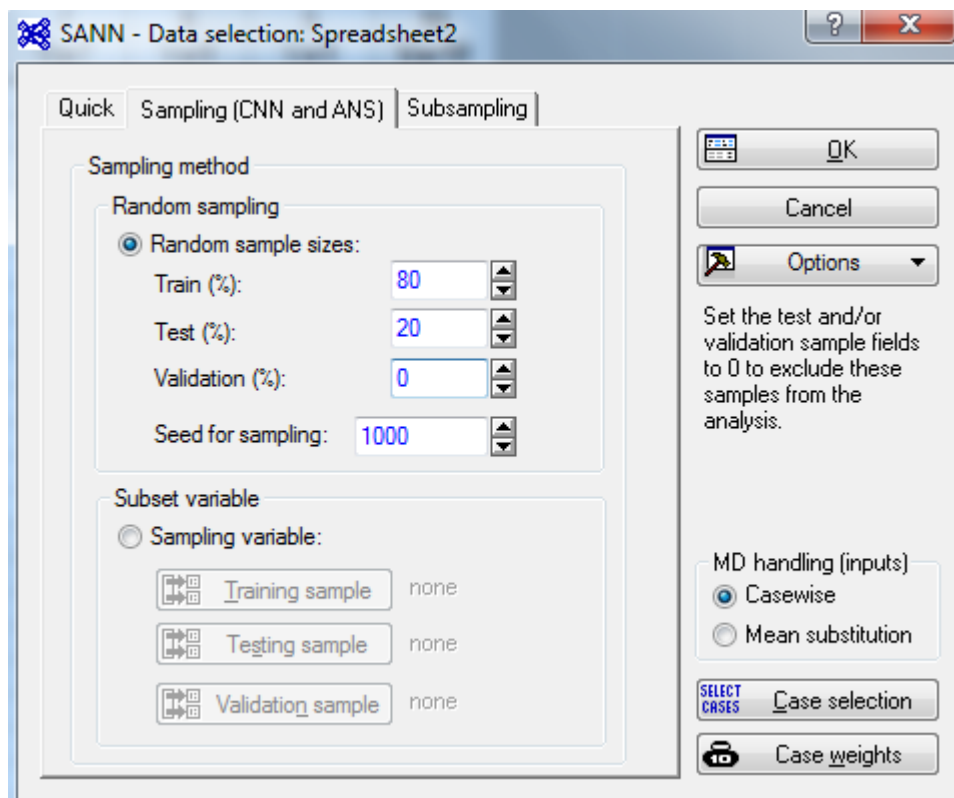


Рисунок 2.13 – Вікно розподілу даних на вибірки у STATISTICA

- оцінка продуктивності: використання різних метрик для оцінки продуктивності моделі, таких як точність, повнота, F-міра, середньоквадратична помилка, ROC-AUC та інші (рис. 2.14 та 2.15);

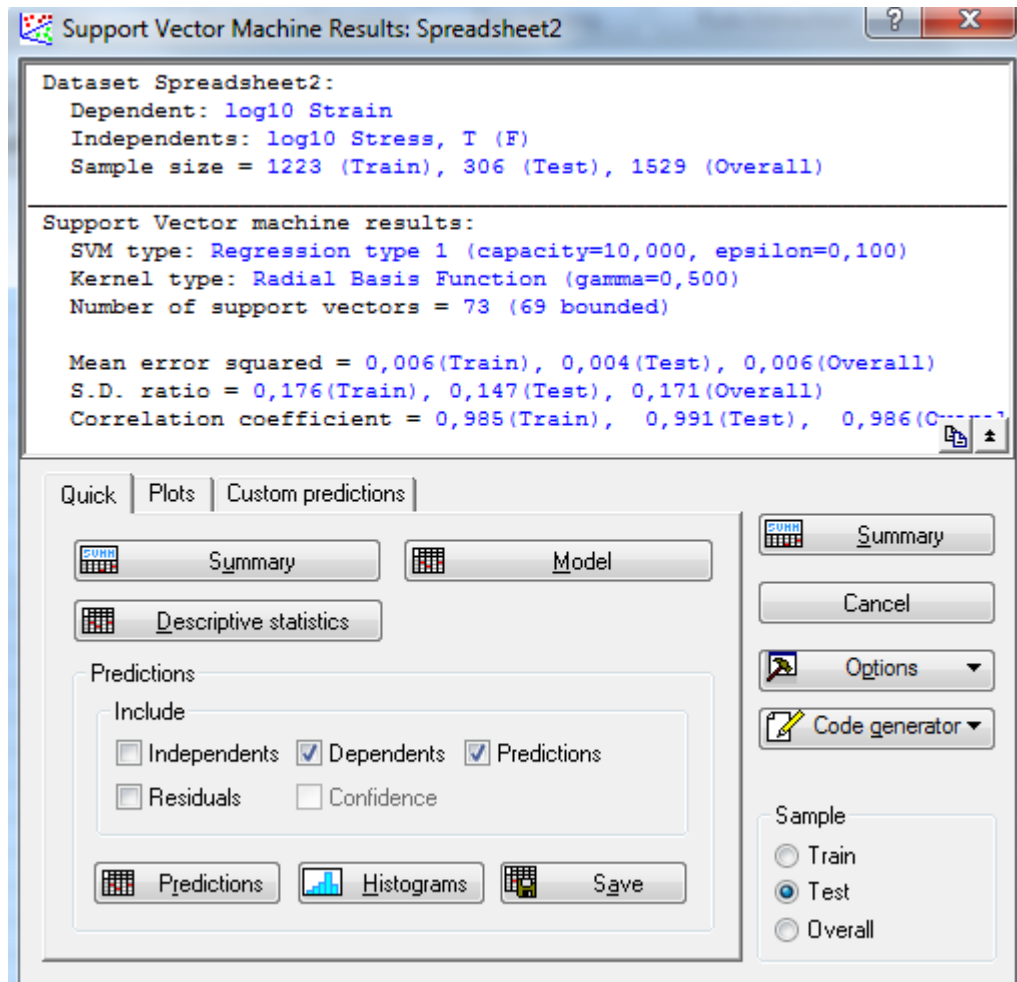


Рисунок 2.14 – Вікно отриманих даних на вибірки у STATISTICA

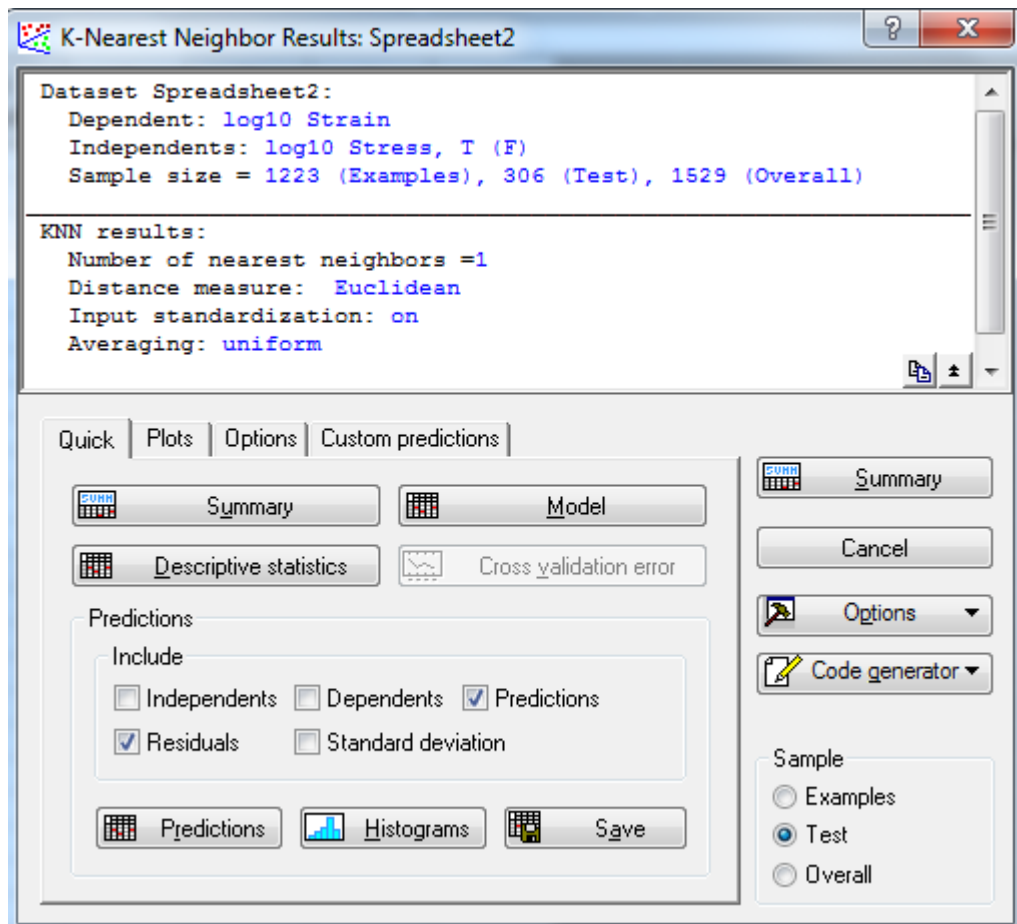


Рисунок 2.15 – Вікно отриманих даних на вибірки у STATISTICA

- перехресна валідація: використання методів перехресної валідації для перевірки стабільності та узагальнювальної здатності моделей. Це включає k-кратну перехресну валідацію, де дані діляться на k частин, і модель тренується k разів на різних підмножинах даних.

Автоматизація робочих процесів включає:

- створення макросів: створення макросів для автоматизації повторюваних задач, таких як імпорт даних, попередня обробка, запуск моделей і збереження результатів;
- налаштування сценаріїв: використання сценаріїв для автоматизації робочих процесів, включаючи автоматичне оновлення даних, повторне навчання моделей на нових даних та регулярне створення звітів;

- інтеграція з іншими системами: налаштування інтеграції з такими системами, як бази даних або системи управління проектами, для забезпечення безперебійного обміну даними та автоматизації процесів. Для автоматизації процесу моделювання у STATISTICA можна використовувати вбудовану мову програмування (SVB - STATISTICA Visual Basic).

Основні кроки включають:

- створення скриптів для завантаження і підготовки даних;
- налаштування параметрів моделей і запуск процесу навчання;
- візуалізація результатів (графіки, таблиці) (рис.2.16).

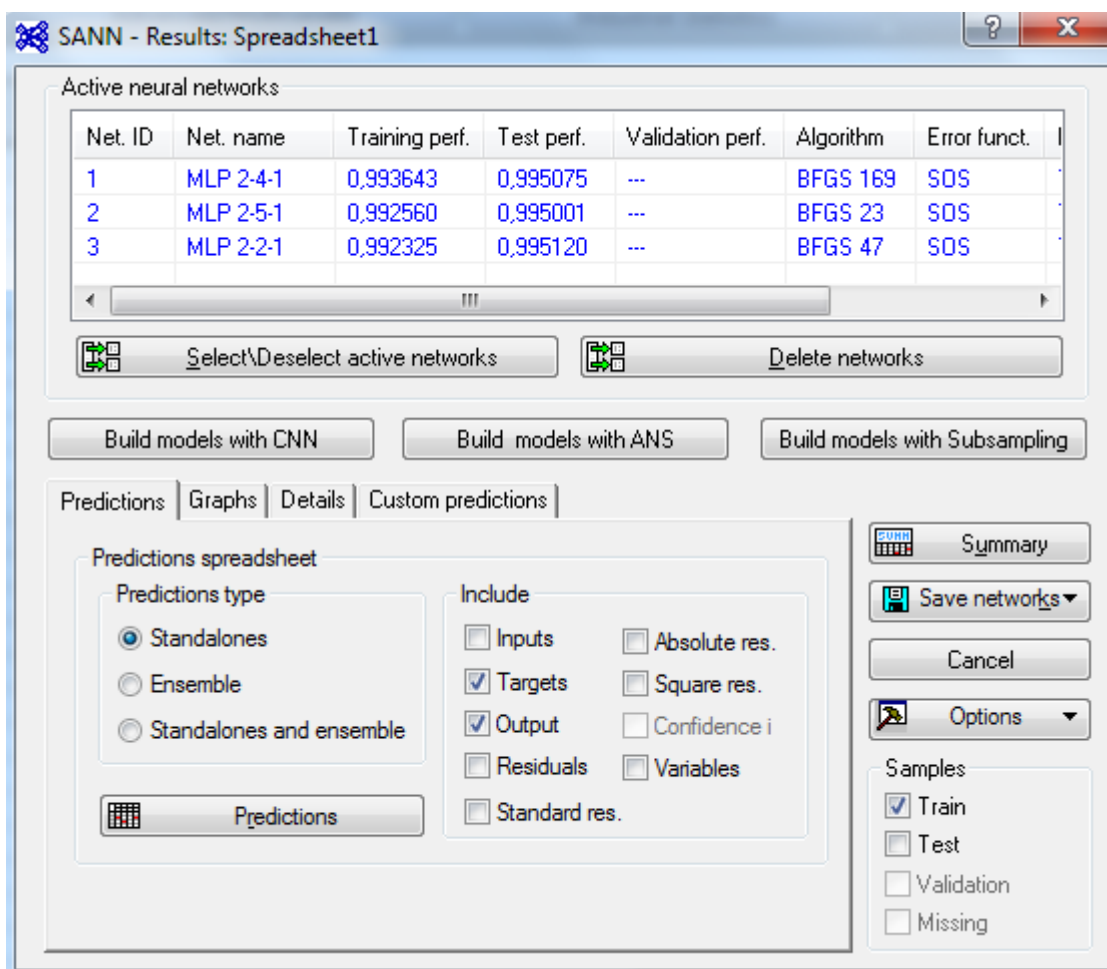


Рисунок 2.16 – Вікно побудованих моделей НМ

Розробка програмного забезпечення для моделювання у STATISTICA є комплексним процесом, що включає декілька етапів, кожен з яких є критичним для успішного виконання завдань МН. Використання потужних інструментів та модулів STATISTICA дозволяє ефективно здійснювати імпорт, обробку та аналіз даних, створювати та налаштовувати моделі, а також автоматизувати робочі процеси. Завдяки цьому забезпечується висока точність, надійність та ефективність моделей МН, що використовуються для аналізу та прогнозування.

## РОЗДІЛ 3. СПЕЦІАЛЬНА ЧАСТИНА

### 3.1 Аналіз результатів прогнозування діаграм деформування Al-6061

Експериментальні дослідження є надзвичайно складними і потребують значних фінансових витрат. Через ці труднощі числове моделювання за допомогою методів МН стає важливою альтернативою фізичним експериментам [5]. Основна мета цього дослідження полягає у прогнозуванні термічних властивостей композитних матеріалів алюмінієвого сплаву Al-6061. Для цього використовувалися різноманітні методи МН, що дозволило уникнути явного визначення аналітичних діаграм деформування та порівняти прогнозовані результати.


Моделювання термічних властивостей композитних матеріалів здійснювалося на основі експериментальних даних, представлених у статті [10]. Загальна вибірка складала 1500 елементів, з яких 80% було випадковим чином відібрано для навчання моделі, а решта 20% були використані для тестування, щоб оцінити якість прогнозування. Результати показали, що прогнозовані значення узгоджуються з експериментальними даними. Найточнішим методом виявилася НМ з похибкою прогнозування 7,2%. Для інших методів похибка становила: методу k-найближчих сусідів - 7,3%, опорно-векторних машин - 8,5%.

Варто зазначити, що точки на рис. 3.1 розташовані близько до бісектриси, проведеної з першого координатного кута, що свідчить про узгодженість між прогнозованими та експериментальними даними [11].


Для прогнозування термічних властивостей композитних матеріалів методом НМ була побудована багатошарова перцептронна мережа (MLP) з архітектурою 2-8-1, де використовувалися логарифмічні функції активації як у прихованому шарі, так і у вихідному шарі. Коефіцієнт кореляції для тестової вибірки становив 0,99, що підтверджує високу точність моделі.




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



а)




б)




в)


Рисунок 3.1 – Прогнозовані та експериментальні деформації одержані методом НМ (а), k-найближчих сусідів (б), опорно-векторних машин (в)



a)



б)

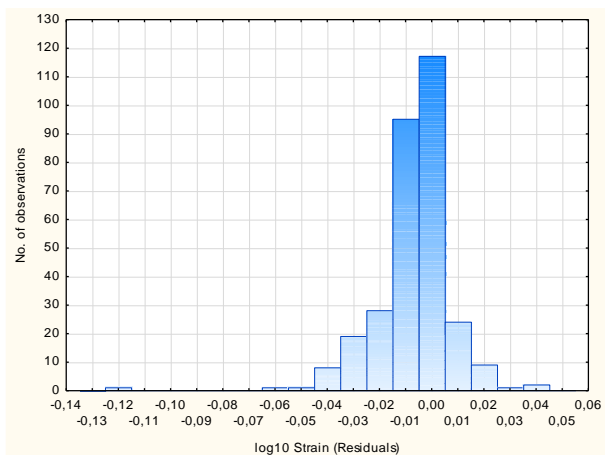


в)


Рисунок 3.2 – Прогнозовані та експериментальні деформації від напружень та температури отримані методом НМ (а),  $k$ -найближчих сусідів (б), опорно-векторних машин (в)

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


На рис. 3.3 показано діаграму залишкових значень, отримана за допомогою методу НМ,  $k$ -найближчих сусідів та опорно-векторних машин.



а)



б)



в)

Рисунок 3.3 – Діаграма залишкових значень, отримана за допомогою методу НМ (а), k-найближчих сусідів (б), опорно-векторних машин (в)

Загалом, розглянуто результати моделювання, а також порівняння з експериментальними даними. Виявлено, що метод НМ дає найбільшу точність прогнозування.

### 3.2 Порівняння результатів прогнозування з експериментальними даними

Аналіз результатів моделювання є критично важливим етапом для оцінки точності та ефективності побудованих моделей. У цій роботі використовувались різні методи МН, такі як НМ, метод k-найближчих сусідів та опорно-векторних машин для прогнозування термічних властивостей композитних матеріалів.

Для аналізу результатів прогнозування було зібрано декілька показників ефективності, включаючи середню абсолютну похибку (MAE), середню квадратичну похибку (MSE), коефіцієнт детермінації ( $R^2$ ) та кореляційний коефіцієнт між прогнозованими та реальними значеннями. Ці показники дозволяють оцінити, наскільки точно моделі можуть передбачати термічні властивості матеріалів.

Порівняння результатів для кожного методу МН показало, що НМ мають найвищу точність прогнозування, що свідчить про їх здатність враховувати складні нелінійні залежності між вхідними даними та вихідними показниками. Опорно-векторні машини також показали високі результати, особливо у випадках, коли дані мали високий ступінь лінійності. Метод k-найближчих сусідів продемонстрував задовільні результати, проте їх точність дещо поступалась нейронним мережам та SVM.

Верифікація та валідація моделей є ключовими етапами для забезпечення їх надійності та точності. Верифікація передбачає перевірку правильності алгоритмів та коду, що використовуються для побудови моделей. Це включає в себе тестування всіх модулів програмного забезпечення та перевірку результатів на контрольних наборах даних.

Валідація моделей проводилась на незалежних наборах даних, які не використовувались під час навчання. Було виділено 20% від загальної вибірки для тестування моделей, що дозволило оцінити їх здатність прогнозувати термічні властивості на нових даних. Результати валідації показали, що моделі мають високу точність та можуть бути використані для практичних завдань прогнозування.

Зокрема, оптимізація параметрів моделей є важливим етапом для підвищення їх ефективності та точності. Для кожного методу МН були визначені ключові параметри, які впливають на результати моделювання. Наприклад, для НМ це кількість шарів та нейронів у кожному шарі, функції активації та швидкість навчання.

Для перевірки точності та надійності моделей результати прогнозування були порівняні з експериментальними даними. Це дозволило оцінити, наскільки добре моделі можуть передбачати реальні термічні властивості композитних матеріалів. Порівняння проводилось за допомогою статистичних показників, таких як кореляційний коефіцієнт та коефіцієнт детермінації.

Результати показали, що моделі МН можуть з високою точністю передбачати термічні властивості композитних матеріалів. Найкращі результати були отримані для НМ, які показали високу узгодженість з експериментальними даними. Інші методи також показали задовільні результати, проте їх точність дещо поступалась НМ.

Впровадження результатів дослідження в практику є важливим кроком для підвищення ефективності виробничих процесів та якості кінцевих продуктів. Розроблені моделі можуть бути інтегровані у виробничі лінії для автоматичного прогнозування термічних властивостей композитних матеріалів. Це дозволить зменшити витрати на проведення експериментальних досліджень та підвищити точність контролю якості продукції.

Зокрема, результати дослідження можуть бути використані для розробки нових композитних матеріалів з покращеними термічними властивостями. Моделі можуть бути застосовані для оптимізації складу та технології виробництва композитів, що забезпечить їх високу надійність та довговічність.

Подальші дослідження у цій галузі можуть включати:

- розширення набору даних: збір більшої кількості експериментальних даних для навчання та тестування моделей. Це дозволить підвищити точність прогнозування та зробити моделі більш універсальними;
- використання інших методів МН: дослідження інших методів МН, таких як глибокі НМ, градієнтний бустинг та інші;
- оптимізація архітектури НМ: проведення досліджень з метою оптимізації архітектури НМ для подальшого підвищення їх точності та ефективності;

- інтеграція з виробничими процесами: розробка програмного забезпечення для інтеграції моделей МН з автоматизованими системами управління виробничими процесами;
- вивчення впливу зовнішніх факторів: дослідження впливу різних зовнішніх факторів, таких як вологість, тиск та інші, на термічні властивості композитних матеріалів.

Таким чином, подальші дослідження сприятимуть розвитку методів прогнозування термічних властивостей композитних матеріалів та їх впровадженню у промисловість, що забезпечить підвищення ефективності виробничих процесів та якості кінцевих продуктів.

## РОЗДІЛ 4. БЕЗПЕКА ЖИТТЄДІЯЛЬНОСТІ, ОСНОВИ ОХОРОНИ ПРАЦІ

### 4.1 Характеристика шкідливих факторів виробничого середовища

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

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

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



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

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

## 4.2 Забезпечення безпеки життєдіяльності при роботі з ПК

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

- фізичні;
- психофізіологічні.

Електробезпека при роботі.

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

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

Освітлення.

Система освітлення повинна відповідати таким вимогам:

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

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

Вимоги до монітору.

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

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

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

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

Фільтри з металевої або нейлонової сітки використовувати не рекомендується, тому що сітка спотворює зображення через інтерференцію світла. Найкращу якість зображення забезпечують скляні поляризаційні фільтри. Вони усувають практично усі відблиски, роблять зображення чітким і контрастним.

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

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

Робоча поза.

Зручна робоча поза при роботі з комп'ютером забезпечується регулюванням висоти робочого столу, крісла та підставки для ніг. Раціональною робочою позою може вважатися таке положення, при якому ступні працівника розташовані горизонтально на підлозі або підставці для ніш, 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

Під час виконання дипломної роботи було досліджено застосування методів штучного інтелекту для прогнозування термічних властивостей композитних матеріалів. Зокрема, основна увага приділялася прогнозуванню діаграм деформування за допомогою НМ, методу k-найближчих сусідів та опорно-векторних машин.

Обґрунтовано, що ці методи забезпечують високий рівень гнучкості та здатні адаптуватися до складних нелінійних залежностей у даних.

Найточнішим методом виявилася НМ з похибкою прогнозування 7,2%. Для інших методів похибка становила: методу k-найближчих сусідів - 7,3%, опорно-векторних машин - 8,5%. Отримані результати підтверджують ефективність застосування цих методів для вирішення задачі, забезпечуючи високу точність і надійність прогнозів.

Загалом, точне прогнозування термічних властивостей композитних матеріалів є критично важливим для багатьох галузей промисловості, включаючи авіабудування, машинобудування та інші високотехнологічні сфери.

Визначено, що використання методів ШІ дозволяє значно підвищити ефективність та точність прогнозування у порівнянні з традиційними методами.

Розроблені моделі та алгоритми можуть бути інтегровані у виробничі процеси для прогнозування термічних властивостей композитних матеріалів, що дозволить підвищити якість продукції та знизити витрати на експериментальні дослідження. Застосування ШІ в цій сфері забезпечує точність та надійність прогнозів, що є ключовими факторами для інноваційного розвитку промисловості.

Таким чином, результати даного дослідження демонструють високий потенціал застосування методів ШІ для прогнозування термічних властивостей композитних матеріалів, що може стати основою для подальших наукових розробок та практичного впровадження у промисловість.

## ПЕРЕЛІК ПОСИЛАНЬ

1. Ясній П.В. Пластично деформовані матеріали: втома і тріщиностійкість. Львів: Світ, 1998. 292 р.
2. Didych, I., Yasniy, O., Pasternak, I., & Sobashek, L. (2022). Modelling of AL-6061 aluminum alloy deformation diagrams by machine learning methods. *Procedia Structural Integrity*, 42, 1344-1349.
3. Yasniy, O., Pastukh, O., Didych, I., Yatsyshyn, V., & Chykhira, I. (2023). Application of machine learning for modeling of 6061-T651 aluminum alloy stress– strain diagram. *Procedia Structural Integrity*, 48, 183-189.
4. Alpayndin E. Introduction to Machine Learning // The Knowledge Engineering Review. 2010. Vol. 25, № 3. P. 353–353.
5. Haykin S. Neural Networks - A Comprehensive Foundation - Simon Haykin. McMaster University, Hamilton, Ontario, Canada, 2006. P. 823.
6. Wasserman Ph.D. Neural Computing: Theory and Practice. New York: Coriolis Group (Sd), 1989.
7. Mitchell T.M. Machine learning. London: McGraw-Hill Science/Engineering/Math, 1997.
8. Шаховська Н.Б., Камінський Р.М., Вовк О.Б. Системи штучного інтелекту: навч. посібник. Львів: Видавництво Львівської політехніки, 2018. 392 р.
9. Smola A., Vishwanathan S.V.N. Introduction to Machine Learning. Cambridge University Press, 2010.
10. Weaver, J. S., Khosravani, A., Castillo, A., Kalidindi, S.R., 2016. High throughput exploration of process-property linkages in Al-6061 using instrumented spherical microindentation and microstructurally graded samples, *Integrating Materials and Manufacturing Innovation* 5, 192–211.
11. Yasnii, O. P., Pastukh, O. A., Pyndus, Yu. I., Lutsyk, N. S., Didych, I. S., 2018. Prediction of the Diagrams of Fatigue Fracture of D16T Aluminum Alloy by the Methods of Machine Learning. *Materials Science* 54, 333–338.



