

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет комп'ютерної інженерії та управління  
(повна назва)

Кафедра Комп'ютерних інтелектуальних технологій та систем  
(повна назва)

**АТЕСТАЦІЙНА РОБОТА**  
**Пояснювальна записка**

Другий (магістерський) рівень  
(рівень вищої освіти)

Застосування штучних нейронних мереж  
для побудови інтелектуального класифікатора

(тема)

Виконав: студент II курсу, групи КІТм-19-1  
спеціальності (напряму підготовки) \_\_\_\_\_

123 – Комп'ютерна інженерія

(код і повна назва спеціальності, напряму)

освітньої програми \_\_\_\_\_

Комп'ютерні інтелектуальні технології

(повна назва освітньої програми)

Звонкова В.О.

(підпис)

(прізвище, ініціали)

Керівник: \_\_\_\_\_ проф. Корабльов М.М.

(підпис)

(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри КІТС

Руденко О.Г.

(підпис)

(прізвище, ініціали)

2020 р.

Харківський національний університет радіоелектроніки

Факультет \_\_\_\_\_ комп'ютерної інженерії та управління  
Кафедра \_\_\_\_\_ електронних обчислювальних машин  
Рівень вищої освіти \_\_\_\_\_ другий (магістерський)  
Спеціальність (напрямок) \_\_\_\_\_ 123 – Комп'ютерна інженерія  
(код і назва)  
Освітня програма \_\_\_\_\_ Комп'ютерні інтелектуальні технології  
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри \_\_\_\_\_  
(підпис)

“ \_\_\_\_\_ ” \_\_\_\_\_ 20\_\_ р.

**ЗАВДАННЯ**  
**НА АТЕСТАЦІЙНУ РОБОТУ**

студентові \_\_\_\_\_ Звонковій Владі Олексіївні  
(прізвище, ім'я, по батькові)

1. Тема роботи Застосування штучних нейронних мереж для побудови інтелектуального класифікатора

затверджена наказом по університету від “ 11 ” листопада 2020 р. № 1582 Ст

2. Термін подання студентом роботи до екзаменаційної комісії \_\_\_\_\_ 10 грудня 2020 р.

3. Вхідні дані до роботи \_\_\_\_\_

1) навчальна множина класифікатора

2) побудова інтелектуального класифікатора виконувати з використанням ШНМ

3) вхідні багатовимірні вектори з діагностичними властивостями резервуара

4) мова програмування – Matlab → Simulink

4. Перелік питань, що потрібно опрацювати в роботі 1) Огляд предметної області;

2) аналіз предмету дослідження;

3) дослідження методів класифікації інформації;

4) розробка інтелектуального класифікатора;

5) експериментальні дослідження;

6) аналіз якості класифікатора;

7) висновки.

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (слайдів) Демонстраційні матеріали. Плакати - 18 арк. ф. А4

---

---

---

---

---

---

---

---

---

---

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

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

### КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Огляд стану проблеми та постановка задачі	01.09-14.09	
2	Аналіз літератури за напрямком магістерської роботи	14.09-28.09	
3	Розробка інтелектуального класифікатору	28.09-12.10	
4	Експериментальні дослідження та аналіз якості класифікатора	12.10-02.11	
5	Оформлення пояснювальної записки	02.11-23.11	
6	Підготовка графічного матеріалу	23.11-07.12	

Дата видачі завдання 11 листопада 2020 р.

Студент \_\_\_\_\_  
(підпис)

Керівник роботи \_\_\_\_\_  
(підпис)

проф. Корабльов М.М.  
(посада, прізвище, ініціали)

## РЕФЕРАТ

Пояснювальна записка атестаційної роботи: 78 с., 28 рис., 12 табл., 2 дод., 18 джерел.

НЕЙРОН, ШТУЧНІ НЕЙРОННІ МЕРЕЖІ, ІНТЕЛЕКТУАЛЬНИЙ КЛАСИФІКАТОР, КЛАСИФІКАЦІЯ, ІМОВІРНІСНА НЕЙРОННА МЕРЕЖА.

Предметом дослідження є методи класифікації на основі використання нейронних мереж.

Метою магістерської атестаційної роботи є розробка інтелектуального класифікатора на основі нейронних мереж для аналізу даних та їх класифікації.

У ході виконання атестаційної роботи проводився аналіз методів класифікації. Проаналізовано архітектури та типи нейронних мереж. Розроблений класифікатор для діагностики стану об'єкта з використанням імовірнісної нейронної мережі та перевірений на вирішення поставлених цілей. Проведена оцінка ефективності класифікатора від параметру впливу, який характеризує розсіювання Гаусівського розподілу, та від кількості об'єктів навчальної множини. Представлені результати експериментальних досліджень.

## ABSTRACT

Explanatory note of attestation work: 78 pages, 28 figures, 12 tables, 2 appendix, 18 sources.

NEURON, ARTIFICIAL NEURAL NETWORKS, INTELLECTUAL CLASSIFIER, CLASSIFICATION, PROBABILITY NEURAL NETWORK.

The subject of research is the methods of classification based on the use of neural networks.

The purpose of the master's certification work is to develop an intelligent classifier based on neural networks for data analysis and classification.

During the performance of attestation work the analysis of classification methods was carried out. Architectures and types of neural networks are analyzed. A classifier has been developed to diagnose the state of an object using a probabilistic neural network and to verify the decision to enter prices. The efficiency of the classifier is evaluated according to the parameters of influence, which characterizes the scattering of the Gaussian distribution from other objects of the educational set. The results of experimental researches are presented.

## ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ .....	8
ВСТУП .....	9
1 АНАЛІЗ МЕТОДІВ КЛАСИФІКАЦІЇ .....	11
1.1 Визначення класифікації .....	11
1.2 Формальний опис класифікації .....	12
1.3 Методи класифікації .....	13
1.3.1 Лінійна регресія.....	13
1.3.2 Модель логістичної регресії- Байєсовська .....	14
1.3.3 Ранжування і чітка класифікація .....	15
1.4 Використання штучних нейронних мереж для класифікації .....	15
1.4.1 Формальний нейрон.....	16
1.4.2 Класифікатор на основі нейронної мережі.....	17
1.4.3 Глибоке навчання.....	17
1.5 Постановка задачі дослідження.....	18
2 ЗАСТОСУВАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПОБУДОВИ ІНТЕЛЕКТУАЛЬНОГО КЛАСИФІКАТОРА .....	20
2.1 Основні принципи нейромережевого підходу .....	20
2.2 Нейронна мережа як математична модель .....	24
2.3 Типи активаційних функцій.....	26
2.4 Архітектура нейронної мережі .....	28
2.5 Навчання нейронних мереж .....	31
2.6 Побудова нейронної мережі для класифікатора .....	32
2.6.1 Визначення архітектури інтелектуального класифікатора.....	32
2.7 Розпізнавання станів.....	37
2.7.1 Об'єкт діагностики.....	37
2.7.2 Навчальна множина класифікатора .....	39

2.7.3	Формування тестового набору.....	41
2.7.4	Процес ініціалізації інтелектуального класифікатора .....	42
3	ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ КЛАСИФІКАТОРА.....	47
3.1	Проведення дослідження класифікатора на розпізнавання стану об'єкта .....	47
3.2	Дослідження впливу параметра spread на якість розпізнавання образів.....	48
3.3	Дослідження якості класифікації в залежності від кількості навчальних векторів.....	54
	ВИСНОВКИ.....	62
	ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ .....	64
	ДОДАТОК А.....	66
	ДОДАТОК Б .....	75

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ  
І ТЕРМІНІВ

ML – машинне навчання – machine learning;

IR – інформаційний пошук – information retrieval;

ШНМ (НМ) – штучна нейронна мережа;

ШН – штучний нейрон;

КНМ – комутаторна НМ;

ІНМ – імовірнісна нейронна мережа;

PNN – імовірнісна мережа – Probabilistic Neural Network;

ППП – пакет прикладних програм;

VLSI – very-large-scale-integrated – схеми надвеликого рівня інтеграції ;

RBF – радіально-базисна функція – radial-basis function network;

FF – Feedforward – мережі прямого поширення сигналів;

LVQ – learning vector quantization – квантування навчального вектора.



## ВСТУП

Сьогодні існує певний клас актуальних завдань, вирішення яких без використання штучних нейронних мереж (ШНМ) неможливо або складно піддається реалізації. Для вирішення таких проблем людський інтелект малоефективний, а традиційні обчислення трудомісткі або фізично неадекватні, оскільки не відображають або погано відображають реальні фізичні процеси і об'єкти. Відповідно стає необхідним використовувати штучні нейронні мережі для вирішення класифікаційних задач.

Завдання класифікації – вказати належність вхідній вибірці, представленого вектором числових атрибутів, до одного або декількох визначених класам. Практичні застосування такого завдання включають розпізнавання тексту, розпізнавання мови, класифікацію сигналів електрокардіограми, класифікацію клітин крові, тощо.

Використання нейромережевих технологій відкриває якісно новий рівень вивчення процесів в такій невизначеній системі, як організм людини. Відмінною особливістю нейронних мереж є те, що вони не запрограмовані - вони не використовують ніяких правил виведення для постановки діагнозу, але вони вчаться робити це на прикладах. Діагностика - це окремий випадок класифікатора подій та основна категорія подій, які не включені до набору навчальних даних. Це відображає перевагу нейромережевих технологій: вони можуть виконувати таку класифікацію, узагальнювати попередній досвід і застосовувати його в нових випадках .

Нейронні мережі здатні вирішувати традиційні математичні задачі з недоступною обробкою, порівняння, класифікації образів; здатністю до самонавчання та самоорганізації. Вони забезпечують діагностику, ідентифікацію та класифікацію складних об'єктів з чіткими, складними нелінійними технічними умовами.

Застосування технології класифікації за допомогою нейронних мереж

дозволяє певною мірою усунути математичні проблеми аналізу властивостей системи. У цьому випадку якість ідентичності буде залежати більше від характеристик нейронної мережі, ніж від аналітичних правил обчислювальних рішень, які часто використовуються комп'ютерними програмами.

Мета роботи: розробка інтелектуального класифікатора на основі нейронних мереж для аналізу даних та її класифікації. Предметом дослідження є методи класифікації на основі використання нейронних мереж. Пояснювальна записка складається з 3 розділів. У першому розділі досліджуються існуючі методи класифікації. У другому розділі розглянуто застосування нейронних мереж для побудови інтелектуального класифікатора. Третій розділ описує експериментальні дослідження класифікатора.

# 1 АНАЛІЗ МЕТОДІВ КЛАСИФІКАЦІЇ

## 1.1 Визначення класифікації

Використовуються два прийоми для групування об'єктів (документів) або їх функцій – класифікація і кластеризація.

Класифікація та кластеризація - це два протилежні аспекти участі користувачів у процесі групування. Використовуючи можливість автоматичного групування пов'язаних документів автоматично за темами, ви можете створювати папки за темами. Процес класифікації зазвичай встановлюється лише на вибраних документах після автоматичного виявлення згрупованих даних (кластера).

Класифікація використовує статистичні зв'язки для розробки правил, які класифікують об'єкти за певними категоріями. Класифікація - це поділ об'єктів на заздалегідь визначені категорії (на відміну від групування, де багато категорій заздалегідь не відомі).

Методи класифікації тексту:

- ML (машинне навчання);
- пошук інформації (information retrieval, IR).

Отже, можна здійснити автоматичну класифікацію: на основі заздалегідь визначеної форми класифікації та набору існуючих класифікаційних документів.

Визначення приналежності до предмета з одним або кількома класами є задачею класифікації. Зокрема, класифікація тексту може визначатися загальною темою, наявністю певних дескрипторів або виконанням певних умов, часом досить складних.

Для кожного класу фахівці підбирають ряд типових об'єктів (документів), які система класифікації використовує в режимі навчання. Після закінчення курсу система зможе розподілити потік інформації про вхідні

документи за класами за допомогою спеціальних алгоритмів.

Класифікацію можна розглядати як завдання розпізнавання зразків. У цьому підході набори функцій різні для кожного об'єкта. Що стосується текстів, символи - це взаємозалежні слова та набори слів - терміни, що містяться в тексті. Статистичні та лінгвістичні методи використовуються для формування набору властивостей кожного документа. Властивості згруповані в спеціальній таблиці - інформаційній матриці. Кожному рядку в інформаційній матриці відповідає один із класів, кожному елементу рядка - одна з функцій; Чисельне значення цього елемента визначається під час вивчення системи класифікації. Після закінчення навчання приналежність нового тексту до одного з класів визначається шляхом аналізу властивостей тексту з урахуванням відносних значень ваги.

Зокрема, автоматичні класифікації можуть бути використані в процедурах пошуку інформації, таких як:

- фільтрування (вибирати) інформації;
- формування категорій тем;
- пошук по класах;
- застосування відповідних зворотних зв'язків шляхом класифікації результатів пошуку та вибору користувачами відповідних класів;
- розширити запити за рахунок термів, характерних для тематики класу;
- автоматичне реферування.

## 1.2 Формальний опис класифікації

Нехай  $D = \{d_1, \dots, d_{|D|}\}$  - множина об'єктів (вузлів мережі або, наприклад, документів),  $C = \{c_1, \dots, c_{|C|}\}$  - множина категорій,  $\Phi$  - цільова функція, яка по парі  $\langle d_i, c_i \rangle$  визначає, чи відноситься документ  $d_i$  до категорії  $c_i$  (1 або *True*) або ні (0 або *False*). Задача класифікації полягає в побудові функції  $\Phi'$ , максимально близької до  $\Phi$ .

- Методи машинного навчання, що використовуються для класифікації, складаються з набору об'єктів, раніше класифікованих експертами, тобто об'єктів, які знають значення цільової функції. Для оцінки ефективності після сортування ця колекція розділена на дві частини (навчальна та тестова).

Цю класифікацію називають чіткою бінарною, тобто передбачається, що лише дві категорії не мають спільних точок. Багато проблем зводяться до таких класифікацій, наприклад класифікації за набором категорій  $C = \{c_1, \dots, c_{|C|}\}$  розбивається на  $|C|$  бінарних класифікацій по множинам  $\{c_i, \bar{c}_i\}$ .

Ранжування здебільшого використовується там, де набором значень цільової функції є сегмент  $[0, 1]$ .

### 1.3 Методи класифікації

#### 1.3.1 Лінійна регресія

Регресійний метод - це варіант лінійної класифікації, який висвітлюється відразу в колекції. Коли для класифікації тексту використовується регресійний аналіз, розглядається набір термів ( $F$ ) та набір категорій ( $C$ ). У цьому випадку набір навчальних матеріалів відповідає двом матрицям:

- матриця документів  $D$  у навчальній колекції, де кожен рядок – це документ, а стовпець – терм, кількість рядків  $N$  – кількість документів в навчальній колекції;

- матриця відповідей  $O = \|O_{i,j}\|$ , в якій рядок  $i$  відповідає документу  $i = 1, \dots, N$ , стовпець  $j$  – категорії ( $j = 1, \dots, K$ ), а  $O_{i,j}$  значення  $CSV_j(d_i)$ .

Метод регресії базується на алгоритмі знаходження матриці правил  $M$ , яка мінімізує значення норми матриці  $\|MD - O\|_F$ , тобто:

$$M = \arg_M \min \|MD - O\|_F. \quad (1.1)$$

Стандарт матриці інтерпретується як функція, що відповідає числовій властивості матриці. Стандарт матриці відображає порядок величини елементів. У цьому випадку слід використовувати норму Фробеніуса  $\| \cdot \|_F$ , яка дорівнює квадратному кореню з суми квадратів усіх елементів у відповідній матриці:

$$\|A\|_F = \sqrt{\sum_{i,j} a_{ij}^2}. \quad (1.2)$$

Елемент  $m_{ij}$  початкової матриці  $M$  буде відображати ступінь належності  $i$ -го терму  $j$ -й категорії.

### 1.3.2 Модель логістичної регресії- Байєсовська

Баєсова модель логістичної регресії враховує умовну ймовірність належності до документа  $D$  класу  $C$ :  $p(C|D)$ .

Припустимо, що документ є вектором,  $D = (w_i, \dots, w_N)$ , де  $w_i$  – вага терма  $i$ , а  $N$  – розмір словника.

Модель байєсовської логістичної регресії задається формулою:

$$p(C|D) = \varphi(\beta \cdot D) = \varphi\left(\sum_{i=1}^N \beta_i \cdot w_i\right) \quad (1.3)$$

де  $C \in \{0,1\}$ ,  $\beta = \{\beta_i, \dots, \beta_N\}$  – вектор параметрів моделі, а  $\varphi$  – логістична функція, в якості якої можна використовувати, наприклад:

$$\varphi(x) = \frac{1}{1+\exp(-x)} \quad (1.4)$$

Головною ідеєю цього підходу є використання попереднього розподілу векторів  $\beta$ , де кожне значення  $\beta_i$ , ймовірно, матиме приблизно рівні значення. У практичних розрахунках приймаються припущення про розподіл значень

Гауса чи Лапласа, а також той факт, що всі величини взаємозалежні.

### 1.3.3 Ранжування і чітка класифікація

Припустимо, що для кожної категорії  $c_i$  функція оцінки (статус належить цій категорії)  $CSV_i$ . Найпростіший спосіб - вибрати поріг для кожної категорії  $c_i$ .

Якщо  $CSV_i(d) > \tau_i$ , то документ  $d$  відповідає категорії  $c_i$ . Інший підхід: для кожного документа  $d$  обрати  $k$  найближчих категорій, тобто  $k$  категорій, на яких  $CSV_i(d)$  приймає максимальні значення.

Обрати поріг можна кількома способами:

- пропорційний метод. Навчальна колекція розділена на дві частини. Для кожної категорії  $c_i$  частина навчальної колекції обчислює, яка частина матеріалу їй належить. Граничні значення підібрані таким чином, щоб інша частина навчальної колекції містила стільки ж іншого матеріалу як  $c_i$ ;

- метод  $k$  найближчих категорій. Кожен документ  $d_i$  вважається таким, що належить до  $k$  категорій, до нього відбувається вибір порогового значення.

## 1.4 Використання штучних нейронних мереж для класифікації

Штучна нейронна мережа - це структура даних, що імітує процеси, які зазвичай відбуваються в мозку людини.

В даний час нейронні мережі вирішують проблеми класифікації, групування, розпізнавання образів, наближення функцій, прогнозування тощо.

Єдиною нейронною моделлю можна вважати комп'ютер; насправді потенціал нейрона (аксона) є функцією дендритного потенціалу. Стан нервової клітини визначається розміром цього потенціалу.

### 1.4.1 Формальний нейрон

Розглянемо формальну модель нейрона (рис. 1.1). Вхідні сигнали через синапси та дендрити надходять у нейрон, а їх значення множаться на вагу, що відповідає певним синапсам (можуть змінюватися під час навчання), результати збираються. На основі коефіцієнта посилення NET, для якого використовується функція (активаційна), формується вихідний сигнал нейрона OUT.

Сигнал суматора визначається за формулою:

$$NET = \sum_{i=1}^n x_i w_i \quad (1.5)$$

де  $n$  – кількість синапсів;

$x_i$  – вхідний сигнал  $i$ -го дендриту;

$w_i$  – вагові показники,  $NET$  – сигнал суматора.




Рисунок 1.1 – Формальний нейрон

Сигнал на виході нейрона має наступний вигляд:  $OUT = F(NET)$ .

Найчастіше застосовуються такі активаційні функції:

$$OUT = \begin{cases} 1, & NET > T, \\ -1, & NET \leq T; \end{cases}$$



$$OUT = \frac{1}{1+e^{-NET}};$$

$$OUT = th(NET). \quad (1.6)$$

#### 1.4.2 Класифікатор на основі нейронної мережі

Класифікатором може бути нейронна мережа, вхідні дані відповідають термам, а виходи категоріям. Для класифікації документів зважені значення термів  $w_k^{(j)}$  включаються у відповідні входи мережі; Активація розподіляється по мережі, і значення, отримані на виході, є результатом класифікації. Зворотне поширення помилки є типовим методом такого навчання. Якщо один із навчальних матеріалів отримує неправильну відповідь на одному з виходів, помилка передається назад через мережу, а значення ваг країв коригуються для зменшення цієї помилки.

#### 1.4.3 Глибоке навчання

Глибоке навчання являє собою сукупність методів машинного навчання, які засновані на навчанні, а не на спеціалізованих алгоритмах, розроблених для конкретних завдань. У минулому столітті було відомо багато методів глибокого навчання, але результати не були приголомшливими, поки досягнення теорії нейронних мереж та обчислювальної потужності не дали змоги створювати архітектури. Штучна нейронна мережа досить ефективна і може вирішити багато проблем ефективніше ніж раніше.

Дослідження в цій галузі покращили моделі роботи з великими обсягами немаркованих даних. Ряд підходів з'явився завдяки досягненням неврології, досягненню інтерпретації обробки інформації та побудові комунікаційних моделей у нервовій системі, таких як нейронне кодування, для визначення взаємозв'язку між подразниками та нервовими реакціями та взаємозв'язку між електричною активністю в клітинах мозку.

Поглиблене навчання представлено як клас алгоритмів машинного навчання:

- використовує багат шарову систему з нелінійними фільтрами для вилучення властивостей з перетвореннями. Кожен наступний рівень отримує дані попереднього класу. Системи глибокого навчання можуть поєднувати алгоритми навчання з учителем і без нього, аналізуючи таким чином шаблон, який представляє навчання без вчителя, а класифікація - навчання з учителем;
- існує певна міра символіки або ідентифікації параметрів подання даних (навчання без вчителя). У цьому випадку символи організовані відповідно до ієрархії, старші символи походять від символів нижчого рівня;
- це частина ширшої галузі машинного навчання.

### 1.5 Постановка задачі дослідження

Метою магістерської роботи є розробка інтелектуального класифікатора на основі нейронних мереж для аналізу даних та їх класифікації.

Для досягнення мети дослідження необхідно вирішити наступні завдання:

- провести аналіз методів класифікації інформації;
- розглянути типи НМ;
- проаналізувати архітектури нейронних мереж;
- розробити класифікатор для діагностики стану об'єкта з використанням імовірнісної нейронної мережі;
- протестувати сформований класифікатор для ідентифікації стану об'єктів за допомогою тестерів;
- оцінити ефективність класифікації, використовуючи характерні параметри ефекту Гаусівського розподілу та кількості об'єктів у навчальному наборі;
- оцінити ефективність розпізнавання та визначити залежність критеріїв точності класифікації від параметрів впливу НМ та кількості

навчальних наборів.

Розв'язання цих завдань дозволить створити інтелектуальний класифікатор на основі нейронних мереж, який можна використовувати для рішення різних практичних задач.

## 2 ЗАСТОСУВАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПОБУДОВИ ІНТЕЛЕКТУАЛЬНОГО КЛАСИФІКАТОРА

### 2.1 Основні принципи нейромережевого підходу

Наявність значного обсягу інформації, часто нелінійної, а також вимоги щодо забезпечення високої ймовірності визначення пошкоджень та виявлення високого рівня сучасних технічних умов диктують побудову класифікатора на основі штучних нейронних мереж. Завдяки можливості виконувати традиційні (інтегрально-диференціальні) операції, недоступні для обробки, порівняння, класифікації зображень, самонавчання та самоорганізації, цей підхід може створити нову потужну інтелектуальну багат шарову діагностичну систему, яка відповідає принципам та вимогам SHM.

Концепція штучних нейронних мереж (ШНМ) виникла в процесі вивчення процесів, що відбуваються в мозку, і в спробах моделювати ці процеси. Цю першу спробу зробив НМ Мак-Калока та Піттса у 1943 р. Після розробки математичних алгоритмів отримані моделі почали використовувати в практичних цілях: для прогнозування проблем, ідентифікація шаблону, контрольні завдання, задачах керування тощо.

Дослідники надають такі визначення ШНМ:

- математичні моделі, як і реалізація програмного чи апаратного забезпечення, базуються на організації та функціях біологічної нейронної мережі - мережі нервових клітин у живому організмі;
- насправді це паралельний процесор, здатний зберігати та відтворювати експериментальні знання [11];
- динамічна система складається з набору вузлів, які з'єднані між собою діаграмою напрямків первинних процесорів, званих формальними нейронами, і які можуть дати результат у відповідь на ефект голови.

Штучні НМ - це система взаємопов'язаних та взаємодіючих факторів

(штучні нейрони). Такі фактори, як правило, досить прості. Кожен нейрон у такій мережі функціонує лише із сигналами. Однак, підключившись до досить великої мережі керованої взаємодії, такі прості локальні елементи разом можуть виконувати досить складні завдання.

Нейронні мережі не запрограмовані у звичному розумінні цього слова, вони вчаться. Вміння вчитися - одна з головних переваг НМ перед традиційними алгоритмами. Технічно тренінг полягає у пошуку коефіцієнтів зв'язків між нейронами. Під час навчального процесу дослідник здатний виявляти складні взаємозв'язки між вхідними даними і результатами, а також робити узагальнення.

З точки зору машинного навчання, НМ - це окремий випадок методів розпізнавання зображень, диференціального аналізу, методів групування та класифікації тощо. Коли мова йде про розвиток комп'ютерних технологій та програмування, НМ є ефективним способом вирішення паралельних проблем. І з точки зору штучного інтелекту, ШНМ є сучасною філософською основою теорії комунікацій і є основним напрямком структурного підходу до вивчення можливості побудови штучного інтелекту.

НМ мають два важливі аспекти:

- під час навчання отримуються мережеві знання;
- синаптичні ваги використовуються для зберігання знань.

Перцептрон - перша електронна модель штучної нейронної мережі. Основну ідею та теорію було викладено в наукових роботах нейрофізіологів Ф. Розенблата та М. Мінського.

Аналіз зарубіжних опитувань для ШНМ та нейронних комп'ютерів дає можливість визначити сучасні напрями розвитку нейронних мереж та нейронних комп'ютерних технологій:

- створення нейронного пакету для виявлення проблем з технічним аналізом;
- розробка спеціалізованих систем для нейронних мереж, включаючи класифікатори НМ;

- використання алгоритмів нейронної мережі в системі управління базами даних;
- обробка зображень та сигналів на основі технологій НМ;
- розроблення НМ алгоритми управління динамічними системами;
- виготовлення нейрооптичних комп'ютерів;
- побудова системи віртуальної реальності за допомогою методу НМ.

Основні функції ШНМ включають [12]:

- функція апроксимації, дуже важлива для вирішення проблем з розпізнаванням, моделюванням та обробкою сигналів;
- класифікація та розпізнавання зображень для вирішення проблем зі станом діагностичного об'єкта;
- функція прогнозування, що використовується для оцінки майбутньої поведінки системи відповідно до існуючої послідовності попереднього стану;
- функція ідентифікації та оцінювання, яка актуальна для вирішення проблем з динамічним управлінням процесами;
- функція асоціативного керування, яка використовується для відновлення інформації за неповними або зашумленими даними.

Використання НМ у системах моніторингу та діагностики є результатом таких характеристик [13]:

- нелінійність. Нейрони можуть бути лінійними та нелінійними, залежно від функції активації. НМ, яка побудована на зв'язках з нелінійними нейронами, є нелінійним. Крім того, ця нелінійність є однією з найважливіших, оскільки вона розподіляється по мережі і повністю або частково знімає обмеження класичних математичних методів;
- навчання буває параметричним («з вчителем») або непараметричним («без вчителя»). Це означає, що коефіцієнти синапсу змінюються залежно від наборів прикладів (навчених зразків) або "нетренованих" без заздалегідь визначених входів. Тому НМ навчається на прикладах і неявно формує відповідну таблицю вводу-виводу для вирішення проблеми;
- адаптивність (adaptivity). Нейронні мережі, здатні пристосувати

(адаптувати) розмір своїх синапсів до змін у навколишньому середовищі, тобто НМ, навчені вирішувати певні типи проблем, можуть перекваліфікуватися в роботу з іншими типами завдань. Щоб повною мірою скористатися переходом, параметри мають бути досить гнучкими, щоб реагувати на значні зміни в навколишньому середовищі. Цю проблему часто називають проблемою стабільності-пластичності (stability-plasticity dilemma);

- очевидність відповіді (evidential response). В контексті проблем класифікації зображень може бути розроблений метод, який збирає інформацію не тільки для ідентифікації певного класу, але й для підвищення надійності рішення. У майбутньому ця інформація може бути використана для виключення сумнівних рішень;

- контекстна інформація (contextual information). Знання структури НМ представлено станом активації. Усі інші нейрони можуть впливати на кожен нейрон мережі. Як результат, існування НМ пов'язане з контекстною інформацією;

- відмовостійкість (fault tolerance). За несприятливих умов незначні структурні несправності ніколи не спричиняють катастрофічних наслідків для роботи НМ, тобто продуктивність мережі, ймовірно, буде повільно знижуватися. Звичайно, якщо елемент мережі (нейрон або його зв'язок) вийде з ладу, буде важко отримати інформацію. Враховуючи той факт, що зберігання та передача інформації в НМ розподіляється по всіх нейронах, можна стверджувати, що лише значні пошкодження структури призведуть до виходу з ладу. Щоб забезпечити прийняття помилок НМ, алгоритм навчання повинен бути відповідно змінений;

- масштабування (VLSI Implementability). Паралельна структура НМ прискорює деякі проблеми та забезпечує масштабованість НМ у широкомасштабній інтегрованій технології VLSI. Перевагою технології VLSI є її здатність представляти досить складну архітектурну поведінку через ієрархію;

- однорідність аналізу. Штучний НМ - це універсальний механізм

обробки інформації. Модель НМ для вирішення цієї проблеми може бути використана в різних дисциплінах як стандартна основа для будь-якої нейронної мережі.

Коли ми розробляємо діагностичні алгоритми та розробляємо інтелектуальні діагностичні системи, засновані на ШНМ або їх підсистемах, низка проблем залишається невирішеною, включаючи такі [14]:

- відсутність методів вибору типу ANN, правильного типу завдання, що вирішується;
- недостатня підтримка вибору методів оптимізації в процесі навчання ШНМ, що призводить до значних помилок у прогнозах і термінах;
- висока агрегаційна складність проблем, пов'язаних з автоматичним формуванням топології ШНМ, у багатьох випадках не дозволяє створювати інтелектуальні інформаційні технології на основі ШНМ зі складністю щонайменше.

Тому використання НМ у сучасних інтелектуальних системах моніторингу та діагностики є дуже перспективним, оскільки вони мають високий поріг перешкод даних, низький рівень помилок і знаходяться в процесі постійного та оптимального вдосконалення. Різні алгоритми вивчення та спрощення структур. Крім того, однією з головних переваг нейронних мереж є те, що вони теоретично здатні наблизитися до будь-якої безперервної нелінійної функції, що дозволяє дослідникам заздалегідь відкинути всі гіпотези. з комплексного математичного моделювання операційного процесу процесу функціонування.

## 2.2 Нейронна мережа як математична модель

Штучний нейрон є окремим елементом в обробці інформації ANN або найважливішим функціональним цілим, з якого виникає ANN.

У загальній моделі ШН представлена на блок-схемі (рис. 2.1) можемо розрізнити три основні компоненти: синаптичний зв'язок, суматор та функцію



активації.

Синаптичні зв'язки характеризуються своїми ваговими коефіцієнтами  $w_{ik}$ . Зокрема, сигнал  $x_i$  на вході синапси  $i$ , що зв'язаний з нейроном  $k$ , помножується на вагу  $w_{ik}$ . Варто звернути увагу на порядок індексів вагового коефіцієнта: перший показник відповідає нейрону, а другий показник - вхідний синапс, пов'язаний з цією вагою. Ваговий коефіцієнт може мати додатні і від'ємні значення.




Рисунок 2.1 – Логічна структура та послідовність передачі сигналу в штучному нейроні

Функція активації  $f(S)$  обмежує амплітуду вихідного сигналу нейрона. Як правило, нормований діапазон амплітуд вихідного нейрона становить приблизно  $[0; 1]$  чи  $[-1; 1]$ .

Ця модель нейрона (рис. 2.1) показує пороговий зсув  $w_0$ . В деяких джерелах він позначається  $b$ . Ця величина відображає збільшення або зменшення вхідного сигналу, що подається на функцію активації.

Сигнали  $x_i$  ( $i = 1 \dots R$ ) поступають на вхід кожного нейрона та підсумовуються. Кожен з сигналів може бути виходом іншого нейрона і сигналом з сенсора.

$$S = \sum_{i=1}^n w_i \cdot x_i + w_0 \quad (2.1)$$

де  $w_0$  – пороговий зсув,  $w_i$  – вагові коефіцієнти (синаптичні ваги).

Відповідно до обраної активаційної функції  $y = f(S)$ , отриманий сигнал  $S$  перетворюється у вихідний сигнал нейрона.

### 2.3 Типи активаційних функцій

Функції активації  $f(S)$  визначають вихідний сигнал нейрона. Існує 3 основних типи активаційних функцій. Більш повна класифікація представлена на рисунку 2.2.




Рисунок 2.2 – Функції активації: а) одиничного стрибку; б) кусково-лінійна; в) сигмоїдальна (сигмовидна); г) радіально-симетрична

Основні типи функцій активації:

1. Порогова функція (рис. 2.2, а). Вона описується як:

$$f(S) = \begin{cases} 1, & \text{якщо } S \geq 0 \\ 0, & \text{якщо } S < 0 \end{cases} \quad (2.2)$$

Цю схему часто називають функцією Хевісайда. У цій моделі сигнал, що виходить стає 1, якщо лінійна комбінація  $S$  не є від'ємною, в інших випадках 0. Цей термін описує атрибут "все або нічого" першої запропонованої моделі Маккалоха-Піттса.

2. Кусково-лінійна функція (рис. 2.2, б). Вона описується наступним виразом:

$$f(S) = \begin{cases} a, & \text{якщо } S > a \\ S, & \text{якщо } -a \leq S \leq a \\ -a, & \text{якщо } S < -a \end{cases} \quad (2.3)$$

де  $a$  – порогове значення, зазвичай 1.

Вихідний сигнал нейрону має такі значення:

- $a$ , якщо лінійна комбінація  $S$  більша за порогове значення  $a$ ;
- $-a$ , якщо лінійна комбінація  $S$  менша за порогове значення  $-a$ ;
- $S$  в діапазоні значень  $[-a; a]$ .

Два особливі випадки кусково-лінійної функції:

- якщо лінійний діапазон пов'язаних значень не досягає порогу насичення, нейрон перетворюється на лінійний суматор;
- припускаючи, що коефіцієнт підсилення лінійної області нескінченно великий, така функція стає пороговою. Тому можна вважати, що функція одиничного стрибку – це частковий випадок кусколінійної функції.

3. Сигмоїдальна функція активації (рис. 2.2, в) є найпоширенішою функцією, яка використовується для створення ШНМ. Функція описується виразом:

$$f(S) = \frac{1}{1+e^{-aS}} \quad (2.4)$$

де  $\alpha$  – параметр нахилу сигмовидної функції. Змінюючи цей параметр можна побудувати функції різної крутизни.

Якщо взяти  $\alpha$  нескінченно велике значення, сигмоїдна функція стає пороговою.

Форма гіперболічного тангенсу, яку використовують як кусково-лінійну функцію:

$$f(S) = \tanh\left(\frac{S}{\alpha}\right) = \frac{e^S - e^{-S}}{e^S + e^{-S}} \quad (2.5)$$

Допустимий діапазон при гіперболічному тангенсі від  $-1$  до  $1$ .

Необхідною умовою для деяких математичних алгоритмів є диференціювання сигмоїдальна функція активації вздовж осі абсцис. Вона має здатність підсилювати слабкі сигнали та запобігати перенасиченню великих сигналів.

4. На рисунку 2.2 представлена радіально-симетрична функція активації – це функція Гаусівського розподілу.

$$f(S) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot e^{-\frac{(S-\langle S \rangle)^2}{2\sigma^2}} \quad (2.6)$$

де  $\sigma^2$  – радіуси базисних функцій - стандартне відхилення.

Цю функцію активації займають нейрони в прихованому шарі нейромережі радіально-базисних функцій (radial-basis function network – RBF). Крутість розподілу визначається за допомогою величини.

Якщо значення радіуса велике, графік функції занадто різкий, до невеликої міри. Ця властивість суттєво впливає на інтерполяцію лінійної комбінації нейронів.

#### 2.4 Архітектура нейронної мережі

В цілому НМ класифікується за наявністю або відсутністю зворотного зв'язку. Існують мережі прямого поширення сигналів без зворотних зв'язків FF та рекурентні мережі або мережі зі зворотними зв'язками.

Приклади мереж прямого поширення сигналів і мереж зі зворотними зв'язками наведені на рисунку 2.3.

Існує три типи нейронних мереж:

- одношаровий персептрон;

- багатошаровий персептрон;
- мережі радіально-базисних функцій.

Мережі прямих сигналів - це статичні мережі, тобто вони утворюють набір виходів на даному вході, незалежно від попереднього стану мережі.



Рисунок 2.3 – Види архітектур НМ

Чотири класи найбільш поширених та важливих багатошарових нейронних мереж [18]:

- мережі прямого розповсюдження – всі зв'язки ретельно спрямовуються від вхідних до вихідних нейронів. Такі мережі також відомі як багатошарові перцептрони;

- рекурентна НМ або мережі зворотного поширення – сигнали в цих мережах від вихідних нейронів або нейронів частково прихованого шару передаються назад на вхід нейронів вхідного шару;

- радіально базисна функція. Мережа досить компактна і швидко навчається. Вона має такі властивості: прихований шар; лише нейрони в прихованому шарі мають нелінійну функцію активації; синаптичні ваги вхідного шару та прихованого шару дорівнюють одиниці;

- карти, що самостійно організуються або мережа Кохонена [19]. Ці багатошарові класи НМ часто навчаються без учителя та успішно використовуються в завданнях ідентифікації. Якщо мережа зустрине набір

даних, всупереч будь-якій відомій схемі, вона не зможе класифікувати цей набір. Мережа Кохонена має лише два шари: вхідний і вихідний, що складаються з радіальних елементів.

Основним критерієм вибору оптимальної архітектури мережі є узагальнення. Навчальна мережа в підмножині навчальної моделі дає очікуваний результат, коли надсилає вхідні дані, що відносяться до того ж набору, але не беруть безпосередньої участі в процесі навчання. Вибір оптимальної структури решітки полягає у зменшенні кількості прихованих нейронів та зв'язків між нейронами, тобто зменшенні решітки різними методами (з урахуванням чутливості, використання функції штрафу тощо) або збільшенні мережі.

Найбільш поширеною архітектурою FF-мереж є багатошаровий перцептрон. Як правило, багатошаровий перцептрон складається з вхідного, вихідного та одного або декількох прихованих шарів, де нервові клітини мають поріг або функцію, яка запускає сигмоподібну систему.

Мережі радіально-базисних функцій – RBF-мережі є прикладом FF-мереж. Перевагою цієї моделі є швидка збіжність алгоритмів навчання, реалізованих із використанням спеціальної архітектури в цих мережах, і використання першої функції активації Гауса або типу розподілу в нейронах прихованого шару.

Суть мережі адаптивної резонансної теорії, яка вирішує проблему пластичної стійкості, полягає в поєднанні нового розпізнавання зображень (шари, які раніше не бачили) та стабільного розпізнавання шаблонів (шари знайдені). Насправді мережа ART ефективно використовується для вирішення задач автоматичної класифікації [15].

Іншим прикладом мережі зі зворотними зв'язками мережі є мережа Хопфілда, широко використовується для розпізнавання спотворених зображень та вирішення проблем з оптимізацією. Коли використовується ШНМ, алгоритм (архітектура мережі) безпосередньо коригується для вирішення проблеми.

## 2.5 Навчання нейронних мереж

При роботі з мережею існує два принципово різні способи - навчання та робота.

Найголовніше в НМ - це здатність вчитися на основі вихідних даних та покращувати їхню продуктивність під час навчання. Останнє відбувається з часом за певними правилами. Навчання НМ є результатом інтерактивного процесу з регулюванням ваги та синапсу.

Навчання НМ - це процес, коли параметри нейронних мереж є вільними налаштовано шляхом імітації середовища, в якому вбудована мережа. Тип навчання визначається шляхом коригування цих параметрів.

Відомі три парадигми навчання ШНМ: «навчання з вчителем», «навчання без вчителя» та змішане навчання.

У режимі самостійного навчання відсутня послідовність тренувань. У цьому випадку досліджується внутрішня структура даних або співвідношення між зображеннями, що дозволяє розділити зображення на шари або кластери.

Найвідомішим сучасним алгоритмом є алгоритм зворотного поширення помилки. Основна ідея полягає в тому, що зміна тяжкості синапсу відбувається з огляду на місцевий нахил несправності.

Весь попередній досвід накопичується в великому сховищі правильно класифікованих прикладів у вигляді «вхід-вихід»:

$$\{(x_i, d_i)\}_{i=1}^N \quad (2.7)$$

де  $x_i$  – вхідний вектор,  $d_i$  – відповідний йому вихідний сигнал,  $N$  – розмірність навчальної послідовності.

Якщо потрібно класифікувати невідомий вхід, вибирається вихід, найближчий до відомого вхідного сигналу з бази даних.

Процес оцінки синаптичних параметрів є не єдиною проблемою і не останньою проблемою навчання. Набагато складнішою проблемою є

створення набору навчальних прикладів, які повністю описують технічний стан складного просторового об'єкта.

Оцінка НМ показує, що для вирішення діагностичної проблеми використовуються різні шари та решітчасті структури. Однак існують труднощі із використанням ШНМ:

- Зі збільшенням розміру вхідного сигналу та кількості шарів складність мережі і, отже, час навчання зростає в геометричній прогресії, і результат може бути неоптимальним;
- Математичний апарат методів вирішення НМ задач важкий для розуміння.

## 2.6 Побудова нейронної мережі для класифікатора

### 2.6.1 Визначення архітектури інтелектуального класифікатора

НМ широко використовується при класифікації станів об'єктів. Практичне використання НМ для вирішення практичної проблеми вимагає наступного:

- навчання НМ на відомих прикладах (на навчальній множині);
- дія навченої нейронної мережі.

Реалізація пов'язана з виконанням пунктів наведених на рисунку 2.4:

- виконати попередню обробку вхідних даних для точної побудови навчального набору;
- визначити спосіб інтерпретації відповідей;
- вибрати критерій оцінки роботи мережі;
- провести процедуру навчання;
- забезпечити роботу мережі.

Типами НМ, які успішно вирішують задачу класифікації є багат шарова НМ прямого розповсюдження, двошарова нейронна мережа LVQ та ймовірнісна мережа PNN (Probabilistic Neural Network).



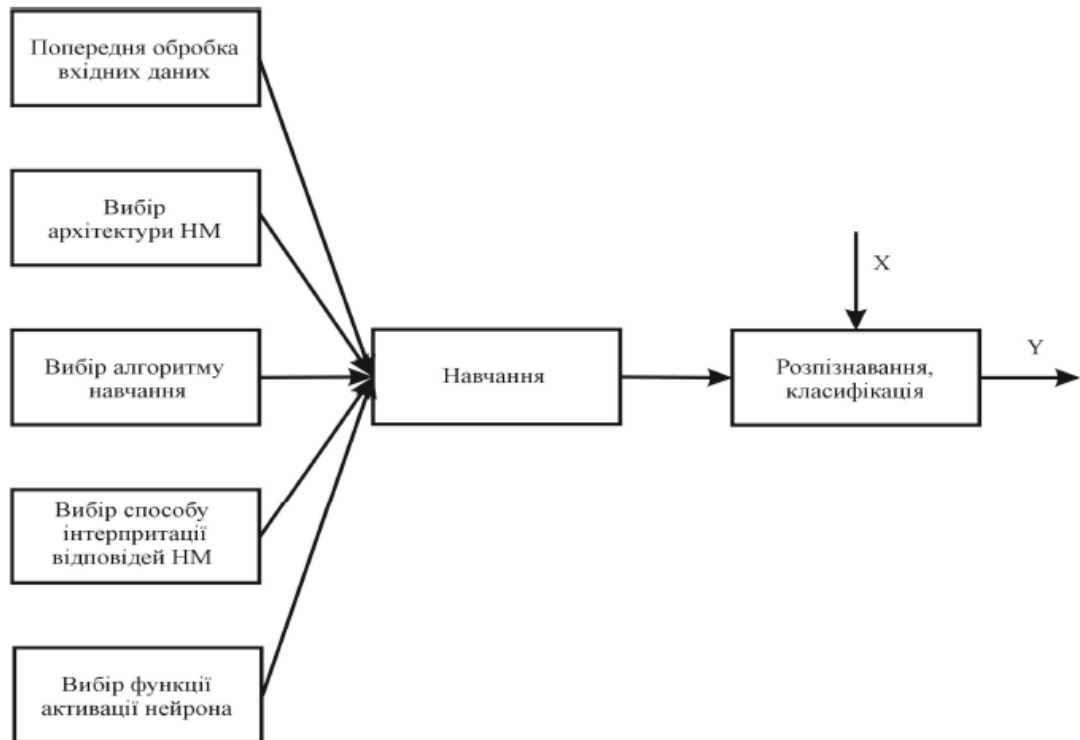


Рисунок 2.4 – Схема конфігурації НМ для вирішення задач класифікації

До радіально-базисного типу належать імовірнісні нейронні мережі. Загалом, основна архітектура мережі базується на радіальних функціях або мережах RBF, які передбачають наявність трьох рівнів, які виконують абсолютно різні функції. Вхідний рівень складається з сенсорних елементів, які підключають мережу до вхідних даних. Другий рівень - єдиний прихований шар. Виконує функцію нелінійного перетворення. Третій рівень - це прийняття рішень, тобто вирішення проблем, з якими стикається мережа. Будова радіального базисного нейрона з  $R$  входами та мережі (рис. 2.5 - 2.6).

У радіально-базисному нейроні функція  $\|dist\|$  обчислює евклідову відстань між вхідним вектором  $P$  і вагою нейрона  $IW$ . Зсув  $b$  використовується для регулювання чутливості нервових клітин. Вхід активації визначається як модуль для різниці між ваговим вектором  $IW$  і вектору входу  $P$ , помножений на зміщення  $b$ . Евклідова відстань розраховується за формулою:

$$\|dist\| = \|P - IW\| = \|p_i - w_j\| = \sqrt{\sum_{i,j=1}^R (p_i - w_j)^2} \quad (2.8)$$

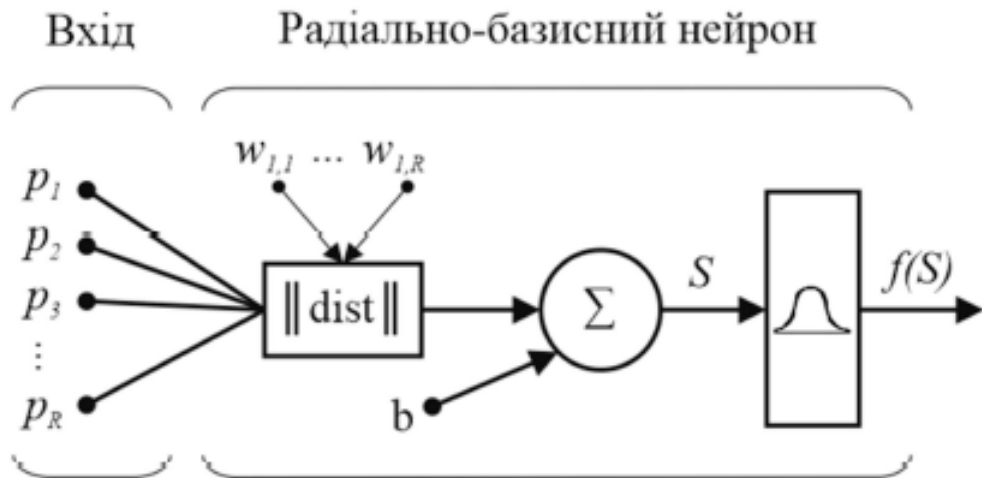


Рисунок 2.5 – Структура радіально базисного нейрона

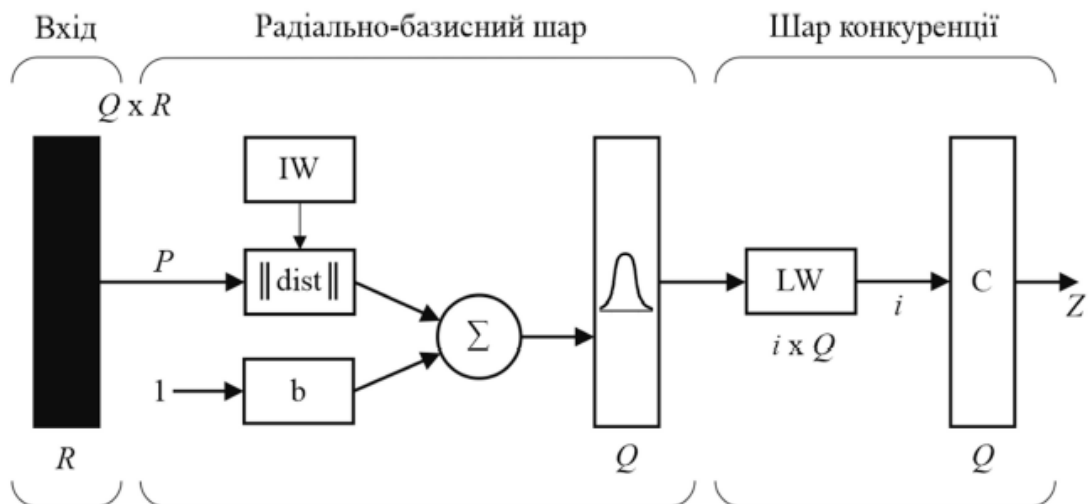


Рисунок 2.6 – Архітектура ІНМ

Вхід функції активації  $S$  формується за формулою:

$$S = \|P - IW\| \cdot b \quad (2.9)$$

При навчанні ІНМ задається параметр впливу *spread* (або його ще називають параметр згладжування), який пропорційний радіусам базисних функцій  $\sigma_j^2$ .

Ці радіуси характеризують перекриття радіально-базисних функцій (рис. 2.7).




Рисунок 2.7 – Розподіл перекриття радіально-базисних функцій від значення параметру впливу  $\sigma^2$ : а) невелике  $\sigma^2$ ; б) середнє  $\sigma^2$ ; в) велике  $\sigma^2$

Середня відстань між центром кластера, включаючи нервовий елемент  $j$  та його безпосереднє оточення є шириною функції:

$$\sigma_j^2 = \frac{1}{p} \sum_{i=1}^p |W_j - W_i|^2 \quad (2.10)$$

Невелике значення  $\sigma^2$  (рис. 2.7 а) означає, що передбачувана щільність функцій має чіткіші та більш окремі класи, які відповідають розташуванню навчальних тестів. Якщо  $\sigma^2 \rightarrow \infty$  розподіл перекриття буде відповідати Гаусівському.

Графік функції активації (рис. 2.8).




Рисунок 2.8 – Функція активації радіально-базисного нейрона

Функція приймає значення 1, за умови, що вектори  $P$  і  $W$  ідентичні. У міру зменшення відстані між цими векторами вихід радіально базисної функції збільшується, і навпаки. Таким чином, радіально базисний нейрон діє як індикатор. Зміщення  $b$  надає можливість коригувати чутливість нейрона *radbas*.

Навчальна множина містить  $Q$  пар векторів вхід/ціль. Є класи, до яких можуть належати вхідні вектори. Рядки матриці  $Tc$  відповідають класу приналежності та стовпцям для вхідних векторів. Отже, якщо елемент  $Tc(i, j)$  матриці зв'язності дорівнює 1, то це означає, що  $j$ -й вхідний вектор належить до класу  $i$ .

Кількість нейронів у першому шарі формується кількістю  $Q$  пар вхідних векторів/ціль навчальної множини. Вихідний шар конкуренції містить  $K$  нейронів, відповідно до  $K$  класів.

Проведений аналіз НМ показав, що використання мережі RBF для задач класифікації є доречнішим, оскільки вони забезпечують якісний зв'язок з кращою точністю та найкращими характеристиками. Перевагою моделі є швидка збіжність алгоритмів навчання, що досягається спеціальною архітектурою цих мереж та використанням тригера або похідної функції розподілу Гауса в нейроні в прихованому шарі.

## 2.7 Розпізнавання станів

### 2.7.1 Об'єкт діагностики

Як об'єкт розглядається зварний паливний резервуар (рис. 2.9), який містить екологічно небезпечні речовини.




Рисунок 2.9 – Резервуар, що зберігає дизельне паливо: а) модель ; б) загальний проектний план

Як показано в [20], зварні шви до резервуарів мають підвищене навантаження та деформацію під впливом вертикальних навантажень від покрівлі, монтажне обладнання та інші конструктивні елементи, що може призвести до появи і розвитку тріщин у зварному шві.

Поява і розвиток тріщин на зварних швах резервуара призводить до зміни їх статичних та динамічних властивостей і негативно впливає на структурну стійкість об'єкта. і може призвести до руйнування.

Причини пошкоджень поділяються на внутрішні та зовнішні. До внутрішніх відносяться якість матеріалів та їх фізико-хімічні характеристики, умови виготовлення. Зовнішні причини включають умови праці та природні фактори, такі як наслідки зміни клімату та навколишнього середовища.

Керуючи реакцією датчиків, розміщених на елементах конструкції,

можна визначити стан об'єкта протягом певного періоду часу.

Для вирішення проблеми ідентичності необхідно генерувати вхідні багатовимірні вектори з діагностичними властивостями на основі аналізу діагностичної інформації від просторово розташованого датчика (рис. 2.10). Розташування датчиків визначається в результаті дослідження пласта як діагностичного об'єкта. Загалом, класифікатор посилається на об'єкт, який посилається на один із визначених класів функціональних станів, розділений за доступністю, розміром та неправильним розташуванням.




Рисунок 2.10 – Приклад розташування множини чутливого елемента на резервуарі: 1 – акселерометри та інклінометри; 2 – тензодатчик.

Якщо підключити координати положення зв'язку до кожного закріплення ЧЕ діагностичну ознаку  $a_i$ , яка, в загальному випадку, може відноситись до спектральних, кореляційних, статистичних характеристик вимірюваного сигналу, то для розпізнавання використовується  $n$ -вимірний вектор діагностичних ознак:

$$A = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{pmatrix} \quad (2.11)$$

Кожна ознака  $a_i$  ( $i = 1 \dots n$ ) характеризує об'єкт в точці отримання інформації,  $n$  (кількість ознак) може варіюватися в залежності від кількості вимірювальних каналів.

За відхиленнями від діагностичних функцій можна сформувати набір даних (тестових векторів), які збігаються з відхиленнями властивостей імітатора.

Визначає вектор  $A_0$ , який складається з 5 елементів.

Стан ОК описується 6 класами.

1) Клас  $S_0$  відповідає нормальній роботі. Усі вказані параметри набору символів не перевищували похибки  $\Delta = \pm 5 \%$ .

2) До класу  $S_1$  складається з вхідних векторів, де один із параметрів перевищує допустиму похибку  $\Delta = \pm 5 \%$ .

3) До класу  $S_2$  складається з вхідних векторів, де два параметри одночасно перевищують допустимі похибки  $\Delta = \pm 5 \%$ .

4) До класу  $S_3$  складається з вхідних векторів, де три параметри одночасно перевищують допустимі похибки  $\Delta = \pm 5 \%$ .

5) До класу  $S_4$  складається з вхідних векторів, де чотири параметри одночасно перевищують допустимі похибки  $\Delta = \pm 5 \%$ .

6) До класу  $S_5$  складається з вхідних векторів, де всі характеристичні параметри перевищують допустимі похибки  $\Delta = \pm 5 \%$ .

### 2.7.2 Навчальна множина класифікатора

Клас  $S_0$  у якого навчальними векторами є сам вектор діагностичних ознак  $A_0$ , два вектори з максимально допустимими похибками  $(+\Delta \cdot A_0)$  та  $(-\Delta \cdot A_0)$ , різні комбінації відхилень елементів  $A_0$  у допустимому проміжку похибок  $[0,95 \ 1,05]$ .

Для кожного стану (від  $S_1$  до  $S_5$ ) вибираються такі помилки в елементах векторного набору векторів:  $\pm 5,5 \%$ ,  $\pm 10 \%$ ,  $\pm 15 \%$ ,  $\pm 20 \%$ ,  $\pm 25 \%$ ,

$\pm 50\%$ . Щоб визначити стан досліджень  $S_1$  НМ навчається на такій сукупності векторів:

$$P_{S_1} = \begin{pmatrix} (1 \pm \Delta_i) \cdot a_1^0 \\ a_2^0 \\ \vdots \\ a_5^0 \end{pmatrix} \quad (2.12)$$

Аналогічно, для визначення класу  $S_2$  НМ навчається на такій сукупності векторів:

$$P_{S_2} = \begin{pmatrix} a_1^0 \\ (1 \pm \Delta_i) \cdot a_2^0 \\ \vdots \\ a_5^0 \end{pmatrix} \quad (2.13)$$

Навчальні вектори для класів  $S_3 - S_5$  формуються за такою ж схемою. Загальний набір векторів для 6 класів  $S_0 - S_5$  записується як матриця:

$$P = [P_{S_0}; P_{S_1}; P_{S_2}; P_{S_3}; P_{S_4}; P_{S_5}] \quad (2.14)$$

Загальна кількість векторів по класам показана на рисунку 2.11 та складає  $R = 378$ . Як видно, клас  $S_0$  навчається на  $R_0 = 6$  векторах, класи  $S_1$  та  $S_4$  – на  $R_1 = R_4 = 60$ , класи  $S_2$  та  $S_3$  – на  $R_2 = R_3 = 120$ , клас  $S_5$  на  $R_5 = 12$  векторах.






Рисунок 2.11 – Кількість навчальних векторів станів  $S_0$  –  $S_5$

### 2.7.3 Формування тестового набору

Розглянемо 3 варіанти тестової множини:

- всі вхідні вектори мають похибку не більше  $\pm 5\%$ . Похибка, як тестове значення, складає  $\pm 2,5\%$ .

- вхідні елементи векторів класу  $S_0$  співпадають з вектором діагностичних властивостей  $A_0$  при похибці  $\pm 5\%$ , знаходячись у діапазоні  $[0,95; 1,05]$ . Елементи векторів класу  $S_1$  –  $S_5$  не співпадають на  $\pm 9\%$  від параметрів  $A_0$ . Отже, кожен елемент у тестовому векторі має похибку  $\pm 9\%$  для класу  $S_1$ , а інші елементи більше, ніж  $\pm 5\%$ ;

- тестова множина векторів класів  $S_0$  –  $S_5$  згенерована алгоритмічно, похибка елементів становить  $\pm 12\%$ .

Набір векторів тесту класу становить 84. Це показано на рисунку 2.12.




Рисунок 2.12 – Кількість тестових векторів станів  $S_0$  –  $S_5$

#### 2.7.4 Процес ініціалізації інтелектуального класифікатора

Процес навчання в НМ потребує декілька прикладів класифікацій -  $P$ -вхідні дані та бажані результати (виходи)  $T$ . Цей метод називається методом навчання "з вчителем". Цей принцип використовується для вивчення ймовірностей мережі PNN. Кожному вектору входу класів  $S_0$  –  $S_5$  повинно відповідати цільове значення класу. Враховуючи що  $R = 378$ , то вектор-рядок цільових виходів має  $R$  цілей. У програмній реалізації класам присвоюються такі значення:  $S_0 - 1$ ,  $S_1 - 2$ ,  $S_2 - 3$ ,  $S_3 - 4$ ,  $S_4 - 5$ ,  $S_5 - 6$ . Отже, вихід  $T_0$  має розмір  $1 \times R_0$  всі елементи якого дорівнюють 1;  $T_1$  розмірністю  $1 \times R_1$  з елементами 2;  $T_2 - 1 \times R_2$  з елементами 3 і т.д.

Масиви  $P$  і  $T_c$  дозволяють сформувати мережу, змоделювати її за допомогою вхідного масиву  $P$  та забезпечити, щоб мережа правильно вирішувала завдання класифікації на елементах тестового набору.

Загальна схема класифікатора стану системи моніторингу зображена на рисунку 2.13.

Функція  $net = newpnn(P,T,spread)$  формує в ППП Matlab ймовірнісну мережу PNN.  $Spread$  – параметр впливу (за замовчуванням встановлюється 1,0).

Перший шар ймовірнісної мережі сформований на радіально-базисних нейронах, має функцію активації з Гаусівським розподілом:

$$f(S) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot e^{-\frac{(S-\mu)^2}{2\sigma^2}} \quad (2.15)$$

де параметр  $\mu$  – математичне очікування,  $\sigma$  – середньоквадратична відхилення ( $\sigma^2$  – дисперсія) відхилення. Чим більше  $\sigma$ , тим більший параметр впливу  $spread$ .

В нормальному розподілі  $spread$  відповідає  $\sigma$ . Якщо  $spread$  близький до нуля, мережа діє як класифікатор стану. У міру збільшення параметра параметр для мережі ймовірностей враховує вплив сусідніх станів. При значно менших значеннях відтворення функція розподілу Гауса охоплює невелику кількість ефектів, що відображається на якості оцінки класифікації.

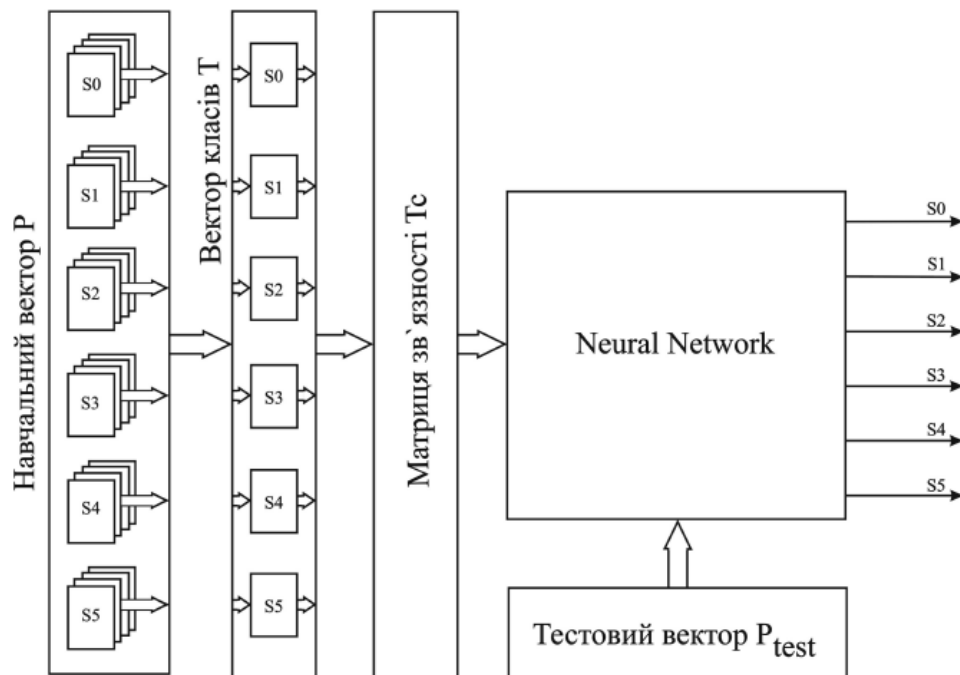


Рисунок 2.13 – Класифікатор технічного стану для системи моніторингу

Блок-схема НМ у програмному середовищі Matlab, де  $x\{1\}$  – вхідна множина векторів,  $y\{1\}$  – результат показана на рисунку 2.14.

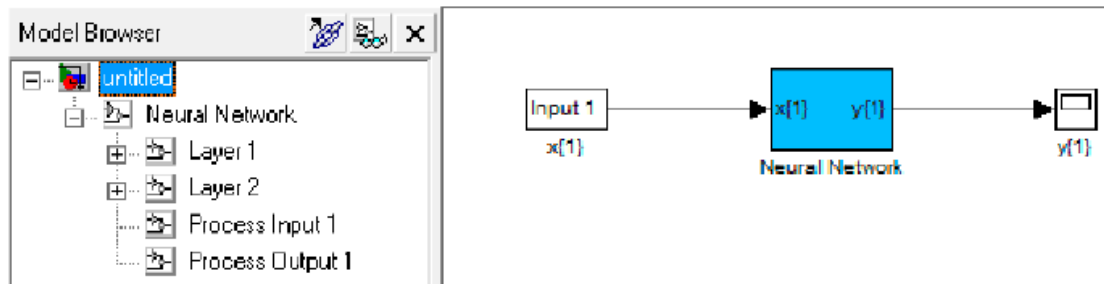


Рисунок 2.14 – Блок-схема класифікатора в програмному середовищі Matlab

Блок Neural Network показано на рисунку 2.15. На вхід подається масив  $x\{1\}$ , який відповідає вектору входу  $P$ . На перший шар НМ подається вхід  $P$ .  $a\{1\}$  – масив розміром  $Q \times 1$ , де  $Q$  – кількість нейронів першого шару являє собою вихід першого шару. Масив  $a\{1\}$  - вхід другого шару. На виході НМ отримуємо матрицю (або масив)  $y\{1\}$ , що показує результат класифікації.

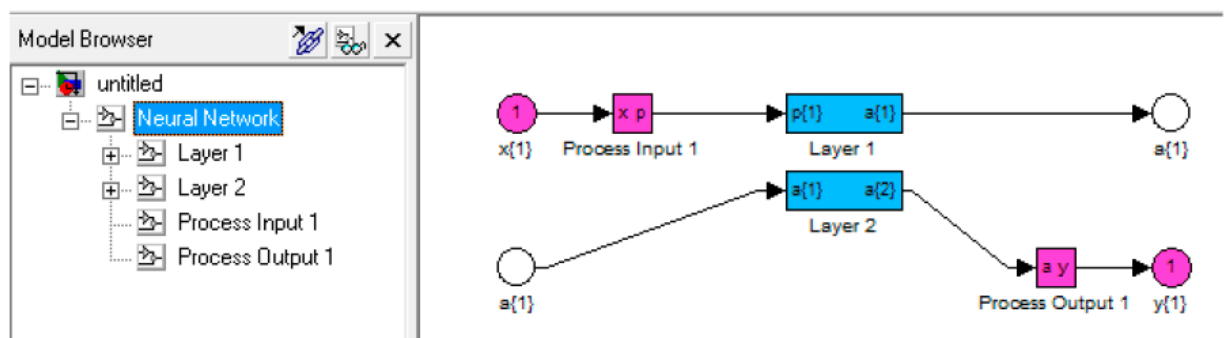


Рисунок 2.15 – Блок-схема сформованої НМ

Розкриті структури кожного шару (рис. 2.16–2.17).




Рисунок 2.16 – Перший шар НМ

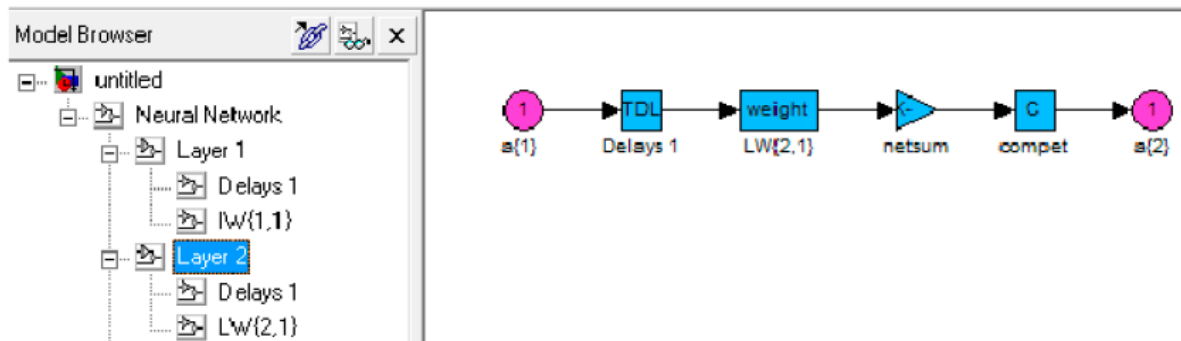
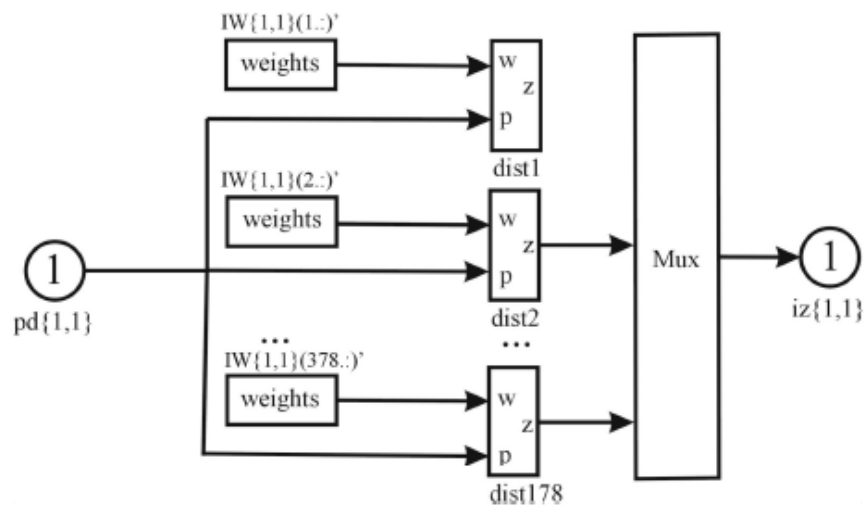


Рисунок 2.17 – Другий шар НМ

Якщо розкрити  $IW\{1,1\}$  та  $LW\{2,1\}$  можна виявити структуру матриці ваг кожного шару (рис. 2.18 – 2.19).

Рисунок 2.18 – Матриця ваг  $IW\{1,1\}$  першого шару

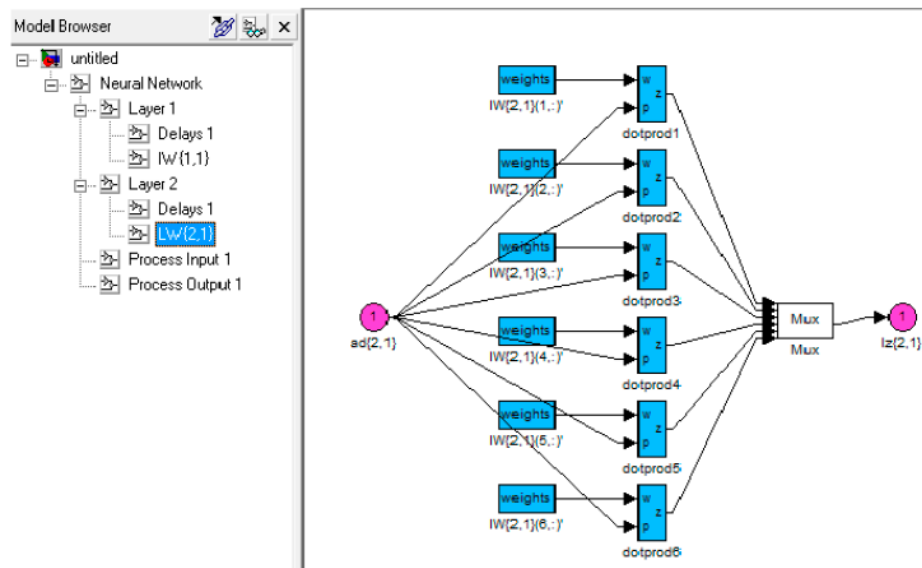


Рисунок 2.19 – Матриця ваг  $LW\{2,1\}$

Основним недоліком мережі PNN є те, що кількість нейронів у першому шарі прихована кількістю векторів. Матриця ваг  $IW\{1,1\}$  має розмірність  $i \times j$ :

$$IW\{1,1\} = (w_{i,j}) \quad (2.16)$$

де  $i = 1 \dots R$  (кількість навчальних векторів),  $j = 1 \dots n$  ( $n$  – кількість елементів матриці діагностичних ознак).

### 3 ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ КЛАСИФІКАТОРА

3.1 Проведення дослідження класифікатора на розпізнавання стану об'єкта

Подаємо на вхід набір тестових даних, які були створені в розділі 2.7.3. Результати класифікації представлені в таблиці 3.1.  $N_{\text{заг}}$  представляє загальну кількість вхідних векторів, призначених класам  $S_0 - S_5$ . Значення стовпців стану показують кількість вхідних векторів, які правильно присвоєні з  $N_{\text{заг}}$  відповідному шару при різних значеннях параметра впливу (*spread*).

Таблиця 3.1 Точність класифікації векторів вхідного набору тестових даних

Клас	$N_{\text{заг. тест}}$	$P(\text{test1})$	$P(\text{test2})$	$P(\text{test3})$
$S_0$ (1)	22	22	22	22
$S_1$ (2)	10	10	10	10
$S_2$ (3)	20	20	20	20
$S_3$ (4)	20	20	20	20
$S_4$ (5)	10	10	10	10
$S_5$ (6)	2	2	2	2
$\Sigma$	84	84	84	84

Було встановлено, що всі вхідні вектори були правильно класифіковані. Звідси можна сказати про надійність розробленого класифікатора в НМ. Проблема розпізнавання стану об'єкта вирішена.

### 3.2 Дослідження впливу параметра *spread* на якість розпізнавання образів

Необхідно дослідити якісні характеристики класифікатора на НМ використовуючи параметр впливу. Параметр впливу *spread* варіюється від 1 до 0,005. Дані досліджень показані в (табл. 3.2 – 3.7). Співвідношення (коефіцієнт) ефективності  $K_{\text{еф}}$  показує узгодженість результатів класифікації та визначається за формулою:

$$K_{\text{еф}} = \frac{N}{N_{\text{заг}}} \quad (3.1)$$

де  $N$  – кількість векторів, що правильно класифікувались;

$N_{\text{заг}}$  – загальна кількість тестових векторів. Так як при похибці  $\delta = \pm 2,5\%$  не перевищує допустимого значення, всі вхідні вектори повинні відноситися до класу  $S_0$ .

Таблиця 3.2 Точність класифікації ( $\delta = 2,5\%$ )

<i>spread</i> (вплив)	Стан	Коефіцієнт ефективності
	$S_0$ (1)	
$N_{\text{заг}}$	84	–
1	0	0
0,8	0	0
0,6	0	0
0,4	0	0
0,3	0	0
0,2	20	0,24
$N_{\text{заг}}$	84	–
0,1	65	0,77
0,08	82	0,97
0,06	84	1
0,01	84	1
0,005	84	1



Задовільна якість класифікації відбувається при значенні параметру впливу  $spread = 0,09$  та становить 89%. Зі значення  $spread = 0,07$  становить 100%. Якщо зменшувати параметр  $spread$  це не призводить до більш поганої класифікації.

У таблиці 3.3 наведені результати класифікації при похибці тестової множини  $\delta = \pm 6\%$ . Задовільна ефективність класифікації відбувається, якщо  $spread = 0,2$ , ефективність = 100% якщо значення  $spread = 0,1$ .

Таблиця 3.3 Точність класифікації ( $\delta = 6\%$ )

$spread$ (вплив)	Клас						$\Sigma$	К еф
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзаг. тест	22	10	20	20	10	2	84	–
1	0	0	20	0	0	0	20	0,24
0,8	0	0	20	0	0	0	20	0,24
0,6	0	2	20	2	0	0	24	0,29
0,5	0	4	18	8	0	0	30	0,36
0,4	0	6	16	14	0	0	36	0,43
0,3	0	8	20	18	6	0	52	0,62
0,2	12	10	20	20	10	2	74	0,89
0,1	22	10	20	20	10	2	84	1
0,08	22	10	20	20	10	2	84	1
0,06	22	10	20	20	10	2	84	1
0,04	22	10	20	20	10	2	84	1
0,02	22	10	20	20	10	2	84	1
0,01	22	10	20	20	10	2	84	1
0,005	22	10	20	20	10	2	84	1

У разі похибки  $\delta = \pm 9\%$  (табл. 3.4) ефективність класифікатора аналогічна похибці  $\delta = \pm 6\%$ . Однак було встановлено, що занадто низькі значення параметрів впливу негативно впливають на якість. Якщо  $spread = 0,005 = 93\%$ . Відбувається гірша класифікація при зменшенні параметру  $spread$ .

Таблиця 3.4 Точність класифікації ( $\delta = 9\%$ )

$spread$ (вплив)	Клас						$\Sigma$	К еф
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзаг. тест	22	10	20	20	10	2	84	–
1	0	0	20	2	0	0	22	0,26
0,9	0	0	20	2	0	0	22	0,26
0,8	0	0	20	8	0	0	28	0,33
0,7	0	0	20	14	0	0	34	0,40
0,6	0	4	18	14	0	0	36	0,43
0,5	0	4	18	18	4	0	44	0,52
0,4	0	8	20	20	10	2	60	0,72
0,3	0	10	20	20	10	2	62	0,74
0,2	12	10	20	20	10	2	74	0,88
0,1	22	10	20	20	10	2	84	1
0,08	22	10	20	20	10	2	84	1
0,06	22	10	20	20	10	2	84	1
0,04	22	10	20	20	10	2	84	1
0,02	22	10	20	20	10	2	84	1
0,01	22	10	20	20	10	2	84	1
0,005	22	10	20	20	6	0	78	0,93

$\delta = \pm 10\%$  (табл. 3.5) похибка є навчальною, тому, починаючи від  $spread = 0,1$ , зменшення параметра впливу не знижує ефективність класифікації. Задовільним значенням  $spread$  є  $0,2$ .

Таблиця 3.5 Точність класифікації ( $\delta = 10\%$ )

<i>spread</i> (вплив)	Клас						$\Sigma$	К еф
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзаг. тест	22	10	20	20	10	2	84	–
1	0	0	20	4	0	0	24	0,29
0,9	0	0	20	8	0	0	28	0,33
0,8	0	0	20	12	0	0	32	0,38
0,6	0	4	18	16	2	0	40	0,48
0,5	0	4	18	20	6	0	48	0,57
0,4	0	10	20	20	10	2	62	0,74
0,2	12	10	20	20	10	2	74	0,88
0,1	22	10	20	20	10	2	84	1
0,08	22	10	20	20	10	2	84	1
0,06	22	10	20	20	10	2	84	1
0,04	22	10	20	20	10	2	84	1
0,02	22	10	20	20	10	2	84	1
0,01	22	10	20	20	10	2	84	1
0,005	22	10	20	20	10	2	84	1

У разі похибки  $\delta = \pm 12\%$  (табл. 3.6) прийнятна ефективність класифікатора відповідає  $spread = 0,2$ . Якщо значення параметру впливу  $spread = 0,1$  до  $0,02$  становить  $100\%$ . Значно зменшується ефективність класифікації, якщо параметр впливу  $spread = 0,01$ .

Таблиця 3.6 Точність класифікації ( $\delta = 12\%$ )

<i>spread</i> (вплив)	Клас						$\Sigma$	К еф
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
$N_{\text{заг. тест}}$	22	10	20	20	10	2	84	–
1	0	0	20	10	0	0	30	0,36
0,9	0	0	18	14	0	0	32	0,38
0,8	0	0	18	16	0	0	34	0,40
0,7	0	0	18	18	4	0	40	0,48
0,6	0	4	18	20	6	0	48	0,57
0,4	0	10	20	20	10	2	62	0,74
0,3	0	10	20	20	10	2	62	0,74
0,2	12	10	20	20	10	2	74	0,88
0,1	22	10	20	20	10	2	84	1
0,09	22	10	20	20	10	2	84	1
0,08	22	10	20	20	10	2	84	1
0,07	22	10	20	20	10	2	84	1
0,06	22	10	20	20	10	2	84	1
0,05	22	10	20	20	10	2	84	1
0,04	22	10	20	20	10	2	84	1
0,03	22	10	20	20	10	2	84	1
0,02	22	10	20	20	10	2	84	1
0,01	22	10	20	20	6	0	78	0,93
0,005	22	6	2	0	0	0	30	0,36

$\delta = \pm 15\%$  (табл. 3.7) похибка є навчальною, тому, починаючи від  $spread = 0,1$ , зменшення параметра впливу не знижує ефективність класифікації. Задовільним значенням  $spread$  є 0,2.

Таблиця 3.7 Точність класифікації ( $\delta = 15\%$ )

<i>spread</i> (вплив)	Клас						$\Sigma$	К <sub>еф</sub>
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
N <sub>заг. тест</sub>	22	10	20	20	10	2	84	–
1	0	0	18	16	0	0	34	0,40
0,9	0	0	18	18	2	0	38	0,45
0,8	0	0	20	20	4	0	44	0,52
0,7	0	4	20	20	8	0	52	0,62
0,6	0	10	20	20	10	2	62	0,74
0,5	0	10	20	20	10	2	62	0,74
0,4	0	10	20	20	10	2	62	0,72
0,3	0	10	20	20	10	2	62	0,72
0,2	12	10	20	20	10	2	74	0,88
0,1	22	10	20	20	10	2	84	1
0,09	22	10	20	20	10	2	84	1
0,08	22	10	20	20	10	2	84	1
0,07	22	10	20	20	10	2	84	1
0,06	22	10	20	20	10	2	84	1
0,05	22	10	20	20	10	2	84	1
0,04	22	10	20	20	10	2	84	1
0,03	22	10	20	20	10	2	84	1
0,02	22	10	20	20	10	2	84	1
0,01	22	10	20	20	10	2	84	1
0,005	22	10	20	20	10	2	84	1

На рисунку 3.1 наведено вплив параметру *spread* при різних похибках вхідних множин на ефективність класифікатора.

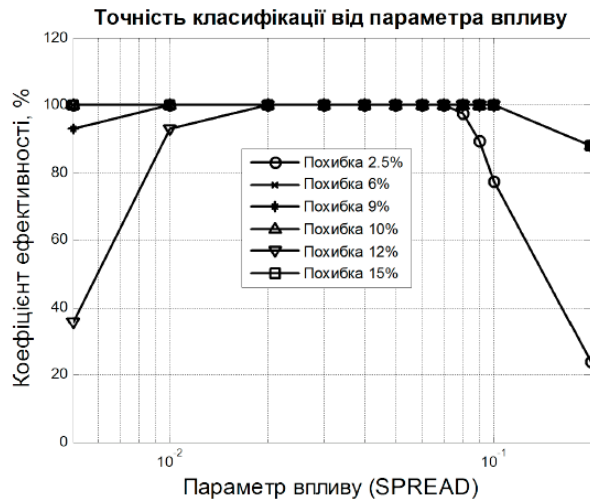


Рисунок 3.1 – Точність класифікатора від параметра впливу

За результатами ефективності класифікатора від параметру впливу можна зазначити, що помилок у стані об'єкта на входному наборі, що відповідають зазначеним класам стану, немає, з іншими помилками, кожен з елементів в об'єкті відбувається за значеннями  $spread \in [0,02; 0,07]$ .

### 3.3 Дослідження якості класифікації в залежності від кількості навчальних векторів

Від кількості входних даних залежить розмір радіально-базисного шару мережі PNN. Зі збільшенням розміру НМ, потрібно збільшувати пам'ять програмному забезпеченню. Необхідно зрозуміти, як кількість векторів навчальних даних впливає на точність класифікації.

Класифікатор перевіряється на наявність похибок що дорівнюють 2,5 %, ± 10 %, ± 15 %, ± 17 %, ± 20 %, ± 25 %, ± 30 %, ± 35%.

Кількість навчальних векторів  $N1 = 316$  зображено на рисунку 3.2.

НМ вчиться на похибках елементів векторів, які дорівнюють: ± 5,5 %, ± 10 %, ± 15 %, ± 20 %, ± 25 %. У таблиці 3.8 наведені результати класифікації. Можемо побачити, що ефективність класифікатора

явно не втрачається.




Рисунок 3.2 – Кількість навчальних векторів  $N1 = 316$

Таблиця 3.8 Підсумкові дані класифікації при навчанні ( $N1 = 316$ )

$\delta$ - Похибка тестових векторів	Клас						$\Sigma$	$K_{\text{еф}}$
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
$N_{\text{заг. тест}}$	22	10	20	20	10	2	84	–
$\delta = 2,5\%$	22	10	20	20	10	2	84	1
$\delta = 10\%$	22	10	20	20	10	2	84	1
$\delta = 15\%$	22	10	18	20	10	2	84	1
$\delta = 17\%$	22	10	20	20	10	2	84	1
$\delta = 20\%$	22	10	20	20	10	2	84	1
$\delta = 25\%$	22	10	20	20	10	2	84	1
$\delta = 30\%$	22	10	20	20	10	2	84	1
$\delta = 35\%$	22	10	20	20	10	2	84	1

Кількість навчальних векторів  $N2 = 254$  зображено на рисунку 3.3.

НМ вчиться на похибках елементів векторів, які

дорівнюють:  $\pm 5,5\%$ ,  $\pm 10\%$ ,  $\pm 15\%$ ,  $\pm 20\%$ . У таблиці 3.9 наведені результати класифікації. Було виявлено, що ефективність класифікатора була втрачена, коли похибка становила  $\delta = \pm 30\%$ .




Рисунок 3.3 – Кількість навчальних векторів  $N2 = 254$

Таблиця 3.9 Підсумкові дані класифікації при навчанні ( $N2 = 254$ )

$\delta$ - Похибка тестових векторів	Клас						$\Sigma$	Кеф
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзаг. тест	22	10	20	20	10	2	84	–
$\delta = 2,5\%$	22	10	20	20	10	2	84	1
$\delta = 10\%$	22	10	20	20	10	2	84	1
$\delta = 15\%$	22	10	18	20	10	2	84	1
$\delta = 17\%$	22	10	20	20	10	2	84	1
$\delta = 20\%$	22	10	20	20	10	2	84	1
$\delta = 25\%$	22	10	20	20	10	2	84	1
$\delta = 30\%$	22	10	20	20	8	2	82	0,98
$\delta = 35\%$	22	10	20	18	4	0	74	0,88

Кількість навчальних векторів  $N3 = 192$  зображено на рисунку 3.4.

НМ вчиться на похибках елементів векторів, які дорівнюють:



$\pm 5,5\%$ ,  $\pm 10\%$ ,  $\pm 15\%$ . У таблиці 3.10 наведені результати класифікації. Було виявлено, що ефективність класифікатора втрачається при  $\delta = \pm 25\%$ .

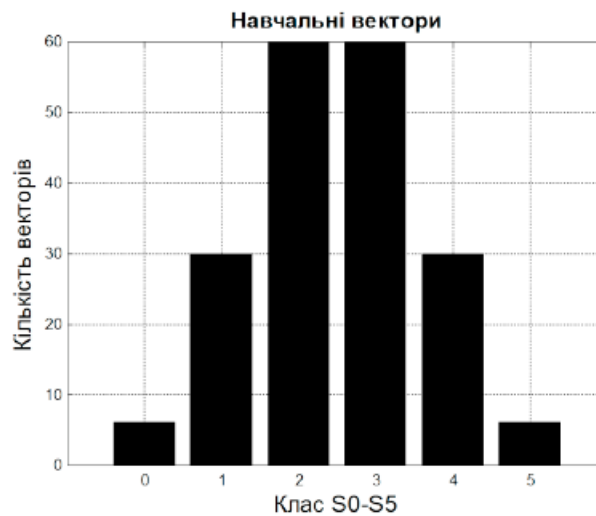


Рисунок 3.4 – Кількість навчальних векторів  $N3 = 192$

Таблиця 3.10 Підсумкові дані класифікації при навчанні ( $N3 = 192$ )

$\delta$ - Похибка тестових векторів	Клас						$\Sigma$	Кеф
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзаг. тест	22	10	20	20	10	2	84	1
$\delta = 2,5\%$	22	10	20	20	10	2	84	1
$\delta = 10\%$	22	10	20	20	10	2	84	1
$\delta = 15\%$	22	10	20	20	10	2	84	1
$\delta = 17\%$	22	10	20	20	10	2	84	1
$\delta = 20\%$	22	10	20	20	10	2	84	1
$\delta = 25\%$	22	10	20	20	8	0	82	0,96
$\delta = 30\%$	22	10	20	18	4	0	74	0,88
$\delta = 35\%$	22	10	12	2	0	0	46	0,55

Кількість навчальних векторів  $N4 = 130$  зображено на рисунку 3.5.

НМ вчиться на похибках елементів векторів, які дорівнюють:  $\pm 5,5\%$ ,  $\pm 10\%$ .

У таблиці 3.11 наведені результати класифікації. Було виявлено, що ефективність класифікатора втрачається при  $\delta = \pm 20\%$ .

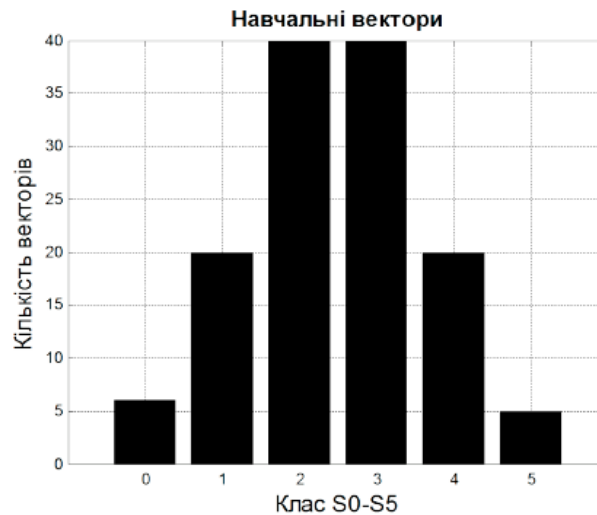


Рисунок 3.5 – Кількість навчальних векторів  $N_4 = 130$

Таблиця 3.11 Підсумкові дані класифікації при навчанні ( $N_4 = 130$ )

$\delta$ - Похибка тестових векторів	Клас						$\Sigma$	Кеф
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзаг. тест	22	10	20	20	10	2	84	1
$\delta = 2,5\%$	22	10	20	20	10	2	84	1
$\delta = 10\%$	22	10	20	20	10	2	84	1
$\delta = 15\%$	22	10	20	20	6	2	84	1
$\delta = 17\%$	22	10	20	20	6	2	84	1
$\delta = 20\%$	22	10	20	18	4	2	82	0,98
$\delta = 25\%$	22	10	20	12	0	0	66	0,79
$\delta = 30\%$	22	10	12	2	0	0	48	0,57
$\delta = 35\%$	22	8	2	0	0	0	34	0,40

Кількість навчальних векторів  $N_5 = 68$  зображено на рисунку 3.6. НМ вчиться на похибках елементів векторів, які дорівнюють:  $\pm 5,5\%$ . У

таблиці 3.12 наведені результати класифікації. Було виявлено, що ефективність класифікатора втрачається при  $\delta = \pm 20\%$ .




Рисунок 3.6 – Кількість навчальних векторів  $N5 = 68$

Таблиця 3.12 Підсумкові дані класифікації при навчанні ( $N5 = 68$ )

$\delta$ - Похибка тестових векторів	Клас						$\Sigma$	Кеф
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзаг. тест	22	10	20	20	10	2	84	1
$\delta = 2,5\%$	22	10	20	20	10	2	84	1
$\delta = 10\%$	22	10	20	20	10	2	84	1
$\delta = 15\%$	22	10	20	20	10	2	84	1
$\delta = 17\%$	22	10	20	20	10	2	84	1
$\delta = 20\%$	22	10	20	20	6	0	78	0,93
$\delta = 25\%$	22	10	14	2	0	0	48	0,57
$\delta = 30\%$	22	8	2	0	0	0	32	0,38
$\delta = 35\%$	22	4	0	0	0	0	26	0,31

Результати точності класифікації (рис. 3.7 – 3.8). Можемо побачити, що дієвість класифікатора не йде щодо більшої похибки за  $\pm 17\%$  у вхідному наборі даних, хоча різниця між елементами в класах  $S_0$  та  $S_1 - S_5$  є загальною до похибок вхідної множини більших не втрачається навіть при різниці між всього на  $0,5\%$ . Виходячи з цього, можна зробити висновок, що використовувати класифікатор можна для надійної точності діагностики стану об'єктів з невеликими відхиленнями. Було встановлено, що зменшення кількості навчальних наборів призвело до того, що класифікація вхідних векторів зменшилась на значні відхилення від елементів порівняно з діагностичним вектором  $A_0$ . Якщо необхідно виправити відповідність стану об'єкта з похибкою, що перевищує  $20\%$ , необхідно вдосконалити класифікаційні функції, розширивши підготовку НМ.

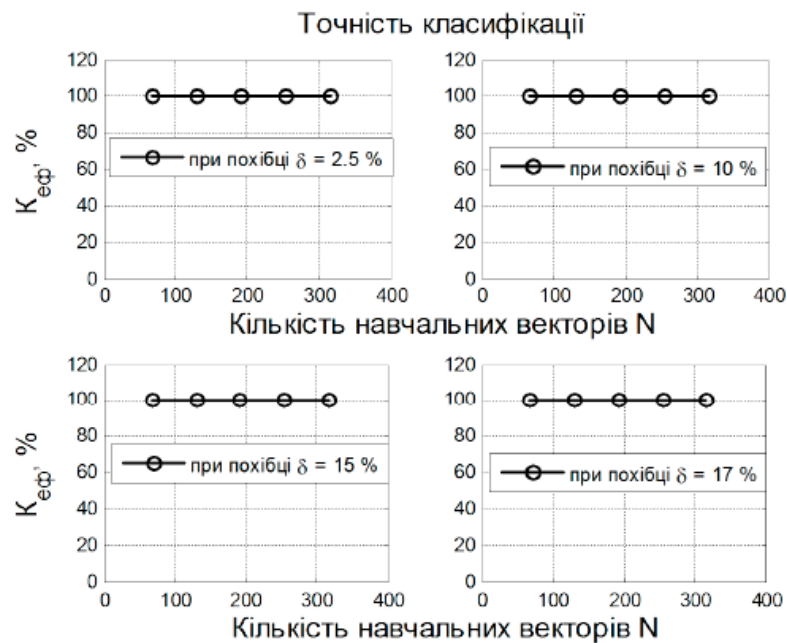


Рисунок 3.7 – Дієвість класифікатора від розмірності вхідних даних при  $\delta = 2,5\%$ ,  $10\%$ ,  $15\%$ ,  $17\%$  вхідних векторів діагностичних ознак

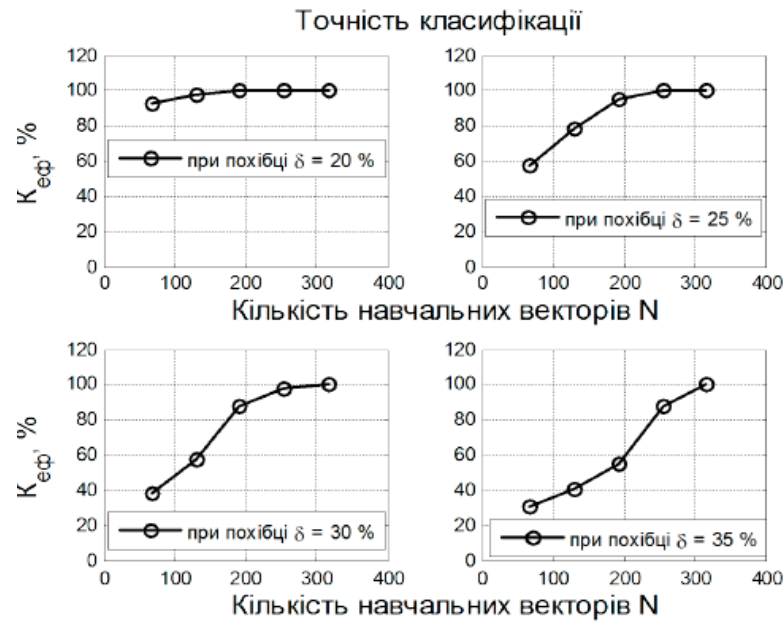


Рисунок 3.8 – Дієвість класифікатора від розмірності вхідних даних при  $\delta = 20\%, 25\%, 30\%, 35\%$  вхідних векторів діагностичних ознак

Було досліджено класифікатори стану об'єкта для реалізації діагностичних функцій на основі ймовірної нейронної мережі, яка забезпечує нелінійний розподіл області функцій у шарах ймовірності. За результатами набору тестів можемо побачити надійність класифікаторів для вирішення проблем з помилками різних вимірів.

Дієвість класифікатора оцінюється за параметром *spread*. Визначено, що для визначення стану бездоганного об'єкта значення параметру впливу *spread* має бути в межах  $[0,02; 0,07]$ .

Ефективність класифікатора оцінюється кількістю об'єктів навчальної множини. За результатами аналізу було встановлено, що навчання нейронних мереж накладає обмеження на правильну класифікацію в послідовності помилок елементів у вхідному наборі. Ефективність розпізнавання зростає із поширенням векторів навчання. Ступінь зміни помилок залежить від мінімальної кількості визначених суб'єктів у наборі досліджень.

## ВИСНОВКИ

Метою магістерської атестаційної роботи є розробка інтелектуального класифікатора на основі нейронних мереж для аналізу даних та їх класифікації.

В магістерській атестаційній роботі проводився аналіз методів класифікації. Проаналізовано архітектури та типи нейронних мереж. На основі аналізу вибрано ймовірнісну мережу PNN, як основу для системи класифікації діагностичної системи, оскільки вона найкраще вирішує проблему. Визначена архітектура для нейронної мережі. Також було сформовано набори навчальних та тестових векторів, що відповідають стану класів діагностичних об'єктів. Виконано реалізацію ймовірнісної НМ в програмному забезпеченні Matlab → Simulink та показано її структуру.

Створений класифікатор перевірено на визначення стану об'єкта за допомогою тестового набору. Отримані результати показують здатність надійної класифікації.

Ефективність класифікатора оцінюється за параметром впливу *spread*. Визначено, що для визначення стану бездоганного об'єкта значення розширення має бути в межах  $[0,02; 0,07]$ .

Ефективність класифікатора оцінюється кількістю об'єктів у навчальному наборі. Аналіз показав, що навчання нейронних мереж накладає обмеження на правильну класифікацію в порядку помилок елементів у вхідному наборі. Якщо збільшується кількість навчальних даних, тоді ефективність розпізнавання зростає. Визначається ступінь змін помилок, що залежить від мінімальної кількості об'єктів у навчальному наборі.

Було визначено яким чином навчальний набір впливає на якість класифікації технічного стану. Ефективність підтверджується точністю визначення стану обстежуваного об'єкту. Похибка факторів параметрів вхідного вектора до 17% від застосованого вектора діагностичних ознак при НМ, яка здатна розрізнити з різницею між факторами стану становить лише

0,5%. Якщо ймовірність оцінки потребує покращення, набір вправ слід збільшити.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Чинакал В. О. Интеллектуальные системы и технологии: учеб. пособие. М.: РУДН, 2008, 303 с.
2. Speckmann H. Structural Health Monitoring: A Contribution to the Intelligent Aircraft Structure. Airbus, Bremen, Germany: ECNDT, 2006, Tu.1.1.1.
3. Бурау Н. І. Вимоги до розробки інформаційно-діагностичного комплексу моніторингу резервуарів з паливом в умовах антарктики: навч. посіб. Вісник НТУУ «КПІ», 2013, вип. 45, с. 105–107.
4. Balageas D. Structural Health Monitoring. Great Britain and the United States. : 2006, 496 p.
5. Prosser W. H. Structural health management for future aerospace vehicles. URL: [http://www.prokopenko.net/Publications/Agents/Australasian\\_SHM\\_Prosser.pdf](http://www.prokopenko.net/Publications/Agents/Australasian_SHM_Prosser.pdf) (дата звернення 01.11.2020).
6. Хареев В. Г. Система комплексного диагностического мониторинга опасных производственных объектов: учеб. пособие. 2006, С. 2–15.
7. Каневский И. Н. Неразрушающие методы контроля : учеб. пособие. Владивосток : ДВГТУ, 2007, 243 с.
8. Петрухин В. В. Основы вибродиагностики и средства измерения вибрации: учеб. пособие. Волгоград : Инфра-Инженерия, 2010, 168 с.
9. Христофоров А. В. Методы спектрального анализа: учебно-методическое пособие к специальному лабораторному практикуму для студентов старших курсов и магистрантов кафедр радиофизического направления. Казань, 2004, 21 с.
10. Grisso V. L. Advancing Autonomous Structural Health Monitoring. Blacksburg, 2007, 124 p.
11. Spencer B. F. Jn. Smart Sensing Technology: Opportunities and Challenges. URL: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.88.3329&rep=rep>



1& type=pdf (дата звернення 01.11.2020).

12. Соколов А. Н. Волоконно оптические датчики и системы: учеб. пособие. Lightwave Russian Edition: 2006, с. 44–46.

13. Янчич В. В. Пьезоэлектрические датчики вибрационного и ударного ускорения : учеб. пособие. Ростов-на-Дону, 2008, 77 с.

14. Лукьянов Д. П. Микроэлектронные акселерометры инерциальных систем навигации : учеб. пособие. СПб. : СПбГЭТУ "ЛЭТИ", 1999, 60 с.

15. Волович А. Интегральные акселерометры: учеб. пособие. 2002. – № 1. – С. 66–72.

16. Клокова Н. П. Тензорезисторы: теория, методики расчёта, разработки: учеб. пособие. М. : Машиностроение, 1990, 224 с.

17. Барашиков А. Я. Оцінка технічного стану будівельних конструкцій промислових будинків і споруд: навч. посіб. К. : НМЦ Держнаглядохоронпраці України, 1998, 232 с.

18. Настанова щодо обстеження будівель і споруд для визначення та оцінки їх технічного стану : національний стандарт України. К.: ДП «УкрНДНЦ», 2017, 47 с.