

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет Комп'ютерної інженерії та управління  
(повна назва)

Кафедра Автоматизації проектування обчислювальної техніки  
(повна назва)

## КВАЛІФІКАЦІЙНА РОБОТА Пояснювальна записка

рівень вищої освіти другий (магістерський)  
(рівень вищої освіти)

Методи прогнозу відмов комп'ютерного обладнання за допомогою  
нейронної мережі  
(тема)

Виконав: студент 2 курсу, групи СКСм-22-1

Кільчицький Д. В.  
(прізвище, ініціали)

Спеціальність 123 – Комп'ютерна інженерія  
(код і повна назва спеціальності)


Тип програми освітньо-професійна  
(освітньо-професійна або освітньо-наукова)

Освітня програма Спеціалізовані  
комп'ютерні системи  
(повна назва освітньої програми)

Керівник доцент Рожнова Т.Г.  
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри

  
(підпис)

Чумаченко С.В.  
(прізвище, ініціали)

2023 р.

Харківський національний університет радіоелектроніки

Факультет Комп'ютерної інженерії та управління

Кафедра Автоматизації проектування обчислювальної техніки

Рівень вищої освіти другий (магістерський)

Спеціальність 123 Комп'ютерна інженерія  
(шифр і назва)

Тип програми Освітньо-професійна  
(освітньо-професійна або освітньо-наукова)

Освітня програма Спеціалізовані комп'ютерні системи  
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. Кафедри АПОТ   
(підпис)

«\_\_\_\_\_» \_\_\_\_\_ 2023 р.

## ЗАВДАННЯ

### НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові Кільчицькому Дмитру Володимировичу

(прізвище, ім'я, по батькові)

1. Тема роботи Методи прогнозу відмов комп'ютерного обладнання за допомогою нейронної мережі

затверджена наказом по університету від 03 листопада 2023 р. № 1282 Ст.

2. Термін подання студентом роботи до екзаменаційної комісії 26 січня 2024 р.

3. Вихідні дані до роботи \_\_\_\_\_

Методики прогнозування відмов, данні для побудови векторів вхідних параметрів мережі  
- таблиця статистичних даних з відмов обладнання КС

Програмне середовище MatLab та мови програмування C+

4. Перелік питань, що потрібно опрацювати в роботі \_\_\_\_\_

Огляд та аналіз сучасних методів прогнозування відмов

Розгляд застосування штучного інтелекту в процесі прогнозування

Оптимальна конфігурація нейронної мережі для прогнозування

Основні моделі методи з використанням ШІ

Апаратні і програмні засоби реалізації алгоритмів нейромереж

Особливості прогнозування відмов за допомогою НМ

Програмна реалізація нейронної мережі та дослідження

Порівняльний аналіз ефективності традиційних та інноваційних методів прогнозування

Експериментальне дослідження та аналіз результатів

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (слайдів) \_\_\_\_\_  
слайди презентацій 18 слайдів.pptx


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

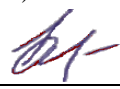
Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата

7. Дата видачі завдання 20 жовтня 2023р.

### КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Видача теми роботи, узгодження і затвердження теми	20.10.2023-25.10.2023	
2	Аналіз проблемної галузі, постановка задачі	25.10.2023-31.10.2023	
3	Вибір інструментальних засобів	01.11.2023-10.11.2023	
4	Аналіз сучасних методів прогнозування відмов КМ та обладнання	11.11.2023-20.11.2023	
5	Розробка програмного інструменту для побудови нейромережі прогнозування	21.11.2023-30.11.2023	
6	Проведення експериментів та аналіз результатів	01.12.2023-25.12.2023	
7	Оформлення пояснювальної записки	26.12.2023-10.01.2024	
8	Перевірка виконаного проекту керівником, допуск до захисту	10.01.2024-26.01.2024	

Студент  Кільчицький Д.В.  
(підпис)

Керівник роботи  доцент Рожнова Т.Г.  
(підпис) (посада, прізвище, ініціали)

## РЕФЕРАТ

Пояснювальна записка містить 68 сторінок, 31 рисунок, 7 таблиць, 21 джерел за переліком посилань

### МЕТОДИ, НЕЙРОННА МЕРЕЖА, КОМП'ЮТЕРНЕ ОБЛАДНАННЯ, ПРОГНОЗУВАННЯ ВІДМОВ, ШТУЧНИЙ ІНТЕЛЕКТ, АЛГОРИТМ.

Роботу присвячено проблемі прогнозування відмов комп'ютерного обладнання на основі виділення та аналізу факторів, що впливають на надійність стану комп'ютерного обладнання та мережі в цілому. Досліджено та проаналізовано методи прогнозу відмов комп'ютерного обладнання, існуючі нейронні мережі, та представлено алгоритми, за якими проводяться навчання нейронної мережі.

Наукова новизна: розробка нейронної мережі, інтегрованої у процес прогнозування відмов комп'ютерного обладнання використовуючи методи прогнозу для підвищення точності та зменшення об'ємів прогнозування експертами.

Практична значимість: завдяки аналізу різних підходів до тренування нейронних мереж, було створено оптимальну архітектуру мережі для прогнозу відмов комп'ютерного обладнання, що забезпечило відносно високу швидкість навчання НМ, і сприятиме ефективності прогнозу відмов.

## ABSTRACT

The explanatory note contains 68 pages, 31 figures, 7 tables, and 21 references from the list of sources.

METHODS, NEURAL NETWORK, COMPUTER HARDWARE, FAILURE PREDICTION, ARTIFICIAL INTELLIGENCE, ALGORITHM

The work is devoted to the problem of predicting computer equipment failures based on the selection and analysis of factors affecting the reliability of computer equipment and the network as a whole. Methods of forecasting computer equipment failures, existing neural networks, and algorithms for neural network training are presented and analyzed

Scientific novelty: the development of a neural network integrated into the process of predicting computer equipment failures using forecasting methods to increase accuracy and reduce the amount of forecasting by experts.

Practical significance: through the analysis of different approaches to training neural networks, an optimal network architecture for computer equipment failure prediction was created, which ensured a relatively high learning rate of NM and will contribute to the effectiveness of failure prediction.

## ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ .....	8
ВСТУП.....	9
1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ПОСТАНОКА ЗАДАЧІ ДОСЛІДЖЕННЯ .....	11
1.1 Постановка задачі дослідження.....	11
1.2 Класифікація станів і відмов КС .....	13
1.3 Показники оцінки станів для діагностування КС .....	15
1.4 Застосування продукційних експертних систем для діагностування компютерних систем.....	22
1.5 Нейронні мережі .....	26
1.6 Оптимальна конфігурація нейронної мережі для прогнозування.....	27
1.7 Архітектури нейронних мереж .....	29
2 ОСНОВНІ МОДЕЛІ ТА МЕТОДИ З ВИКОРИСТАННЯМ ШТУЧНОГО ІНТЕЛЕКТУ .....	35
2.1 Методи інтелектуальних обчислень .....	36
2.2 Апаратні і програмні засоби реалізації алгоритмів нейромереж.....	37
2.3 Класифікація нейронних мереж .....	37
2.4 Активаційна функція і типи функцій .....	40
3 ОСОБЛИВОСТІ ПРОГНОЗУВАННЯ ВІДМОВ ЗА ДОПОМОГОЮ НЕЙРОННОЇ МЕРЕЖІ .....	45
3.1 Формування вектору вхідних параметрів НМ .....	47
3.2 Вектор вхідних параметрів та вагові коефіцієнти .....	47
4 ПРОВЕДЕННЯ ЕКСПЕРИМЕНТІВ ТА АНАЛІЗ РЕЗУЛЬТАТІВ ДОСЛІДЖЕННЯ .....	56
4.1 Програмна реалізація нейронної мережі та дослідження .....	56

4.2	Процес моделювання нейронної мережі .....	60
4.3	Оцінка результатів експериментальних досліджень .....	65
	ВИСНОВКИ.....	66
	ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ.....	67
	ДОДАТОК А Код програмної реалізації нейронної мережі .....	69
	ДОДАТОК Б Графічний матеріал.....	72
	ДОДАТОК В Апробація результатів дослідження .....	81

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ  
І ТЕРМІНІВ

MRT – математичне очікування часу відновлення працездатного стану об'єкта після відмови (англ. Mean Restoration Time);

MTTR – математичне очікування часу відновлення працездатного стану об'єкта після відмови (англ. Mean Time To Repair);

ML – машинне навчання (англ. Machine Learning);

NLP – обробка природної мови (англ. Natural Language Processing);

ГКМ – глобальна комп'ютерна мережа;

ІС – інтелектуальна система;

КС – комп'ютерна система;

КО – комп'ютерне обладнання;

НМ – нейронна мережа;

СКВ – середнє квадратичне відхилення;

СКС – спеціалізовані комп'ютерні системи;

ОД – об'єкт діагностування;

ПС – продукційна система ;

ПДЕС – продукційна діагностична експертна система;

ЕС – експертна система;

ШІ – штучний інтелект.

## ВСТУП

Нейронні мережі є потужним інструментом машинного навчання, що використовується в задачах класифікації, розпізнавання образів, моделювання та прогнозування відмов комп'ютерних систем, це зумовлено зростанням вимог до продуктивності та надійності комп'ютерних систем. Необхідність визначення технічного стану компонентів системи в процесі експлуатації з метою підтримання справності та готовності до застосування, значно зростає в залежності від часу експлуатації спеціалізованої комп'ютерної системи.

З погляду надійності комп'ютерна система є відновлюваним технічним об'єктом, процес функціонування якого можна розглядати як послідовність періодів працездатності і відновлення, простою. Для характеристики надійності технічної системи, що відновлюється, використовують коефіцієнт готовності, який одночасно оцінює властивості працездатності та відновлення об'єкта. Цей показник може бути підвищено за рахунок збільшення надійності технічної системи та зменшення середнього відновлення часу системи.

Незважаючи на високу надійність технічних засобів і високий коефіцієнт готовності, на етапі експлуатації комп'ютерні системи схильні до збоїв у роботі. Відсутність або висока вартість діагностичних програм та апаратних засобів діагностування комп'ютерних систем призводять до ускладнення процесу діагностування.

Таким чином, перспективним напрямом підвищення ефективності використання комп'ютерних систем шляхом підвищення коефіцієнта готовності є застосування інтелектуальних засобів, зокрема експертних систем реального часу, що значною мірою вирішує задачу діагностування комп'ютерних систем та мереж. Центральним питанням побудови експертних систем є вибір форми подання знань. Форма подання знань суттєво впливає на характеристики та властивості експертних систем, тому подання знань є однією з найважливіших проблем, які характерні для експертних систем. Отже

ефективне функціонування СКС передбачає безвідмовну роботу кожної складової системи і комп'ютерної мережі в цілому.

Методи прогнозування відмов комп'ютерних систем пов'язані з аналізом статистичних даних та метриками вірогідності. Іншим можливим альтернативним способом контролю працездатності обладнання КС є використання нейронних мереж [1-3].

За допомогою штучних нейронних мереж (neural networks) можна розв'язати майбутні всі задачі, які розв'язуються іншими методами. Таке концептуальне твердження є насправді підґрунтям того значного інтересу, який спостерігається сьогодні у світі до теорії та практики нейронних мереж.

Отже актуальним завданням є розвиток методів діагностики та прогнозування відмов обладнання КС та мереж, спрямованих на підвищення ефективності процесу прогнозування за рахунок зменшення часових витрат на пошук можливих несправностей.

Тому дослідження методів прогнозу відмов комп'ютерного обладнання з використанням нейронної мережі під час експлуатації КС є актуальною задачею. Метою даного наукового дослідження є бажання отримати об'єктивні дані щодо ефективності різних методів та визначити їхні переваги та обмеження при прогнозуванні відмов. Такий підхід дозволить прискорити та поліпшити процес прогнозування.

Перспективи розвитку включають аналіз інноваційних методів штучного інтелекту разом із традиційними методами прогнозу відмов комп'ютерного обладнання.

Об'єктом дослідження в даній роботі є методи прогнозу відмов комп'ютерного обладнання

Предметом дослідження є аналіз та порівняння різних методів прогнозу відмов комп'ютерного обладнання та процесу тренування нейронної мережі.

Кваліфікаційна робота буде зосереджена на інноваційних підходах до проблематики непередбачених відмов комп'ютерного обладнання, виборі та оптимізації вхідних параметрів при побудові нейронної мережі.

# 1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ПОСТАНОВКА ЗАДАЧІ ДОСЛІДЖЕННЯ

## 1.1 Постановка задачі дослідження

Предметом дослідження є аналіз та порівняння різних методів прогнозу відмов комп'ютерного обладнання та процес тренування нейронної мережі.

В ході роботи будуть проаналізовані проблеми працездатності комп'ютерного обладнання на основі виділення та аналізу факторів, що впливають на надійність стану комп'ютерного обладнання та мережі в цілому, виявлено необхідність прогнозування відмов комп'ютерного обладнання. Досліджено а проаналізовано методи прогнозу відмов комп'ютерного обладнання, розглянуто класифікацію існуючих нейронних мереж, та представлено алгоритми, за якими проводяться навчання нейронної мережі.

Буде виборі та оптимізація вхідних параметрів при побудові нейронної мережі прогнозування відмов обладнання комп'ютерної системи.

Парадигми, які реалізовано у нейронних мережах поряд із сприйняттям та вивченням концептуальних ідей, що вони реалізують, є і проблеми, що супроводжують процеси застосування нейромереж для розв'язання практичних задач.

На користь використання нейромереж свідчать наступні їх властивості:

- наслідування певних механізмів роботи людського мозку;
- можливість універсальної апроксимації будь-яких неперервних залежностей;
- здатність до відновлення інформації під час руйнування або вилученні частини нейромережі;
- паралельна обробка інформації.

До недоліків нейромереж відносять:

- відсутність чіткої теорії та механізмів інтерпретації функціонування і результатів роботи;

- відносно низька швидкість навчання та необхідність розробки додаткових алгоритмів уникнення ступорів, потрапляння у локальні оптимуми та деякий час на перенавчання;

- необхідність вибору та розробки відповідної формалізації для розв'язування задач прогнозування.

Основні завдання дослідження:

- на основі аналізу методів та алгоритмів функціонування НМ сформулювати основні переваги, визначити фактори, що впливають на напрацювання на відмови;

- розрахувати вектори вхідних параметрів для нейронної мережі прогнозування відмов;

- провести аналіз різних підходів до навчання НМ та обрати алгоритм навчання та метод навчання;

- провести експериментальні дослідження на основі програмної моделі при навчанні нейронної мережі з реальними значеннями векторів вхідних параметрів.

Очікувальні результати:

- розроблена нейронної мережа прогнозу відмов комп'ютерного обладнання;

- сформульовані вирази, для опису залежності між параметрами для одного об'єкту дослідження та параметрами об'єктів одного типу при різних умовах ;

- оцінка розробленої нейромережі за показником регресії та середньоквадратичного відхилення за обраним методом.

## 1.2 Класифікація станів і відмов КС

Комп'ютерна система є об'єднання конструктивно та функціонально комп'ютерних засобів для виконання необхідних функцій та має задані умови експлуатації.

Одним із основних засобів підтримки працездатності КС є її діагностика. Основне призначення систем діагностики – скорочення часу простою та ліквідація вузьких місць КС за допомогою автоматичної ідентифікації шкідливих явищ та автоматичної генерації методів їх вирішення. Питання, пов'язані з оцінкою надійності та діагностування КС пов'язано з властивостями системи: безвідмовність, готовність, обслуговуваність, достовірність, функціональна безпека, живучість, цілісність, конфіденційність [1,2].

Під технічним станом КС розуміється сукупність схильних до зміни в процесі виробництва або експлуатації властивостей об'єкта, що характеризуються в певний момент часу ознаками, встановленими технічною документацією на цей об'єкт. Так як КС у більшості випадків працює в безперервному режимі, то вона повинна постійно перебувати у працездатному стані. При цьому одним із основних засобів забезпечення працездатності КС є технічна діагностика, призначенням якої є своєчасне виявлення та локалізація відмов складових КС. У зв'язку з високою технічною складністю КС існує певна ймовірність виникнення відмов у системі. Основна проблема діагностування КС полягає в тому, що КС є симбіозом апаратної та програмної частин, кожна з яких окремо від іншої не має ніякого сенсу і визначити, в якій частині відбулася відмова, це досить складний процес.

Для класифікації функціональних станів та відмов КС розглядається як єдина програмно-апаратна структура. Усі несправності КС та комп'ютерного обладнання, як складової КС, поділяються на апаратні, програмно-апаратні та програмні.

Програмно-апаратні та програмні несправності завжди відбуваються з однією і тією ж частиною комп'ютерної системи – програмним забезпеченням. Їхня різниця лише в характері впливу на роботу КС. Програмно-апаратні несправності впливають працювати через відмову устаткування.

Для КС як одного з видів складного технічного об'єкта характерні такі види технічного стану:

– справний стан. КС виконує всі вимоги нормативно-технічної та конструкторської документації;

– несправний стан. КС не здатна виконувати задані функції;

– працездатний стан. Значення всіх параметрів, що задають функції, відповідають вимогам нормативно-технічної та проектної документації;

– непрацездатний стан. Значення хоча б одного з параметрів, що характеризує здатність КС виконувати задані функції, не відповідає вимогам нормативно-технічної та проектної документації.

Класифікацію можливих видів відмов для програмно-апаратних складових КС представлено у таблиці 1.1.

Таблиця 1.1 – Класифікація відмов КС

Класифікаційна ознака	Вид відмови	Визначення
Область виникнення відмов	Апаратна	Відмова, при якій об'єкт втрачає працездатність і для його відновлення потрібен ремонт апаратури або заміна виробу, що відмовив, на працездатне
	Програмна	Відмова, за якої об'єкт втрачає працездатність через недосконалість програмного забезпечення

## Продовження таблиці 1.1

Характер зміни параметрів в часі до відмови	Миттєва відмова	Відмова, що характеризується стрибкоподібною зміною значень одного або кількох параметрів об'єкта
	Поступова відмова	Відмова, що виникає внаслідок поступової зміни значень одного або кількох параметрів об'єкта
Характер існування відмови у часі	Збій	Самоусувна або одноразова відмова, що усувається втручанням оператора
	Відмова, що перемежується	Відмова одного характеру, що багаторазово виникає самоусувається
	Стійка	Відмова, яка не припиняється до усунення його причини
Змога виявлення відмови	Явна	Відмова, що виявляється візуально або штатними методами та засобами контролю
	Скрита	Відмова, що виявляється під час проведення технічного обслуговування або спеціальними методами діагностики
Обумовленість іншими відмовами	Залежна	Відмова, зумовлена іншими відмовами
	Незалежна	Відмова, не обумовлена іншими відмовами

## 1.3 Показники оцінки станів та діагностування КС

Простої КС обходяться надто дорого, а іноді просто неприпустимі. Комплекс з надійністю п'ять " дев'яток " працює без збоїв 99,999% часу, тобто. за 20 років простоює приблизно 2 години. Перехід від двох "дев'яток" до п'яти дозволяє зберегти майже 90 годин робочого часу на рік.

Однією з найважливіших характеристик надійності КС є безвідмовність властивість об'єкта безперервно зберігати працездатний стан протягом деякого часу або до відмови.

Відмова КС та її складових розглядаємо як подію, що полягає у припиненні здатності об'єкта виконувати необхідну функцію. Оскільки відмови комп'ютерних систем є випадковими подіями, то характеристики з метою оцінки діагностовності КС мають імовірнісний характер, які чисельні значення визначаються і аналізуються статистичними і імовірнісними методами.

Розглянемо основні показники безвідмовної роботи КС та її обладнання:

– середня частота відмов, а  $(t_1, t_2)$  – відношення числа виробів, що відмовили, в одиницю часу до початкового числа виробів, що випробовуються, за умови, що всі вироби, що вийшли з ладу, не відновлюються;

– напрацювання – тривалість або обсяг роботи об'єкта, виміряна в будь-яких незменшувальних величинах;

– середнє напрацювання до першої відмови (MTTF – Mean operating Time To Failure)  $T_{cp} = \int_0^{\infty} P(t) dt$  – математичне очікування напрацювання об'єкта до першої відмови (має сенс тільки для систем, що відновлюються);

– інтенсивність відмов  $\lambda(t) = \frac{1}{P(t)} \frac{dP(t)}{dt}$  – умовна щільність ймовірності виникнення відмови об'єкта, яка визначається за умови, що до моменту часу, що розглядається, відмова не виникла;

– середнє напрацювання на відмову MTBF – Mean operating Time Between Failures,  $T_0 = t / M\{r(t)\}$  – відношення сумарного напрацювання об'єкта, що відновлюється, до математичного очікування числа його відмов протягом цього напрацювання;

– ймовірність безвідмовної роботи  $P(t_{б.р.}) = P\{\tau > t\}$  – ймовірність того, що в межах заданого напрацювання відмова об'єкта не виникне.

Ремонтопридатність є властивістю об'єкта, що полягає у пристосованості до підтримки та відновлення працездатного стану за рахунок технічного обслуговування та ремонту за умови дотримання умов експлуатації об'єкта, а також умов проведення технічного обслуговування та ремонту.

Розглянемо основні показники ремонтпридатності обладнання КС:

– ймовірність відновлення,  $P(tв)$  – ймовірність того, що час відновлення працездатного стану об'єкта не перевищить задане значення;

– середній час ремонту (MRT – Mean Restoration Time) – математичне очікування часу відновлення працездатного стану об'єкта після відмови;

– середній час відновлення (MTTR – Mean Time To Repair) – математичне очікування часу відновлення працездатного стану об'єкта після відмови.

Довговічність – властивість об'єкта зберігати працездатний стан до настання граничного стану при встановленій системі технічного обслуговування та ремонту. Нижче наведено основні показники довговічності КС:

– ресурс – сумарне напрацювання об'єкта від початку його експлуатації або її відновлення до переходу в граничний стан;

– термін служби – календарна тривалість експлуатації від початку експлуатації об'єкта до переходу до граничного стану.

Для загальної характеристики надійності, готовності (доступності) використання та якості обслуговування КС використовуються основні показники експлуатаційної готовності технічних систем.

Експлуатаційна готовність є поєднанням властивостей безвідмовності та ремонтпридатності об'єкта.

У таблиці 1.2 наведено основні показники експлуатаційної готовності.

Таблиця 1.2 – Комплексні показники експлуатаційної готовності

Показник	Умовні позначки	Визначення Определение
Середній коефіцієнт експлуатаційної готовності Можливість виявлення	$\bar{A}(t_1, t_2)$	Усереднена на заданому інтервалі ймовірність того, що об'єкт виявиться працездатним у заданий момент часу, що відраховується від початку роботи
Середній коефіцієнт експлуатаційної неготовності	$\bar{U}(t_1, t_2)$	Усереднена на заданому інтервалі ймовірність, що об'єкт виявиться непрацездатним у заданий момент часу, що від початку роботи
Середня адміністративна перерва у роботі	MAD	Математичне очікування часу, протягом якого об'єкт, будучи у працездатному стані, не експлуатувався з причин адміністративного характеру
Середній час несправного стану	MDT	Математичне очікування часу знаходження об'єкта у несправному стані
Коефіцієнт оперативної готовності $K_{ог}$	$K_{ог} = K_r * P(t_{б.р})$	Ймовірність того, що система опиниться у працездатному стані у довільний момент часу

## Продовження таблиці 1.2

Коефіцієнт готовності $K_r$	$K_r = T_o / (T_o + T_B)$ Наробітка на відмову $T_o$ . Відновлення $T_B$	Імовірність того, що об'єкт опиниться у працездатному стані у довільний момент часу
Коефіцієнт технічного використання $K_{тi}$	$K_{тi} = T_o / (T_o + T_B + T_{пi})$ де $T_{пi}$ – час простою системи	Відношення маточікування інтервалів часу перебування системи у працездатному стані до суми математичних очікувань інтервалів часу простоїв та ремонтів

Наведені у таблиці 1.2 показники для забезпечення технічного обслуговування та ремонту КС – середній час несправного стану (MDT) та середня адміністративна перерва у роботі (MAD) суттєво залежать від рівня підготовки та кваліфікації персоналу КС, тобто. від компетентності користувача та впливають на коефіцієнти готовності  $K_r$ , оперативної готовності  $K_o$  та технічного використання  $K_{тi}$ .

Підвищення надійності КС дозволяє збільшити середнє напрацювання на відмову МТВФ. При цьому здійснюється запобігання несправностям шляхом зниження інтенсивності відмов та збоїв за рахунок застосування електронних схем та компонентів з високим ступенем інтеграції, зниження рівня перешкод, полегшених режимів роботи схем, забезпечення теплових режимів їх роботи, а також за рахунок удосконалення методів збирання апаратури.

Підвищення готовності КС дозволяє зменшити середнє відновлення (ремонт) системи MTTR, тобто. середній час між моментом виявлення несправності та моментом повернення системи до повноцінного функціонування. Одиницею виміру в оцінці ступеня готовності КС є коефіцієнт готовності, який визначає можливість перебування системи у працездатному стані у будь-який довільний час. Статистично коефіцієнт

готовності визначається як  $MTBF/(MTBF+MTTR)$ . Готовність системи іноді розглядають як  $D$  доступність технічної системи.

Процес функціонування КС як технічного об'єкта, що відновлюється, доцільно розглядати як послідовність періодів працездатності  $T_1 \dots T_n$  та відновлення (простою)  $\tau_1 \dots \tau_n$ . При цьому :

$$T = \sum_{i=1}^n T_{p_i} \quad \text{– загальний час знаходження системи у працездатному стані;}$$

$$\tau = \sum_{i=1}^n T_{B_i} \quad \text{– загальний час відновлення КС.}$$

Для об'єкта, що відновлюється, при найпростішому потоці відмов і відновлень коефіцієнт готовності можна представити в такому вигляді:

$$K = \frac{1}{1 + \gamma} ,$$

де  $\gamma = \frac{\tau}{T}$  – показник відновлюваності.

З цього виразу випливає, що  $K$  залежить не від абсолютних значень величин  $T$  і  $\tau$ , а від відношення цих величини, тобто. від  $\gamma$ . Для високонадійних систем ці показники мають значення  $T \gg \tau$  та  $\gamma \ll 1$ .

Для практичних обчислень достатньо використовувати наближене значення  $K \approx 1 - \gamma$ .

Коефіцієнт готовності  $K$  є граничним значенням, якого прагне середній коефіцієнт готовності зі зростанням інтервалу часу

$$K = \lim_{t \rightarrow \infty} K(t) ,$$

де  $K(t)$  – ймовірність того, що в момент часу  $T_i$  КО знаходиться в працездатному стані (при відомих початкових умовах в момент часу  $T_0 = 0$ )

$$K(t) = \frac{1}{T + \tau} \int_0^{\infty} P(t) dt ,$$

де  $P(t)$  – можливість безвідмовної роботи.

На рисунку 1.1 наведено залежність коефіцієнта готовності  $K_r$  від часу.




Рисунок 1.1– Залежності коефіцієнта готовності  $K_r$  від часу  $t$ .

З рисунку видно, що на момент часу  $t=0$  КС починає експлуатуватися справною, причому  $K_r(0) = 1$ . Зі зростанням  $t$   $K_r(t)$  зменшується і коефіцієнт готовності прагне постійної, відмінної від нуля величині (залежність 1). Значення ординати  $K_r(t)$  у довільний час є можливість, що у момент часу  $t$  система справна. До моменту  $t$  вона могла скільки завгодно разів відмовляти і ремонтуватися.

Функція коефіцієнта готовності  $K_r(t)$  може мати вигляд зростаючої чи коливальної залежності. Якщо на початку експлуатації КС має несправні резервні пристрої, то в точці  $K_r(0)$  не дорівнює 1 коефіцієнт готовності має вигляд зростаючої функції. Якщо ж аналіз готовності системи починається з часу, коли система взагалі несправна і ремонтується, то  $K_r(0) = 0$ .

Коливальний процес зміни функції готовності (криві 2,3) спостерігається при обслуговуванні КС з певним видом пріоритету та тривалістю відновлення. Незалежно від виду кривих  $K_r(t)$  фінальна можливість цієї системи завжди

постійна і має одне й те значення, тобто. коефіцієнт готовності залежить від початкового стану КС, з якого починається її експлуатація.

#### 1.4 Застосування продукційних експертних систем для діагностування комп'ютерних систем

Сучасні ЕС – це складні програмні комплекси, що акумулюють знання фахівців у конкретних предметних галузях та розповсюджують цей емпіричний досвід для консультування менш кваліфікованих користувачів.

Мета досліджень з ЕС полягає в розробці програм, які при вирішенні завдань, важких для експерта-людини, отримують результати, що не поступаються за якістю та ефективністю рішенням, які отримують експерти. Дослідники в галузі ЕС для назви своєї дисципліни часто використовують також термін "інженерія знань", запроваджений Е. Фейгенбаумом як «привнесення принципів та інструментарію досліджень із галузі штучного інтелекту у вирішення важких прикладних проблем, що вимагають знань експертів».

За якістю та ефективності рішення ЕС у більшості випадків не поступаються експерту, тому що їх рішення мають «прозорість» і можуть бути пояснені користувачеві на якісному рівні, ця якість ЕС забезпечується їхньою здатністю формувати міркування на основі знань та висновків. ЕС здатні поповнювати свої знання під час взаємодії з експертом. В даний час ЕС використовуються для вирішення різних завдань (інтерпретація, передбачення, діагностика, планування, конструювання, контроль, налагодження, інструктаж, управління) у найрізноманітніших галузях науки та техніки.

Проведем аналіз використання ЕС на вирішення завдань діагностування КС. Системи діагностування КС вирішують завдання виявлення несправностей та причин їх появи. Дані системи співвідносять спостерігаються порушення поведінки систем з причинами, що їх зумовили,

спираючись на один з двох наступних методів. У першому використовується таблиця асоціативних зв'язків між типами поведінки та діагнозами. У другому методі спільне використання знань про структуру системи та про ненадійні місця конструкції або реалізації пристрою або використовуваних деталей дозволяє будувати припущення про несправності, сумісні з даними, що спостерігаються. Важлива специфіка таких завдань – необхідність розуміння структури систем, що діагностуються. Проблема ускладнюється тим, що одні несправності можуть маскуватися іншими. Важливим є те, що діагностичне обладнання може спотворювати реєстровану інформацію.

Нарешті, структура системи, що діагностується, може бути невідома або бути представлена сукупністю не завжди узгоджених приватних моделей. Типова структура ЕС складається із трьох основних компонентів обчислювальних засобів. Перший компонент є виконавчою системою, спроектованою з позицій ефективного вирішення завдань діагностування мережі: планування експерименту та постановки діагнозу. Другий компонент – сукупність засобів інтелектуального інтерфейсу, які мають гнучку структуру, що забезпечує можливість адаптації діагнозу, поставленого ЕС, під кінцевого користувача ). Третім компонентом засобів, за допомогою яких організується взаємодія перших двох, є БЗ забезпечує використання обчислювальними засобами перших двох компонентів системи знань про проблемне середовище (в даному випадку КС).

Інтелектуальний інтерфейс – система програмних і апаратних засобів, які забезпечують кінцевого користувача використанням комп'ютера на вирішення завдань діагностування КС.

БЗ займає центральне становище стосовно решти компонентів ЕС загалом і через БЗ здійснюється інтеграція засобів ЕС, що у вирішенні завдань діагностування [7,8] акумулюють людські знання про виявлення причин аномальної роботи мереж та обладнання, а також можливі способи приведення мережі у працездатний стан. В основному реалізуються у вигляді окремих підсистем різних засобів моніторингу та аналізу мереж: систем управління

мережами, аналізаторів протоколів. Найпростішим варіантом ЕС є контекстно-залежна help-система. Більш складні ЕС є БЗ, що володіють елементами штучного інтелекту.

Прикладом є експертна система аналізу мережі Expert Analysis із сімейства продуктів Distributed Sniffer System [8].

Основне призначення системи – скорочення часу простою та ліквідація вузьких місць мережі за допомогою автоматичної ідентифікації аномальних явищ та автоматичної генерації методів їх вирішення. Система експертного аналізу надає діагностичну інформацію трьох категорій:

1) симптом – подія в мережі, якій адміністратор мережі повинен приділити додаткову увагу (наприклад, фізична помилка при зверненні до вузла мережі або поодинокі повторна передача файлу). Необов'язково означає виникнення часткової втрати працездатності, проте за високого рівня періодичності вимагає уваги адміністратора;

2) діагноз – неодноразове повторення симптому, що вимагає обов'язкового аналізу з боку адміністратора мережі. Зазвичай діагноз описує ситуації, що характеризують серйозні несправності в мережі (наприклад, мережна адреса, що дублюється). На етапі діагнозу відбувається переклад події, що призводить до часткової втрати працездатності мережі, на мову, зрозумілу оператору та адміністратору;

3) пояснення – контекстно-залежне експертне висновок системи аналізу кожному за симптомом чи діагнозом. Пояснення містить опис кількох можливих причин цієї ситуації, обґрунтування такого висновку та рекомендації щодо їх усунення.

В системі є можливості доповнення існуючої БЗ специфічними даними. Система автоматичного аналізу Expert Analysis засновано на унікальній багатозадачній технології аналізу пакетів, яка складається з наступних кроків:

– пакети, що циркулюють у мережі, безперервно захоплюються і поміщаються в кільцевий буфер захоплення (перше завдання);

– одночасно з цим кілька завдань-аналізаторів протоколів (по одному на кожне із сімейств протоколів) сканують буфер захоплення та генерують інформацію в єдиному внутрішньому форматі;

– стандартизована інформація надходить на групу завдань-експертів.

Кожна з цих програм є екпертом лише у своїй вузькій галузі, наприклад, знання протоколу взаємодії клієнта з сервером NetWare.

Існує друга група завдань-експертів, що постійно аналізує стан БД та видає повідомлення про ненормальне функціонування мережі (симптоми або діагнози). Система Expert Analysis оперує з більш ніж 200 різними подіями, що призводять до часткової втрати працездатності мережі. Останній елемент цієї системи – програми-експерти, що генерують докладний опис проблеми та методи її виправлення. При цьому ці експерти сканують БД і підставляють у рекомендації реальні об'єкти мережі - MAC-адреси, назви серверів, імена завдань і т.д.

ЕС, що не відносяться до дорогих систем вищого класу, зазвичай виводять діагноз і його короткий опис, але не наводять подробиць про розглянуті пакети. Діагноз "неправильно маршрутизований пакет" також може некоректно інтерпретуватися користувачем. Аналізатор просто не бачить маршрут для даної IP-адреси, яка не була оголошена маршрутизатором. Можливо, використовується статичний маршрут або разом з RIP-протоколом застосовується протокол маршрутизації за станом зв'язку. В останньому випадку оголошення про маршрут надсилається тільки при його зміні.

Багато ЕС аналізаторів протоколів ставлять діагноз «за єдиною одномоментною подією» або за перевищенням статистичного порога. Про настання подій можна судити за єдиним пакетом з помилкою CRC або містить повідомлення ICMP [7].

Таким чином, найбільш важливою властивістю ЕС є наявність методів та алгоритмів планування діагностичного експерименту як додаткового компонента ЕС діагностування КС, з метою скорочення тимчасових витрат на

процедуру пошуку дефекту, встановлення причин його виникнення та його усунення, а також з метою підвищення достовірності поставленого діагнозу.

### 1.5 Нейронні мережі

Розглядаючи задачі розв'язувані нейронними мережами можна виділити широке коло завдань обробки та аналізу даних – розпізнавання та класифікація образів, прогнозування, управління, кластерний аналіз, апроксимація, нейромережевий стиск даних.

Із різних способів розширення аналітичних можливостей людини найбільш ефективними для дослідження завдань, що не мають загально визнаного алгоритму розв'язання, є використання нейронних мереж, або нейромережевих технологій. Нейромережеві технології не вимагають програмування, а передбачають роботу з навчання нейронної мережі на спеціально підібраних прикладах. Основною функцією навчання нейромережі є впізнавання, вміння визначати схожість і відмінності. На етапі навчання формуються основні відносини між вхідними параметрами і оформляються в незримі таблиці-образи. Ці сформовані таблиці будуть використовуватися для розв'язання задач на НМ.

Нейрон – це закінчений елемент програмного коду, що формує нейронну сітку та, водночас, є базовою одиницею штучного інтелекту, Кожний нейрон сприймає вхідні дані, опрацьовує їх, та передає далі за допомогою синапсу. НМ є комп'ютерною реалізацією мозоку людини. Процеси глобалізації сприяли тому, що з'явилося багато інформації, опрацювати яку самотужки людина фізично не зможе.

Слід сказати ще про поняття нейронна мережа та штучний інтелект, це хоча і схожі, але різні терміни. Нейронні мережі мають модулярну систему, де обчислення виконуються на основі встановлених правил. Система вчиться аналізувати лише конкретні дані та підходить для вирішення тільки однієї чітко сформованої задачі. Добре розвинена та добре навчена, за адекватно

сформульованою задачею, НМ легко замінить штатного аналітика, але лише в межах одного діапазону даних.

Штучний інтелект – це здатність комп'ютера самостійно створювати та навчати нейронні мережі.

Складність вирішення задачі використання нейронної мережі в першу чергу пов'язана з необхідністю побудови адекватної моделі мережі [10]. Проблематика побудови топології нейронної мережі прогнозування пов'язана з необхідністю селекції значимих факторів, які впливають на обладнання в процесі експлуатації. Іншим обмеженням при застосуванні нейронної мережі є необхідність збору і аналізу даних для формування навчальної вибірки.

### 1.6 Оптимальна конфігурація нейронної мережі для прогнозування

При виборі кількості шарів ШНМ та кількості нейронів у прихованих шарах варто керуватись такими правилами:

- максимальна кількість зв'язків у НМ обмежується об'ємом навчальної вибірки;
- збільшена кількість зв'язків між нейронами збільшує можливості НМ до навчання;
- за нормальної швидкості навчання кращою вважається та НМ, яка надає меншу похибку наближення.
- за близьких значень похибки наближення, перевагу слід віддати мережі, яка має коротший час для процесу навчання.
- час, необхідний для навчання мережі пропорційний її складності, це відображено у математичній формі так [4]:

Позначимо  $\vec{a}$  – вектор параметрів мережі таких як кількість шарів та кількість нейронів в цих шарах.

Тоді критерій  $f_1(\vec{a})$  визначає чи нижча похибка наближення за визначений поріг точності і приймає відповідно значення 0 або 1 якщо вона нижча чи вища;  $f_2(\vec{a})$  – похибка наближення, що приймає значення в

діапазоні від 0 до 1,  $f_3(\vec{a})$  – час, необхідний для налаштування мережі;  $w_k$  – відповідні вагові коефіцієнти критеріїв.

Тоді вибір оптимальної конфігурації мережі зводиться до мінімізації :

$$\sum_{k=1}^K f_k(\vec{a}) w_k$$

Для значно ширшого спектру задач прийнято використовувати метод навчання з вчителем. Він полягає в наявності готових даних для навчання. Фактично, нейронна мережа вивчає взаємозв'язок між наборами вхідних даних та достовірно відомими «правильними» виходами, що зветься тренувальною вибіркою, щоб після мінімізації помилки при навчанні, користуватись цими правилами для вирішення задачі на реальних тестових даних.

Мінімізація помилки при навчанні проводиться для отримання бажаної точності. Якщо позначити допустиму помилку як  $e$ , то процес навчання можна буде описати як

$$f(x) - e \leq Y \leq f(x) + e$$

Зазвичай для обчислення помилки використовують формулу суми квадратів відстаней від вихідних сигналів мережі до їх необхідних значень:

$$E = \frac{1}{2} \sum_{i=1}^n (y_i - f(x_i))^2$$

де  $f(x_i)$  – бажане значення вихідного сигналу.

Метод зворотнього розповсюдження помилки – це ітеративний метод навчання за якого задля мінімізації помилки та отримання бажаної точності від виходів мережі назад на вхід поширюється сигнал помилки. Алгоритм

зазвичай застосовують до багатошарового перцептрону у випадку, коли функція активації є диференційованою.

### 1.7 Архітектури нейронних мереж

Правильно обрана архітектура нейронної мережі є одним із факторів її ефективності для вирішення поставленої задачі. Проведемо огляд найпопулярніших архітектур та порівняємо їх сильні та слабкі сторони, розглянемо можливості використання.

Нейронні мережі прямого поширення (FFNN, Feed-Forward Neural Networks) є однією із найпростіших архітектур. Найбільш класичним прикладом таких мереж є повнозв'язні мережі прямого поширення (FNN) на прикладі перцептрона.

Нейрони в кожному окремому шарі перцептрона не мають зв'язків між собою, натомість вони з'єднані із кожним нейроном наступного шару. Сигнал передається від вхідних нейронів до вихідних. Найпростіша модель перцептрона без прихованих шарів зображена на рисунку 1.2.



Рисунок 1.2 – Перцептрон без прихованих шарів

Частіше перцептрони мають хоча б один або два приховані шари, як зображено на рисунку 1.3.




Рисунок 1.3 – Перцептрон із одним прихованим шаром

Якщо в мережі наявно більше одного прихованого шару, то вона вважається глибокою (Deep Neural Network). Глибоку нейронну мережу прямого поширення зображено на рисунку 1.4.




Рисунок 1.4 – Глибока нейронна мережа прямого поширення

Одношарові та багатошарові перцептрони добре підходять для розв'язання багатьох задач класифікації, однак, за всієї простоти архітектури, в них є і недоліки.

Проблема великої кількості параметрів пов'язана з тим, що при подачі на вхід великих об'ємів вхідних даних, особливо у випадку коли мережа має більше одного прихованого шару, може призвести до того, що в нейронній мережі буде неймовірно велика кількість параметрів для обчислення яких знадобиться забагато навчальних прикладів і, навіть якщо знайдеться достатньо тренувальних даних, це може призвести до виникнення проблеми

перенавчання і при роботі із такими великими об'ємами навчальних даних і переході до класифікації в реальних умовах.

Характерною проблемою навчання глибоких нейронних мереж є проблема спадаючих градієнтів, що пов'язана з тим, що при передачі градієнта похибки через усі шари нейронної мережі він сильно зменшується і майже не викликати зміни ваг.

Згорткові нейронні мережі (CNN, Convolutional Neural Network) – вид багатошарових нейронних мереж прямого поширення, що характеризується меншими вимогами до попередньої обробки вхідних даних. Основою згорткових нейронних мереж є згорткові шари що складаються з фільтрів. Згортка передбачає обчислення скалярного добутку даних фільтру та вхідних даних та формуванні карти збудження фільтру.

Згортковий шар нейронної мережі та рецептивне поле зображено на рисунку 1.5.




Рисунок 1.5 – Згортковий шар та рецептивне поле

Окрім згорткових шарів, CNN мають також шари субдискретизації, що зменшують розмірність вхідного сигналу шляхом операції усереднення або знаходження максимуму, а також звичайні повнозв'язні шари багатошарового перцептрону (MLP) для кінцевої класифікації.

Їх перевагою є менша кількість параметрів, необхідних для обробки вхідного сигналу певного розміру, що допомагає полегшити процес навчання

мережі та позбутися проблеми перенавчання. Прикладом застосування згорткових нейронних мереж є класифікація, а також генерація зображень.

Рекурентні нейронні мережі (RNN, Recurrent Neural Networks) – архітектура, що характеризується наявністю циклічних зв'язків від одного нейрона до самого себе, коли вихід одного нейрона прихованого шару далі подається йому ж на вхід (рис. 1.6).




Рисунок 1.6 – Рекурентна нейронна мережа

Головні переваги таких мереж перед звичайними нейронними мережами прямого поширення є можливість враховувати вплив часу, наявності пам'яті, вони також здатні до реалізації будь-якої обчислюваної функції завдяки своїй Тьюринг-повноті вони підходять для роботи з часовими рядами, послідовностями.

При навчанні рекурентної нейронної мережі зазвичай використовується класичний метод зворотнього поширення помилки, але при повторенні циклу декілька разів такі мережі можуть зіштовхнутись із тією ж проблемою спадаючих градієнтів, що і звичайні глибокі нейронні мережі.

Для вирішення такої проблеми існують варіації RNN такі як мережі довгої короткострокової пам'яті (LSTM, Long Short-Term Memory), схему якої зображено на рисунку 1.7.

Мережа Гопфілда (HN, Hopfield Network) – є типом архітектури рекурентних повнозв'язних нейронних мереж, що характеризується симетричною матрицею зв'язків (рис. 1.8). Кожен нейрон в мережі Гопфілда може мати на виході одне із двох значень -1 або 1. Мережа працює за

принципом повернення в положення рівноваги за деяким набором заданих шаблонів. Матриця зв'язків мережі Гопфілда є симетричною, вплив нейронів на себе відсутній (автоасоціативна пам'ять).

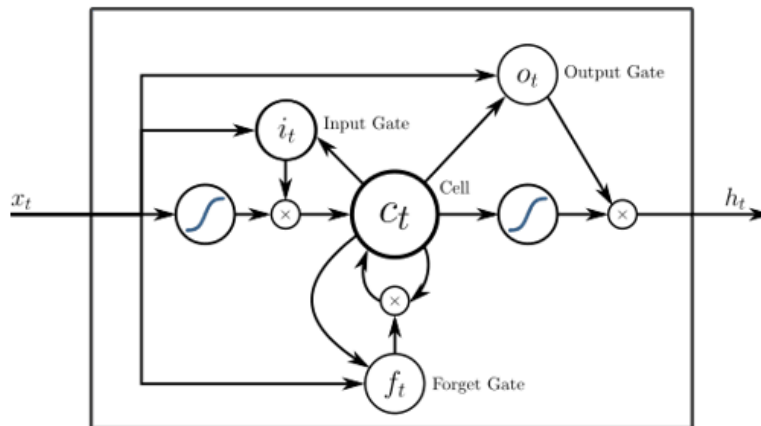


Рисунок 1.7– Схема мережі довгої короткострокової пам'яті



Рисунок 1.8 – Нейронна мережа Го

Радіально-базисні нейронні мережі (рис. 1.9) засновані на використанні радіально-базисних функцій, що характеризуються їх симетричними відгуками відносно певної осі та змінюються монотонно.




Рисунок 1.9 – Радіально-базисна нейронна мережа

Радіально-базисні функції – це функції, значення яких визначається як відстань від деякої точки, вхідного сигналу  $x$ , до початку координат чи певного центру. Типовим прикладом радіально-базисної функції є функція Гауса:

$$y = \alpha e^{-\frac{(x-b)^2}{2\sigma^2}}$$

де  $\alpha$  – коефіцієнт, що характеризує висоту гаусіани,  $b$  – зміщення від початку координат,  $\sigma$  – швидкість спадання

Графік функції Гауса для різних значень параметрів зображено на рисунку 1.10.




Рисунок 1.10 – Графік функції Гауса для різних значень параметрів

Такі мережі, що було розглянуто, характеризуються високою швидкістю навчання та деякою додатковою складністю в навчанні, викликаною необхідністю правильного налаштування параметрів радіально-базисних функцій.

## 2 ОСНОВНІ МОДЕЛІ ТА МЕТОДИ З ВИКОРИСТАННЯМ ШТУЧНОГО ІНТЕЛЕКТУ

Основні моделі і методи технологій обчислень, з використанням штучного інтелекту з методи знаходження знань в інформаційному сховищі

Розглянемо основні види методів, що використовуються для знаходження нового знання на основі даних інформаційного сховища.

Результатом моделювання є виявлення типу відношень у даних. Можна визначити шість методів виявлення та аналізу знань:

- класифікація;
- регресія;
- прогнозування тимчасових послідовностей (рядів);
- кластерізація;
- асоціація,
- послідовність.

Перші три методи використовуються головним чином для прогнозування, останні зручні для опису існуючих закономірностей у даних.

Класифікація – це найпоширеніша модель інтелектуального аналізу даних. За її допомоги виявляються ознаки, що характеризують групу, до якої належить той або інший об'єкт за допомогою аналізу вже класифікованих об'єктів і формулювання деякого набору правил [11,12].

Якщо можна побудувати математичну модель і знайти прототипи, що адекватно відображають цю динаміку, є ймовірність прогнозу поведінки системи в майбутньому.

Кластерізація відрізняється від класифікації тим, що класи заздалегідь не задані і за допомогою моделі кластерізації засобу інтелектуальних обчислень самостійно створюють однорідні групи даних.

Асоціація дозволяє здійснювати аналіз структур і застосовується, коли кілька подій зв'язані між собою (прикладом транзакції) [11,13].

## 2.1 Методи інтелектуальних обчислень

Можна визначити такі методи інтелектуальних обчислень:

- нейроні мережі;
- дерева рішень;
- системи розміркувань на основі аналогічних випадків;
- алгоритми визначення асоціацій і послідовностей;
- нечітка логіка;
- генетичні алгоритми;
- еволюційне програмування;
- візуалізація даних.

Нейроні мережі – це такі системи, що мають архітектуру, використання якої дозволяє умовно імітувати роботу нейронів мозку людини.

Математична модель нейрона представляє собою деякий універсальний нелінійний елемент із можливістю широкої зміни і настроювання його характеристик (параметрів).

Нейроні мережі являють собою сукупність зв'язаних між собою шарів нейронів, що одержують вхідні дані, здійснюють їх обробку і генерують результат, який видають на виході. Між вузлами видимих вхідного і вихідного шарів може знаходитися визначене число схованих шарів. Нейроні мережі реалізують непрозорий процес. Це означає, що побудована модель, як правило, не має чіткої інтерпретації [12,17].

Багато пакетів комп'ютерних програм, що реалізують алгоритми нейронних мереж, застосовуються в сфері обробки комерційної інформації, при розпізнаванні образів, розшифровування рукописного тексту, інтерпретації кардіограм та інше.

## 2.2 Апаратні і програмні засоби реалізації алгоритмів нейромереж

Апаратні і програмні засоби реалізації алгоритмів нейромереж називають нейрокомп'ютером

Нейрокомп'ютери забезпечують використання існуючих методів для розв'язання багатьох оригінальних задач. І неважливо, що спеціалізована обчислювальна машина дозволяє краще вирішувати один клас задач. Важливіше, що один нейрокомп'ютер розв'яже цю задачу і будь яку іншу, і не треба щораз проектувати і створювати спеціалізовану ЕОМ, нейрокомп'ютер зробить усе сам. Замість програмування – навчання. Нейрокомп'ютер навчається, потрібно лише сформулювати навчальні множини. Робота програміста замінюється новою роботою вчителя. Програміст указує машині всі послідовності виконання роботи, а вчитель створює "навчальне середовище", до якого пристосовується нейрокомп'ютер. З'являються нові можливості для роботи [13].

Нейрокомп'ютери ефективні там, де потрібний аналог людського способу мислення інтуїції. Нейронні мережі дозволяють створити ефективне програмне і математичне забезпечення для комп'ютерів з високим ступенем розпаралелювання обробки, обчислень.

## 2.3 Класифікація нейронних мереж

Існують різні варіанти класифікацій НМ із величезною кількістю елементів. Ми в роботі використаємо свій варіант класифікації (рис. 2.1).

Нейронні мережі можна розділити за типами структур нейронів:

- гомогенні (однорідні);
- гетерогенні.

Гомогенні мережі складаються з нейронів одного типу з єдиною функцією активації, а гетерогенну мережу входять нейрони з різними функціями активації.

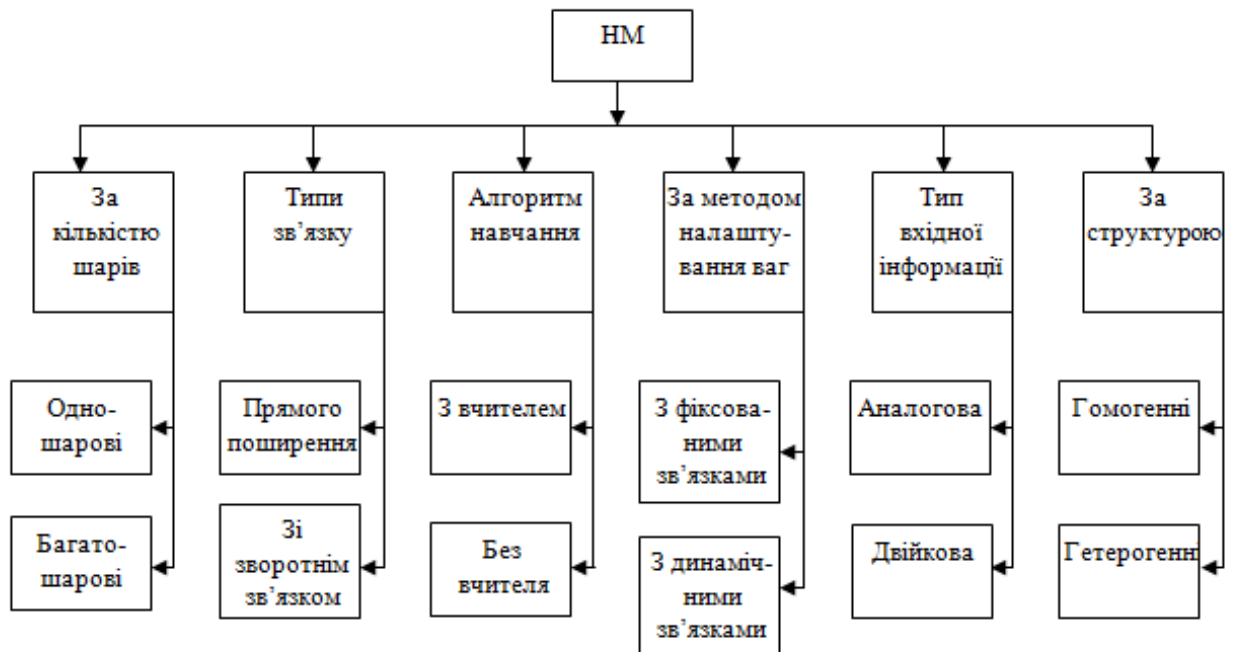


Рисунок 2.1 – Класифікація НМ що використано в роботі

Нейронні мережі поділяються на одношарові та багатошарові:

- в одношарових нейронних мережах сигнали з вхідного шару відразу подаються на вихідний шар. Він проводить необхідні обчислення, результати яких відразу подаються на виходи;

- багатошарові нейронні мережі крім вхідного і вихідного шарів нейронів, характеризуються ще і прихованим шаром (шарами).

За типом зв'язку існують мережі прямого та зворотного поширення:

- мережі прямого поширення – штучні нейронні мережі, в яких сигнал поширюється строго від вхідного шару до вихідного. У зворотному напрямку сигнал не поширюється;

- мережі зі зворотними зв'язками – штучні нейронні мережі, в яких вихід нейрона може знову подаватися на його вхід. У більш загальному випадку це означає можливість поширення сигналу від виходів до входів.

За методом налаштування вагових коефіцієнтів нейронні мережі поділяються на:

– мережі з фіксованими зв'язками – вагові коефіцієнти нейронної мережі вибираються відразу, виходячи з умов задачі;

– мережі з динамічними зв'язками – для них в процесі навчання відбувається налаштування синаптичних ваг.

За типом вхідної інформації НМ розподіляються на :

– мережі з аналоговою вхідною інформацією, де вхідну інформацію представлено у формі дійсних чисел;

– та мережі з двійковою вхідною інформацією де, вся вхідна інформація в таких мережах представляється у вигляді нулів і одиниць.

За алгоритмом навчання існує навчання:

– навчання з вчителем (supervised neural networks), зовнішнє середовище, яке надає навчальні приклади (значення входів та відповідні їм значення виходів) на етапі навчання або оцінює правильність функціонування нейронної мережі та відповідно до своїх критеріїв змінює стан нейронної мережі або заохочує (карає) нейронну мережу, запускаючи тим самим механізм зміни її стану;

– навчання без вчителя (nonsupervised), вид навчання мережі, при якому мережа самостійно класифікує вхідні сигнали та демонструє отримані вихідні сигнали;

– навчання змішане [15,18,19].

Також є різні алгоритми навчання :

– навчання по входам;

навчання по вихідам

При навчанні по входах навчальний приклад є лише вектором вхідних сигналів, а при навчанні по виходах до нього входить і вектор вихідних сигналів, що відповідає вхідному вектору.

За способом пред'явлення прикладів розрізняють: пред'явлення одиночних прикладів та пред'явлення "сторінки" прикладів. У першому випадку зміна стану нейронної мережі (навчання) відбувається після

пред'явлення кожного прикладу. У другому – після пред'явлення "сторінки" (множини) прикладів на основі аналізу відразу усіх прикладів.

На основі аналізу даної класифікації можна зробити висновок, що основою проектування або вибору моделі нейронної мережі для поставленого завдання є:

- структура зв'язків між шарами нейронів,
- вид нейронів (з точки зору передавальної функції),
- правила визначення вагових коефіцієнтів при навчанні нейронної моделі.

Використання нейронних мереж забезпечує такі корисні властивості систем як нелінійність, відображення вхідної у вихідну інформацію, адаптивність, очевидність відповіді, підвищена продуктивність нейромережі; відмовостійкість, одноманітність в проектуванні [10].

Отже прогнозування за допомогою нейронної мережі можливо, коли попередні зміни дійсно дають змогу визначати майбутні. Після навчання мережа здатна передбачити майбутнє значення послідовності подій на основі знання декількох попередніх значень чинників.

#### 2.4 Активаційна функція і типи функцій

Функція активації (активаційна функція, функція збудження) – функція, що обчислює вихідний сигнал штучного нейрона [6].

Існує багато різних активаційних функцій, але частіше за все використовуються наступні такі.

Порогова передатна функція (Функція Хевісайда) є перепадом, або одиничним стрибком (рис. 2.2). Доки зважений сигнал на вході нейрона не досягає певного рівня  $T$  – сигнал на виході дорівнює нулю. Коли сигнал на вході нейрона перевищує вказаний рівень – вихідний сигнал стрибком змінюється на одиницю.

Математичний запис цієї функції виглядає так

$$f(x) = \begin{cases} 1 & \text{if } x \geq T \\ 0 & \text{else} \end{cases},$$

де  $T = -w_0x_0$  – зсув функції активації щодо горизонтальної осі, відповідно під  $x_0$  слід розуміти зважену суму сигналів на входах нейрона без урахування цього слагаємого. Зважаючи на те, що дана функція не є диференційованою на всій осі абсцис, її не можна використовувати в мережах, які навчаються за алгоритмом зворотного розповсюдження помилки та іншими алгоритмами, що потребують диференціювання передавальної функції.




Рисунок 2.2 – Графік функції одиничного стрибка, або порогова функція

При лінійній передавальній функції (рис. 2.5) сигнал на виході нейрона лінійно пов'язаний із виваженою сумою сигналів на його вході

$$f(x) = tx,$$

де  $t$  – параметр функції. У штучних нейронних мережах, із структурою шарами, нейрони з передатними функціями такого типу складають вхідний шар. Також можна використовувати модифікації простої лінійної функції.

Наприклад напівлінійна функція, якщо її аргумент менший за нуль, то вона дорівнює нулю, а в інших випадках, поводитья як лінійна, або

крокова функція (лінійна функція з насиченням), яка відображається формулою:

$$f(x) = \begin{cases} 0 & \text{if } x \leq -0.5 \\ x & \text{if } -0.5 < x < 0.5 \\ 1 & \text{if } x \geq 0.5 \end{cases}$$




Рисунок 2.3 – Кусково-лінійна функція

Сигмоїдальна передатна функція (рис. 2.4) – один із поширених типів передавальних функцій, функція, яка підтримує баланс між лінійною та нелінійною поведінкою. Введення функцій сигмоїдального типу було обумовлено обмеженістю нейронних мереж з граничною функцією активації нейронів – за такої функції активації будь-який з виходів мережі дорівнює або нулю, або одиниці, що обмежує використання мереж не в межах класифікації. Використання сигмоїдальних функцій дозволило перейти від бінарних виходів нейрона до аналогових. Нейрони з такою функцією знаходяться у внутрішніх шарах нейронної мережі [12].




Рисунок 2.4 – Сигмоїдальна функція

Логістичну функцію математично можна виразити як:

$$\sigma(x) = \frac{1}{(1 + \exp(-tx))},$$

де  $t$  – параметр функції, що визначає її крутість. Коли  $t$  прагне нескінченності, функція вироджується в граничну. При сигмоїді вироджується у постійну функцію зі значенням 0,5. Область значень цієї функції перебуває у інтервалі  $(0,1)$ . Важливою перевагою цієї функції є простота її похідної:

$$\frac{d\sigma(x)}{dx} = t f(x)(1 - f(x))$$

Те, що похідна цієї функції може бути виражена через її значення, полегшує використання цієї функції при навчанні мережі за алгоритмом зворотного розповсюдження. Особливістю нейронів з такою передатною характеристикою є те, що вони посилюють сильні сигнали істотно менше, ніж слабкі, оскільки області сильних сигналів відповідають пологим ділянкам характеристики, що дозволяє запобігти насиченню великих сигналів.

Використання функції гіперболічного тангенсу відрізняється від розглянутої вище логістичної кривої тим, що область значень лежить в інтервалі  $(-1;1)$ . Обидва графіки відрізняються лише масштабом вісей. Похідна гіперболічного тангенсу, зрозуміло, також виражається квадратичною функцією значення.

Радіально-базисна функція передачі приймає як аргумент відстань між вхідним вектором і деяким наперед заданим центром активаційної функції. Значення цієї функції тим вище, чим ближче вхідний вектор до центру [3]. Мережі з нейронами, які використовують такі функції, називаються RBF-мережами.

У реальних мережах активаційна функція нейронів може відображати розподіл ймовірності будь-якої випадкової величини, або позначати будь-які евристичні залежності між величинами.

### 3 ОСОБЛИВОСТІ ПРОГНОЗУВАННЯ ВІДМОВ ЗА ДОПОМОГОЮ НЕЙРОННОЇ МЕРЕЖІ

З врахуванням нейронної теорії щодо функцій нервових клітин, ми отримуємо розуміння структури і функцій нейронів. Нейрони з'єднуються через синаптичні контакти, утворюючи специфічно організовані нейронні ланцюги та центри, які утворюють різні функціональні системи мозку. Кількість синаптичних контактів між нейронами людини наближається до числа  $10^{15}$ - $10^{16}$ , а сама кількість нейронів досягає  $5\text{-}9 \times 10^{11}$  [10,11].

Нейронна мережа - це сукупність елементів, які пов'язані між собою та зовнішнім середовищем зв'язками, що характеризуються ваговими коефіцієнтами. (рис. 3.1) .




Рисунок 3.1 – Загальний вигляд нейронної мережі

У кожного з нейронів існують два основних параметри: вхідні та вихідні дані. У випадку вхідного нейрона вхідна інформація дорівнює вихідній. У інших випадках вхідна інформація дорівнює сумарній інформації всіх нейронів з попереднього шару, після чого вона нормалізується за допомогою функції активації та перетворюється у вихідну. [13,14].

На рисунку 3.2 показано схему моделі нейрона, а також на схемі виділено три основні елементи нейрона.




Рисунок 3.2 – Схема моделі нейрона

На моделі нейрона (рис. 3.2), можливо виділити три основні елементи [15]:

1) синапс (від грецького *synapsis* - з'єднання) - це структура, яка дозволяє нейрону (нервовій клітині) проводити електричний або хімічний сигнал в іншу клітину (нервову, м'язову та ін.). Це зв'язок між двома нейронами. У синапсів є єдиний параметр - вага. Завдяки вазі вхідна інформація змінюється, коли передається від одного нейрона до іншого.;

2) суматор - це механізм, який об'єднує вхідні сигнали, зважені відповідно до ваги синапсів нейрона;

3) функція активації – це спосіб нормалізації вхідних даних. Це означає, що якщо на вході буде велика кількість, після проходження через функцію активації отримаємо вихід у потрібному діапазоні.

Додатково, ця модель може включати пороговий елемент, який контролює збільшення або зменшення вхідного сигналу. Кожен нейрон характеризується своїм поточним станом, який може бути збудженим або загальмованим.

### 3.1 Формування вектору вхідних параметрів НМ

Для побудови адекватної моделі нейронної мережі розглянемо фактори, що впливають на комп'ютерне обладнання (КО) комп'ютерної системи [19] та наведемо їх в таблиці 3.1.

Таблиця 3.1 – Фактори, що впливають на КО

Експлуатаційні фактори	
Умови використання	Інтенсивність використання
	Частота включень
	Вібраці
Якість експлуатації	Помилки при експлуатації
	Порушення об'єму експлуатації
	Порушення об'єму профілактики
Умови експлуатації	Атмосферний тиск
	Температура
	Вологість

Фактори, що впливають на комп'ютерне обладнання, можна розділити на два класи: об'єктивні і суб'єктивні.

Серед суб'єктивних факторів можна віднести кваліфікацію персоналу для обслуговування КО, технічне обслуговування КО, служби збору і аналізу відомостей про надійність, служби ремонту і постачання комплектуючими, організацію даних та їх зберігання.

До об'єктивних факторів можна віднести вплив зовнішнього середовища (температура, вологість, тиск), механічні, електричні навантаження, перехідні процеси, біологічне середовище, хімічні процеси.

Отже, з причин і характеру впливу на комп'ютерну техніку та експлуатаційних факторів можна умовно розділити їх на дві групи: фактори, обумовлені якістю експлуатації ІТС, та фактори, обумовлені характером і особливостями розташування обладнання, впливом природних умов.

### 3.2 Вектор вхідних параметрів та вагові коефіцієнти

Існує декілька підходів до аналізу проблем, що виникають під час експлуатації комп'ютерного обладнання (КО) і пов'язані з прийняттям рішень

в умовах недостатньо достовірних даних. Розглядається ситуація, коли КО перебуває в одному з декількох станів, при цьому два крайні стани - "відновлення технічної справності" та "відмова". Між ними існує ряд проміжних станів, які відображають різну ступінь погіршення характеристик обладнання. Для визначення векторів вхідних параметрів розглядаються критерії вибору параметрів вхідного кроку, такі як ступінь впливу на працездатність, можливість адекватного розрахунку та вимірюваність.

Розглядається цикл працездатності об'єкта А від моменту  $Q_0$  початку експлуатації до моменту  $Q_n$  — зміни технічного стану в результаті  $n$ -ої відмови (рис. 3.3).




Рисунок 3.3 – Життєвий цикл об'єкта А

У цьому циклі є такі етапи :

$Q_0$  – момент початку життєвого циклу об'єкту;

$Q_1$  – момент часу, коли було змінено стан об'єкту із робочого в неробочий;

$R_n$  – напрацювання об'єкта між моментом циклу  $Q_{n-1}$  та моментом  $Q_n$ ,  $n = \overline{1; N}$ ;

$Q_n$ , – момент часу у який відбувалися  $n$ -ні відмови.

Для прогнозування відмов за допомогою НМ, визначаємо вектор вхідних параметрів.

Напрацювання від моменту відновлення  $R_n$  за час роботи на проміжку від  $Q_{n-1}$  до  $Q_n$ , можна визначити за виразом:

$$R_n = Q_n - Q_{n-1}$$

де  $Q_n, Q_{n-1}$  – моменти часу, коли відбулася зміна стану об'єкту.

Розглянемо напрацювання між моментами життєвого циклу об'єкта  $R_n$  що розраховується за допомогою лічильників, або застосовується єдина методика визначення напрацювання за період часу, напрацювання  $R_n$  об'єкта складається з двох показників:

- робота, яка відбувається під час технічного обслуговування;
- робота при виконанні обчислень;

Та напрацювання  $R_n$  визначається за формулою :

$$R_n = t_{ПП} + t_{РП}$$

де  $t_{ПП}$  – час напрацювання в період технічного обслуговування;

$t_{РП}$  – час роботи при виконанні обчислень на відмову.

Час напрацювання в період технічного обслуговування  $t_{ПП}$  розраховується за допомогою виразу:

$$t_{ПП} = t_{ППП} + t_{ПВ} + t_{РР} ,$$

де  $t_{ППП}$  – час напрацювання об'єкта у період перед технічним обслуговуванням;

$t_{ПВ}$  – час напрацювання об'єкта у період підготовки повторного виконання обчислень ;

$t_{РР}$  – час напрацювання у період проведення регламентних робіт.

Зовнішні впливи проявляються тим значніше, чим довший час знаходження комп'ютерного обладнання в експлуатації. Цей фактор прийнято оцінювати календарним терміном експлуатації.

Припускаємо, що на двох однакових виробках, та мають однакові показники за умовою експлуатації, відмова не відбудеться одночасно (ймовірність такої відмови є мінімальною).

Таким чином за один і той же період експлуатації на них впливають різні умови використання і відбувається різна кількість відмов. Загальне напрацювання  $R_{com}$  до відмови відображає сумарне напрацювання об'єкту від початку експлуатації до моменту відмови та визначається за формулою

$$R_{com} = \sum_{n=1}^N R_n = \sum_{n=1}^N Q_n - Q_{n-1}.$$

Визначимо загальну кількість  $W_{com}$  циклів включення-вимикання. Розглянемо складові для розрахунку за формулою 3.5 загальної кількості  $W_{com}$  включень-вимикань за час проведення ТО та експлуатації в період проведення обчислень за календарний термін  $K_n$ :

$$W_{com} = \sum_{n=1}^N w_n = w_{PP} + w_{ПП} + w_{ППлП} + w_{ПллП} + w_{ПовтВ} + w_{пол}$$

де  $w_{PP}$  – кількість циклів включення-вимикань під час регламентних робіт;

$w_{ПП}$  – кількість циклів включення-вимикань під час попередньої підготовки;

$w_{ППлП}$  – кількість циклів включення-вимикань під час планової перед обчислювальної підготовки;

$w_{ПовтВ}$  – кількість циклів включення-вимикань під час підготовки до повторного обчислення;

$w_{ПллП}$  – кількість циклів включення-вимикань після обчислювальної підготовки;

$w_{пол}$  – кількість циклів включення-вимикань за час виконання обчислення.

Як бачимо загальну кількість циклів включень-виключень важко визначити без даних про напрацювання за календарний час  $K_n$ , що також є вектором вхідних параметрів

На працездатність об'єкта  $A$  впливає його календарний час  $K_n$ , що розраховується від моменту справності об'єкту  $Q_{n-1}$  та моменту часу  $Q_n$  зміни технічного стану, ( $n = \overline{1; N}$ ). Календарний час напрацювання  $K_n$  розраховується за формулою:

$$K_n = \sum k_n^{нч} - \sum k_n^{нпр} - \sum k_n^{роб}$$

де  $k_n^{нч}$  – час роботи обладнання, дорівнює календарному, що становить 365 днів;

$k_n^{нпр}$  – нормативні простой обладнання,

$k_n^{роб}$  – планові ремонтні роботи на цьому обладнанні.

Інтенсивність відмов  $I$ . Збільшення інтенсивності відмов  $I$  пояснюється незворотними змінами параметрів і характеристик елементів. Інтенсивність відмов  $I$  можна визначити за формулою:

$$I = \frac{\sum R_{com}}{\sum J_n},$$

де  $R_{com}$  – загальне напрацювання об'єкта;

$J_n$  – загальна кількість відмов.

Індекс псування  $A_{пс}$ . До факторів, що впливають на відмови також потрібно віднести кліматичні впливи (температура вологість навколишнього

середовища, атмосферний тиск), що становлять так званий індекс псування  $A_{пс}$ .

Фактори навколишнього середовища сприяють хімічній ерозії металів, деградації і руйнуванню структури матеріалу, корозії, пошкодженню електричних частин комп'ютерного обладнання [11,13].

У таблиці 3.2 наведено показники нормальних умов експлуатації комп'ютерного обладнання.

Таблиця 3.2 – Показники нормальних умов експлуатації КО

Показник, одиниця виміру	Значення показника
Температура навколишнього середовища, °С	+10...+35
Відносна вологість повітря, %	80
Тиск, мм рт.ст	630...800
Запиленість, мг/м <sup>3</sup>	0,75
Напруга живлення, В / частота живлення, Гц	220 ± 10% / 50-60.

Індекс псування комп'ютерного обладнання визначається за формулою

$$A_{пс} \in [1,2,3,4,5]$$

На якість експлуатації КО впливає також фактор помилки в експлуатації.

До параметрів якості обслуговування обладнання можна віднести:

- кваліфікація інженерно-технічного складу;
- укомплектованість КО.

Коефіцієнт  $T_y$  укомплектованості ІТС визначається за формулою:

$$T_y = \frac{S}{V},$$

де  $S$  – штатна кількість спеціалістів для обслуговування;

$V$  – фактична кількість спеціалістів.

Розглянемо кваліфікацію (клас) особового інженерного складу та зазначимо вагові коефіцієнти  $H \in [1,2,3,4,5]$  (табл. 3.3), визначивши середню класність  $H$  фахівців ІТС за формулою:

$$H = \frac{\sum_{i=1}^Z X_i}{Z}$$

де  $X_i$  – ваговий коефіцієнт  $i$ -го фахівця ІТС,  $i = \overline{1; Z}$ ;

$Z$  – загальна кількість фахівців.

Стан комп'ютерного обладнання КС безпосередньо залежить від умов експлуатації. Тому варто розглядати умови експлуатації (місце розташування) комп'ютерного обладнання та зазначити вагові коефіцієнти  $M \in [1,2,3]$  (табл. 3.3).

На особливості роботи того, чи іншого обладнання впливають вібрації, перехідні процеси, тому використовують ваговий коефіцієнт  $L_p$ , що характеризує роботу електронних елементів на різних типах компютерного обладнання :

$$L_p \in [1,2,3,4,5,6,7,8,9,10].$$

Для прогнозування відмов необхідно визначити вектор вхідних параметрів для нейронної мережі, наступним етапом проводимо моделювання нейронної мережі.

Для моделювання нейронної мережі зручно представити вектор вхідних параметрів у вигляді загальної таблиці параметрів та їх вагових коефіцієнтів (таблиця 3.4).

Таблиця 3.3 – Кваліфікація ІТС та умови експлуатації КО

	Параметр	Ваговий коефіцієнт
Клас	Ведучій ІТС	5
	ІТС 1 клас	4
	ІТС 2 клас	3
	ІТС 3 клас	2
	ІТС технік	1
Умови експлуатації КО	Відкрита площадка	1
	Приміщення без утеплення	2
	Приміщення утеплене	3

Таблиця 3.4 – Вектори вхідних параметрів та вагові коефіцієнти

Умови використання	
Вхідний параметр	Ваговий коефіцієнт
Напрацювання від моменту відновлення $R_n$ за час роботи на проміжку від $Q_{n-1}$ до $Q_n$	$R_n = Q_n - Q_{n-1}$
Загальне напрацювання до відмови, $R_{com}$	$R_{com} = \sum_{n=1}^N R_n = \sum_{n=1}^N Q_n - Q_{n-1}$
Загальна кількість циклів включення-вимикання, $W_{com}$	$W_{com} = \sum_{n=1}^N w_n = w_{PP} + w_{ПП} + w_{ПлП} + w_{ПлПл} + w_{ПовтВ} + w_{пол}$
Календарний час, $K_n$	$K_n = \sum k_n^{nc} - \sum k_n^{mp} - \sum k_n^{pob}$
Інтенсивність відмов, $I$	$I = \frac{\sum R_{com}}{\sum J_n}$
Якість експлуатації	
Укомплектованість ІТС, $T_y$	$T_y = \frac{S}{V}$
Кваліфікація ІТС, $H$	$H = \frac{\sum_{i=1}^Z X}{Z}$ , $H \in [1,2,3,4,5]$

Умови експлуатації	
Індекс псування , $A_{nc}$	$A_{nc} \in [1,2,3,4]$
Умови зберігання, $M$ (місце розташування )	$M \in [1,2,3]$
Робота електронних елементів на різних типах КО, $L_p$	$L_p \in [1,2,3,4,5,6,7,8,9,10]$

## 4 ПРОВЕДЕННЯ ЕКСПЕРИМЕНТІВ ТА АНАЛІЗ РЕЗУЛЬТАТІВ ДОСЛІДЖЕННЯ

У рамках дослідження для формування вектору вхідних параметрів при побудові і використанні нейронної мережі прогнозування відмов було обрано наступних показників роботи обладнання:

- 1) загальний час напрацювання, що збір даних про загальне напрацювання системи та її окремих компонентів, вимірюється у одиницях часу;
- 2) час напрацювання системи після заміни або відновлення окремих елементів, збір напрацювання для кожного окремого елемента;
- 3) кількість циклів включення-вимикання обладнання та циклів зміни станів, передбачає використання спеціально розробленого програмного забезпечення, та пов'язана з появою перехідних процесів в електричних колах та напівпровідниках в результаті включення або вимикання;
- 4) коефіцієнт циклічності відмов, отримання коефіцієнту передбачає проведення аналізу спектральної щільності та періодичності відмов обладнання;
- 5) кількість компонентів системи з різними ваговими коефіцієнтами [20,21].

### 4.1 Програмна реалізація нейронної мережі та дослідження

Процес навчання НМ, проведення досліджень, оцінок результатів відбувається за допомогою програмної реалізації нейронної мережі НМ на мові C+.

Етапи процесу навчання нейронної мережі з вхідними та вихідними даними для кожного етапу, що були розглянуті раніше в роботі представлено на рисунку 4.1

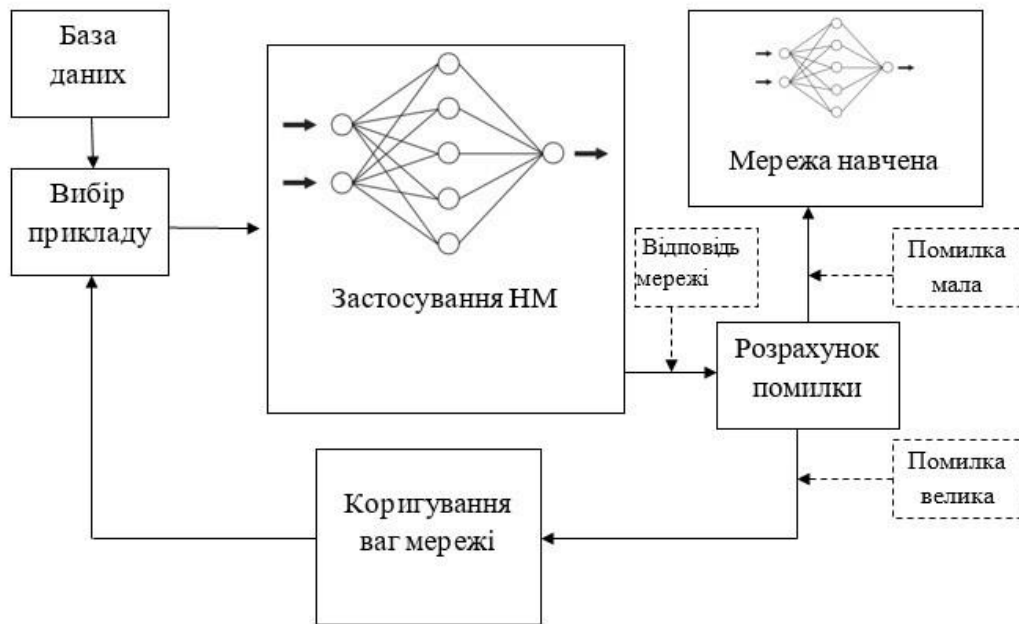


Рисунок 4.1 – Схема процесу навчання НМ

На основі аналізу вектору вхідних параметрів, можемо розпочати побудову та навчання НМ в програмному середовищі MatLab, з використанням функції пакета Neural Networks Toolbox.

Neural Networks Toolbox пакет прикладних програм, що містять все необхідне для побудови нейронних мереж, що базуються на поведінці математичного аналога нейрона, забезпечує ефективну підтримку проектування, навчання та моделювання і дослідження.

Для визначення кращого результату застосовується декілька методів навчання НМ та обрається один, що забезпечує виконання певних факторів.

Сформулюємо фактори до реалізації методу:

- ємність;
- складність зразків;
- обчислювальна складність.

Ємність показує, скільки зразків може запам'ятати мережа, і які межі прийняття рішень можуть бути на ній сформовано.

Складність зразків визначає кількість навчальних прикладів, необхідних для досягнення здатності мережі до узагальнення.

Обчислювальна складність напряму пов'язана з потужністю комп'ютера. Серед великої кількості алгоритмів навчання НМ, найбільш широко застосовують наступні алгоритми:

- алгоритм Левенберга-Марквардта;
- алгоритм Байєсовської лінійної регресії;
- алгоритм сполучених градієнтів;
- алгоритм зворотнього поширення;
- алгоритм навчання Кохонена.

В роботі було розглянуто декілька із них, перші три, що є найбільш поширеними та найчастіше використовуються у середовищі MatLab [16].

НМ з методом навчання на основі алгоритма Левенберга-Марквардта, що також відомий як метод пошуку найменших квадратів [9].

Діаграму станів для процесу навчання нейронної мережі з використанням методу алгоритму Левенберга-Марквардта показано на рисунку 4.2.

За допомогою методу за алгоритмом Левенберга-Марквардта при кількості прихованих шарів 10, отримано такі результати після моделювання у програмі MatLab:

- СКВ=96,681
- регресія = 0,106.

Отже, алгоритм Левенберга-Марквардта є методом, адаптованим для функцій типу суми квадратів помилок, що робить його дуже швидким при навчанні нейронних мереж на такому роді помилки [10,12, 13].

Метод байєсових мереж дозволяє враховувати та використовувати будь-які вхідні дані [10].

Діаграму станів для процесу навчання нейронної мережі з використанням методу алгоритму Байєсівської лінійної регресії показано на рисунку 4.3.

За допомогою методу за алгоритмом Байєсівської лінійної регресії, отримано такі результати після моделювання у програмі MatLab – СКВ=147,888 та регресія– 0,287 .

Мережі Байєса є високоресурсним методом, який забезпечує можливість достатньо точного опису їх функціонування, оцінювання прогнозів та використовується для системи управління процесом.

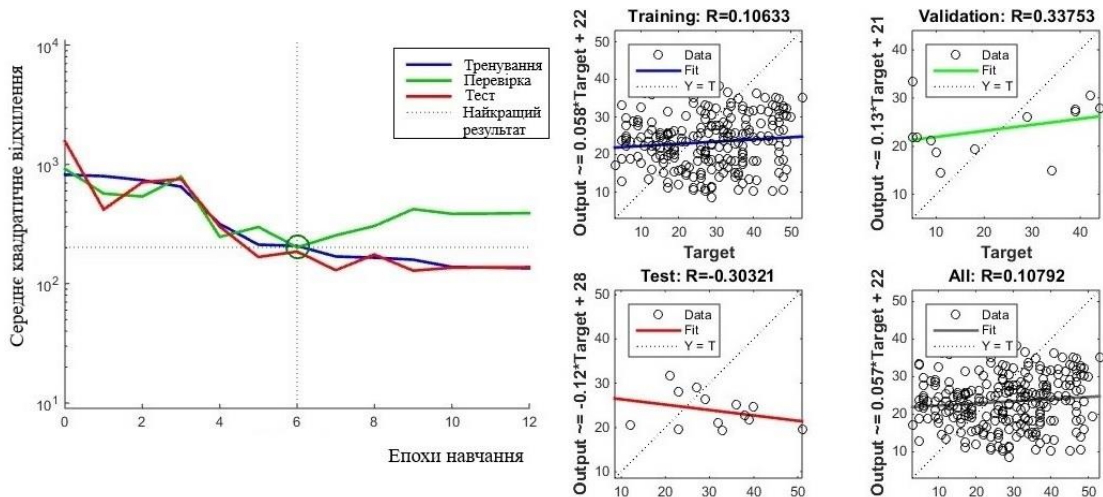


Рисунок 4.2 – НМ з методом навчання на основі алгоритму Левенберга-Марквардта

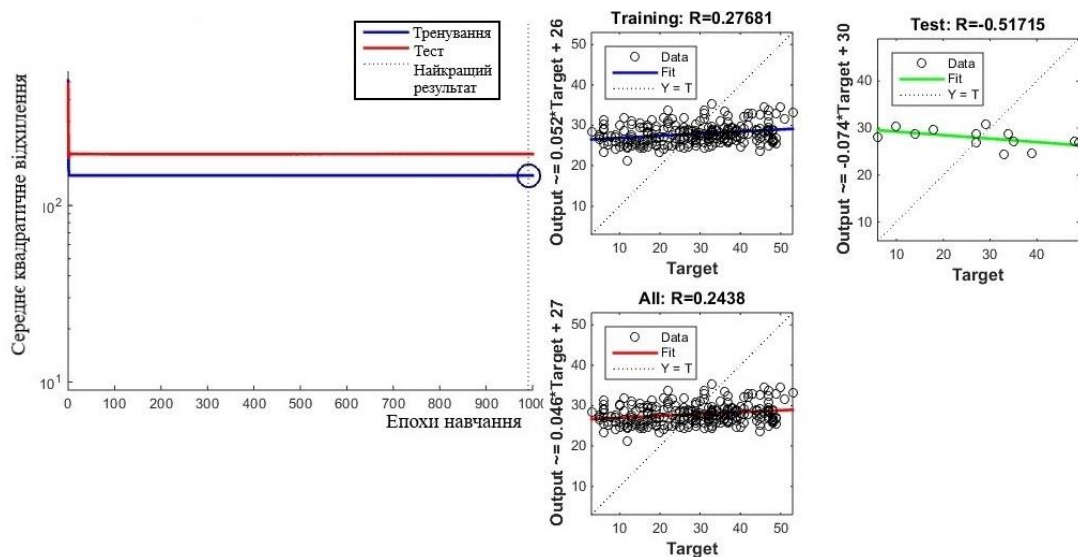


Рисунок 4.3 – НМ з методом навчання на основі алгоритму Байєсівської лінійної регресії

Метод сполучених градієнтів можна використовувати для усунення жорстких вимог до інформації, що пов'язані з оцінкою та зберіганням її у системі [10, 13].

Діаграму станів для процесу навчання нейронної мережі з використанням методу сполучених градієнтів показано на рисунку 4.4. НМ має 10 прихованих шарів та за допомогою методу сполучених градієнтів отримано такі результати після моделювання у програмі MatLab – СКВ=162,441 та регресія=0,195 .

Метод сполучених градієнтів можна рекомендувати для використання, у випадку дуже великих нейронних мереж.

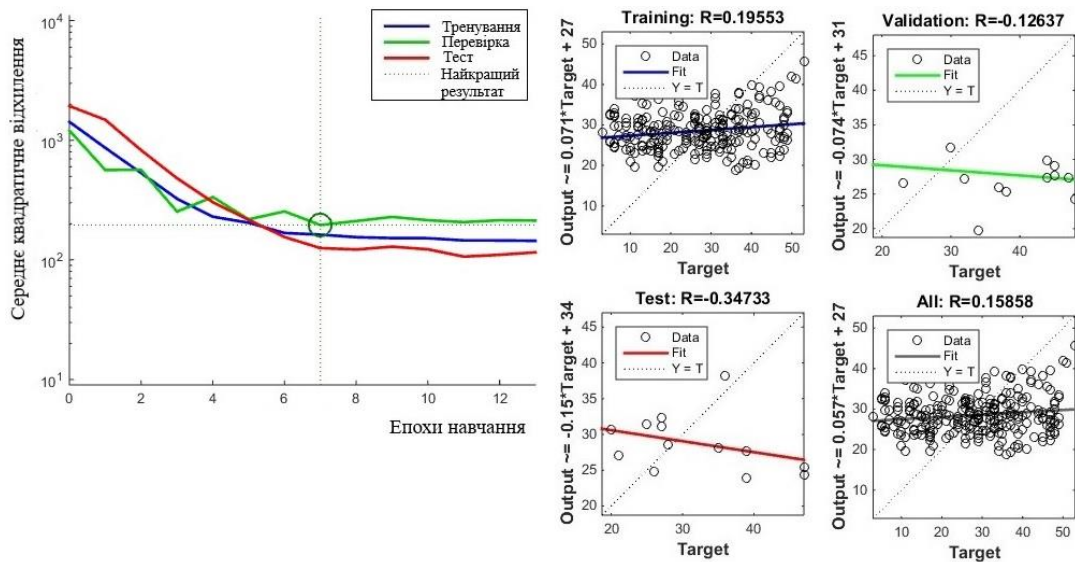


Рисунок 4.4 – Навчання методом сполучених градієнтів

## 4.2 Процес моделювання нейронної мережі

Побудуємо модель нейронної мережі за обраним методом Левенберга-Марквардта та розглянемо загальний вигляд схеми такої нейронної мережі (рис.4.5) у середовищі MatLab [16].

Схема складається з :

– блоку нейронної мережі прогнозування відмов;

- блоку вектору значень вхідних параметрів, що є умовно визначеними, блок розміщено на вході схеми;
- блоку спрогнозованого напрацювання.

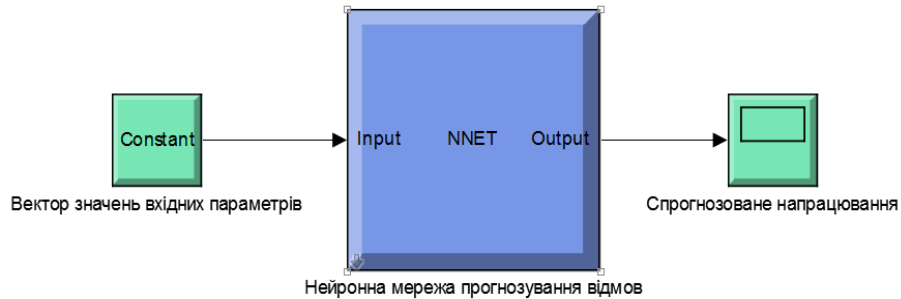


Рисунок 4.5 – Структура НМ в Matlab

До блоку нейронної мережі прогнозування відмов входить схема самої НМ, до складу якої входять такі блоки (рис.4.6):

- вхідні дані,
- первинна обробка,
- 1-й шар,
- вихідний шар НМ,
- вторинна обробка та результат.




Рисунок 4.6 – Схема нейронної мережі блока прогнозування

Первинна обробка вхідних даних, відбувається за схемою, що показано на рисунку 4.7. Вхідні дані після первинної обробки потрапляють у 1-й шар, що складається з вхідних даних, затримки, нейронів, суми нейронів з певними значеннями  $b\{1\}$ , функції активації та вихідних даних (рис. 4.8).

Наступною схемою, що реалізовано є функція активації для нормалізації вхідних значень, до її складу входять експоненти та математичні операції (рис. 4.9).




Рисунок 4.7 – Первинна обробка




Рисунок 4.8 – 1-й шар НМ




Рисунок 4.9 – Функція активації

Навчання нейронної мережі проводиться на наборі вхідних параметрів. Результат такого моделювання за допомогою програмного пакету Neural Networks toolbox у середовищі Simulink Matlab показано на рисунку 4.10.

Вікно налаштування у середовищі Simulink Matlab для навчання мережі показано на рисунку 4.11.

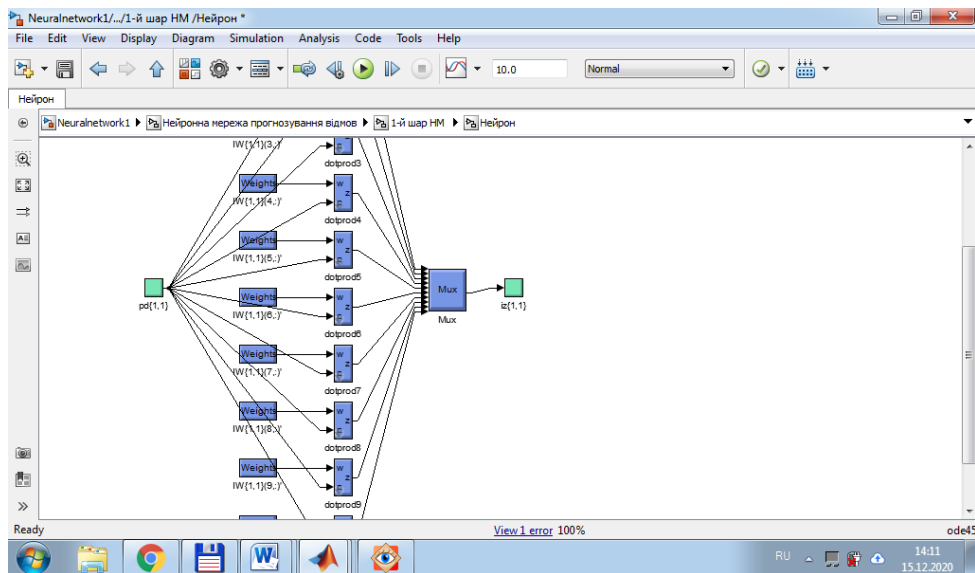


Рисунок 4.10– Результат моделювання робочої нейронної мережі

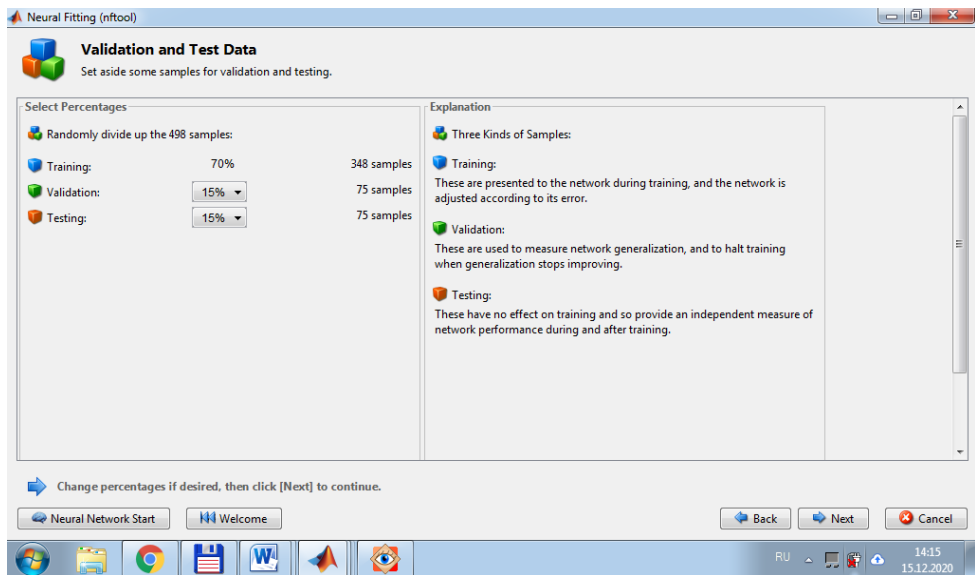


Рисунок 4.11 – Вікно налаштування для навчання мережі

Схему з'єднання шарів нейромережі: вхід– прихований – вихідний – вихід нейронної мережі та процес тренування нейромережі для прогнозу відмов показано на рисунках 4.12 та 4.13.

Рисунок 4.14 показує графік розподілу значень градієнту зміни вагових коефіцієнтів для ітерацій навчання кількістю 200, у залежності від змін умов навчання.

Код програмної реалізації нейронної мережі на мові програмування C++ наведено в додатку А кваліфікаційної роботи.

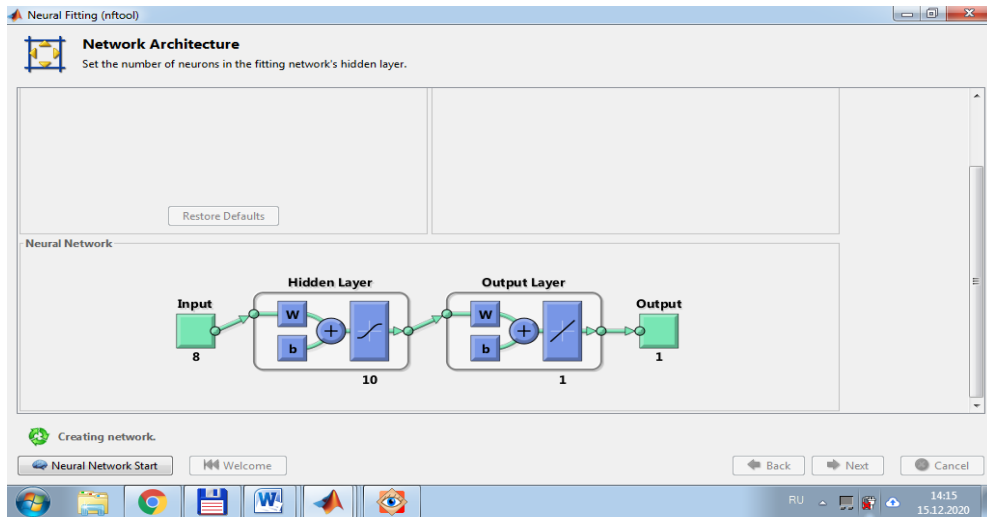


Рисунок 4.12 – Архитектура НМ

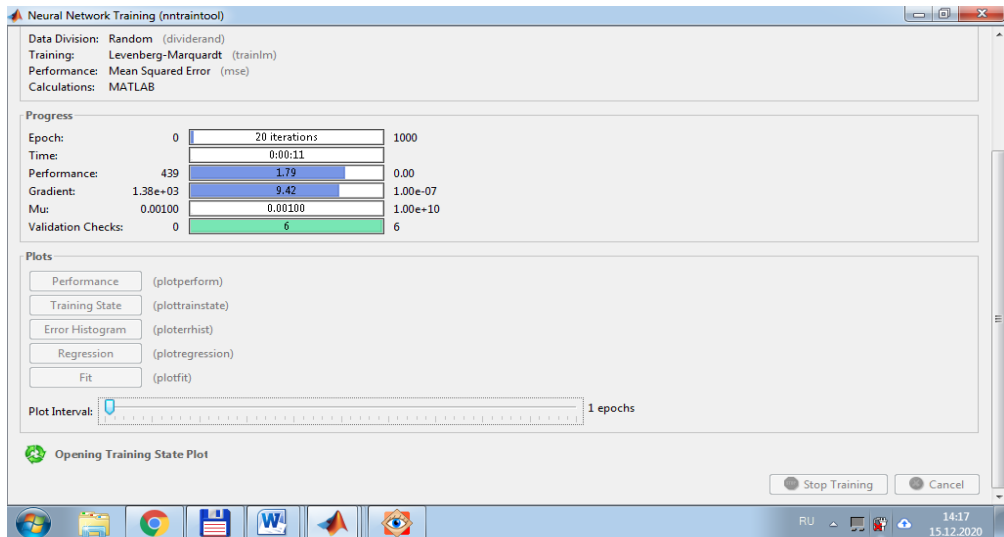


Рисунок 4.13 – Процес тренування нейронної мережі

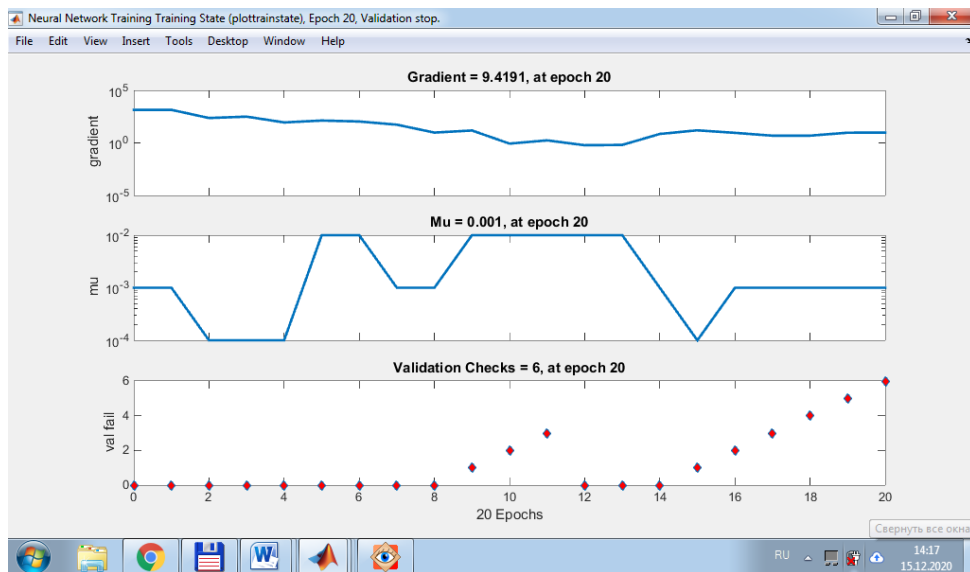


Рисунок 4.14 – Графік залежності зміни умов навчання від ітерації навчання

### 4.3 Оцінка результатів експериментальних досліджень

Для наглядності результатів експериментальних досліджень зведемо їх в одну таблицю 4.1.

Таблиця 4.1 – Порівняння результатів моделювання нейронної мережі

Алгоритм	Кількість прихованих шарів	Середнє квадратичне відхилення	Регресія
Левенберга-Марквардта	10	96,681	0,106
Байєсівська лінійна регресія	10	147,888	0,287
Метод сполучених градієнтів	10	162,441	0,195

Порівняння результатів моделювання, наочно показує, що навчання за алгоритмом Левенберга-Марквардта надає найменшу похибку при кількості прихованих шарів 10 та значеннях СКВ і показнику регресії є найменшими серед розглянутих методів. Це означає, що алгоритм Левенберга-Марквардта є методом адаптованим для функцій типу суми квадратів помилок, що робить його дуже швидким, порівняно з іншими, при навчанні нейронних мереж. Та серед розглянутих методів навчання він є найбільш ефективним для прогнозування відмов комп'ютерного обладнання з використанням нейронної мережі.

## ВИСНОВКИ

В кваліфікаційній роботі досліджено методи прогнозу відмов комп'ютерного обладнання з використанням нейронної мережі під час експлуатації КС спрямованих на підвищення ефективності процесу прогнозування за рахунок зменшення часових витрат на пошук можливих несправностей. Метою дослідження було бажання отримати об'єктивні дані щодо ефективності різних методів та визначити їхні переваги та обмеження при прогнозуванні відмов. Такий підхід дозволить прискорити та поліпшити процес прогнозування. Проведено аналіз існуючих нейронних мереж, алгоритмів навчання нейронної мережі, обрано алгоритм Левенберга-Марквардта, адаптованим для функцій типу суми квадратів помилок, що робить його дуже швидким, порівняно з іншими. Розраховано вектори вхідних параметрів нейронної мережі, сформульовано вирази залежностей параметрів одного об'єкту(обладнання) та параметрів об'єктів одного типу при різних умовах застосування. Отримано вектор вхідних параметрів, та побудовано НМ, в програмному середовищі MatLab з використанням пакету Neural Networks Toolbox, яку було досліджено.

Проведено оцінку розробленої нейромережі за показником регресії та середньоквадратичного відхилення з використанням нейронної мережі за методом Левенберга-Марквардта, що відповідно дорівнюють 0,106 та 96,681.

Наукова новизна: розробка нейронної мережі, інтегрованої у процес прогнозування відмов КО використовуючи класичні методи прогнозу для підвищення точності та зменшення прогнозування експертами.

Практична значимість: створено оптимальну архітектуру мережі для прогнозу відмов комп'ютерного обладнання, що забезпечило відносно високу швидкість навчання, зниження часу та ресурсів, необхідних для прогнозування відмов.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Davidov, A. A. Classification of the basic parameters for estimation of reliability and diagnosability of computers systems [text] / A. A. Davidov, A. I. Lipchansky // *Радіоелектронні і комп'ютерні системи*. – 2007. – № 6 (25). – С. 206-209.
2. Липчанский, А. И. Классификация основных показателей для оценки надежности и диагностируемости компьютерных систем [текст] / А. И. Липчанский, А. А. Давыдов // *Радіоелектроніка. Інформатика. Управління*. – 2007. – №2 (18). – С. 76-79.
3. Кривуля, Г. Ф. Оптимізація бінарних вирішальних дерев при інтелектуальній діагностиці комп'ютерних систем [текст] / Г. Ф. Кривуля, А. А. Давидов // *Радіоелектронні і комп'ютерні системи*. – 2010. – № 6 (47). – С. 260-265.
4. Кривуля, Г. Ф. Интеллектуальные средства диагностики компьютерных систем [текст] / Г. Ф. Кривуля, А. А. Давыдов // *3-ий Международный радиоэлектронный форум «Прикладная радиоэлектроника. Состояние и перспективы»*: Сб. научных трудов. – Харьков: ХНУРЭ, 2008. – С. 296.
5. Люгер Д.Ф. Искусственный интеллект: стратегии и методы решения сложных проблем: пер. с англ. – 4-е издание. – 2003. – 864 с.
6. Стоун, М. Д. Ваш РС. Проблемы и решения: практ. пособ. [текст]: пер. с англ. / М. Дэвид Стоун, Альфред Пур. – М.: Издательство ЭКОМ, 2002. – 416с.
7. Проектирование и диагностика компьютерных систем и сетей [текст] / М. Ф. Бондаренко, Г. Ф. Кривуля, В. Г. Рябцев [и др.]. – Харьков: ХНУРЭ, 2000. – 306 с.
8. Кириченко А.А. Нейропакеты – современный интеллектуальный инструмент исследователя. – 2013. – 183с.

9. Хайкін С. Нейронні мережі та навчальні машини. Prentice Hall. Нью-Йорк. – 2009. – №3. – 936 с.
10. Барский, А.Б. Логічні нейронні мережі: Учебное пособие / А.Б.Барский., 2013. – С. 352.
11. Schmidhuber J. Deep Learning in Neural Networks: An Overview / Schmidhuber J. // Neural Networks. – 2015. – Vol. 61. – P. 85-117.
12. Nadia Mana. Artificial Neural Networks in Pattern Recognition 5<sup>th</sup> INNS IAPR TC 3 GIRPR Workshop, ANNPR 2012, Trento, Italy, September 17-19, 2012 Proceeding. // Springer , 2012. – 245 p.
13. О. Матвійків, С.Ткаченко, В. Хаханов. Інженерне проектування складних об'єктів і систем : Навчальний посібник. Національний університет "Львівська політехніка". – 2016. – 261с.
14. Інтернет ресурс [http://vnz-mpu.com.ua/images/pdf/F\\_1.pdf](http://vnz-mpu.com.ua/images/pdf/F_1.pdf)
15. Інтернет ресурс <https://ela.kpi.ua/bitstream/123456789/26711/1.pdf>
16. Silage, D. Digital Communication Systems Using MATLAB and Simulink / D. Silage. – М. : Bookst and Publishing, 2009. – 199 p.
17. Нейронные сети <https://docplayer.ua/38344285-Neyronnye-seti-html>
18. Sravnenie-RBF [http://ni.biz.ua/2/2\\_6/2\\_63155\\_sravnenie-RBF-setey-i-mnogosloynih-perseptronov.html](http://ni.biz.ua/2/2_6/2_63155_sravnenie-RBF-setey-i-mnogosloynih-perseptronov.html)
19. Алгоритм навчання rbf-мережі та її використання <https://tudfile.net/preview/4494701/page:6/>
20. Кільчицький Д.В., Рожнова Т.Г. Побудова нейронної мережі прогнозу відмов обладнання комп'ютерної системи /27-й Міжнародний молодіжний форум «Радіоелектроніка та молодь у ХХІ столітті». Комп'ютерної інженерії та захисту інформації : Матеріали 27-го Міжнар. Молодіж. форуму, м. Харків, 10 травня 2023 р. – Харків, 2023. – С. 143–144.
21. Кільчицький Д.В., Рожнова Т.Г.Прогноз відмов комп'ютерного обладнання за допомогою нейронної мережі. December 22, 2023. Coventry, United Kingdom . Collection of scientific papers «SCIENTIA». – 2022. – P. 113–115.

