

Міністерство освіти і науки України  
Український державний університет науки і технологій

Комп'ютерні технології і системи  
(назва факультету)

Електронні обчислювальні машини  
(повна назва кафедри)

До зах. ст.  
23.06.2024

Пояснювальна записка  
до кваліфікаційної роботи  
другий (магістерський)  
(ступінь вищої освіти)

на тему: Прогнозування затримки на маршрутизаторі комп'ютерної мережі  
засобами нейронечіткої мережі

за освітньою програмою: Комп'ютерна інженерія

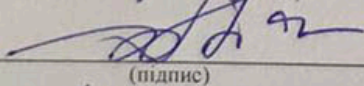
зі спеціальності: 123 Комп'ютерна інженерія  
(шифр і назва спеціальності)

Виконав: студент групи: КС2226

  
(підпис студента)

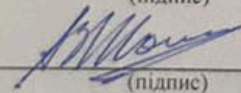
/ Анна ХРЕСТЯН /  
(Ім'я ПРІЗВИЩЕ)

Керівник:

  
(підпис)

/ доцент, Вікторія ПАХОМОВА /  
(посада, Ім'я ПРІЗВИЩЕ)

Нормоконтролер:

  
(підпис)

/ доцент, Володимир ШАПОВАЛОВ /  
(посада, Ім'я ПРІЗВИЩЕ)

Консультанти:

(назва розділу)

(підпис)

(посада, Ім'я ПРІЗВИЩЕ)

(назва розділу)

(підпис)

(посада, Ім'я ПРІЗВИЩЕ)

(назва розділу)

(підпис)

(посада, Ім'я ПРІЗВИЩЕ)

(назва розділу)

(підпис)

(посада, Ім'я ПРІЗВИЩЕ)

Засвідчую, що у цій роботі немає запозичень з  
праць інших авторів без відповідних посилань.

Студент

**Ministry of Education and Science of Ukraine**  
**Ukrainian State University of Science and Technologies**

Faculty Computer technologies and systems

(faculty)

Department Electronic computing machines

(department)

**Explanatory Note**  
**to Master's Thesis**  
**master**

(higher education degree)

on the topic: Prediction of latency on a computer network router by means of a neurofuzzy network

according to educational curriculum Computer engineering

in the Speciality: 123 Computer engineering

(speciality and its code)

Done by the student of the group: KS2226

/ Anna HRESTYAN /  
(name, surname)

Scientific Supervisor:

/ associate professor Victoria PAKHOMOVA /  
(position, name, surname)

Normative controller :

/ associate professor Volodymyr SHAPOVALOV /  
(position, name, surname)

Supervisors

\_\_\_\_\_

(Chapter title heading)

/ \_\_\_\_\_ /  
(position, name, surname)

\_\_\_\_\_

(Chapter title heading)

/ \_\_\_\_\_ /  
(position, name, surname)

\_\_\_\_\_

(Chapter title heading)

/ \_\_\_\_\_ /  
(position, name, surname)

\_\_\_\_\_

(Chapter title heading)

/ \_\_\_\_\_ /  
(position, name, surname)

Dnipro – 2024

Міністерство освіти і науки України  
Український державний університет науки і технологій

Факультет: Комп'ютерні технології і системи  
Кафедра: Електронні обчислювальні машини  
Рівень вищої освіти: другий (магістерський)  
Освітня програма: Комп'ютерна інженерія  
Спеціальність: 123 Комп'ютерна інженерія

(шифр та назва)

ЗАТВЕРДЖУЮ  
Завідувач кафедри ЕОМ

Ігор  
ЖУКОВИЦЬКИЙ  
(підпис) (Ім'я ПРІЗВИЩЕ)

Дата 15.11.2023

**З А В Д А Н Н Я**

на кваліфікаційну роботу другий (магістерський)  
(ступінь вищої освіти)

студенту Хрестян Ані Вячеславівні  
(Прізвище, Ім'я По батькові)

1. Тема роботи: Прогнозування затримки на маршрутизаторі комп'ютерної мережі засобами нейронечіткої мережі

Керівник роботи: Пахомова Вікторія Миколаївна, к.т.н., доцент кафедри ЕОМ  
(Прізвище, Ім'я, По батькові, науковий ступінь, вчене звання)

затверджені наказом від "21" 04 2023 р. № 332 ст

2. Строк подання студентом роботи: 08.01.2024 р.

3. Вихідні дані до роботи: значення затримок на маршрутизаторі комп'ютерної мережі

4. Зміст пояснювальної записки (перелік питань, які потрібно опрацювати):

4.1 Аналітична частина:  
огляд нейронних мереж, що придатні для прогнозування параметрів.

4.2 Основна частина: постановка задачі; нейронечітка мережа як основний метод розв'язання задачі; створення нейронечіткої мережі за допомогою додатку Fuzzy Logic Toolbox системи MatLAB.

4.3 Дослідницька частина:  
визначення оптимальних параметрів на створеній нейронечіткій мережі.

6. Консультанти розділів роботи:

Розділ	Прізвище, ініціали та посада консультанта	Завдання видав: (підпис консультанта, дата)	Завдання прийняв: (підпис студента, дата)

**КАЛЕНДАРНИЙ ПЛАН**

№ з/п	Назва етапів кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
1	Вступ	01.01.2024-07.01.2024	5 %
2	Огляд нейронних мереж, що придатні для прогнозування параметрів	06.11.2023-26.11.2023	20 %
3	Постановка задачі	27.11.2023-30.11.2023	10 %
4	Нейронечітка мережа як основний метод розв'язання задачі	01.12.2023-10.12.2023	25 %
5	Створення нейронечіткої мережі за допомогою додатку Fuzzy Logic Toolbox системи MatLAB	11.12.2023-17.12.2023	20 %
6	Визначення оптимальних параметрів на створеній нейронечіткої мережі	18.12.2023-29.12.2023	15 %
7	Висновки та рекомендації	01.01.2024-07.01.2024	5 %
8	Подання кваліфікаційної роботи до кафедри	08.01.2024	
9	Захист кваліфікаційної роботи на засіданні Екзаменаційної комісії		

Студент

  
(підпис)

Ана ХРЕСТЯН  
(Ім'я ПРІЗВИЩЕ)

## Реферат

Пояснювальна записка до кваліфікаційної роботи магістра: 64 с., 47 рис., 3 табл., 4 додатків, 21 джерело.

Мета кваліфікаційної роботи - прогнозування затримки на маршрутизаторі комп'ютерної мережі засобами нейронечіткої мережі.

Методи дослідження - розрахунок показника Херста для часового ряду затримок на маршрутизаторі комп'ютерної мережі; створення за методом Сугено нейронечіткої мережі для прогнозування затримки на маршрутизаторі; навчання та тестування створеної нейронечіткої мережі за різними методами оптимізації: зворотнього поширення помилки (Backprogra) та гібридним (Hybrid); оцінка за допомогою MAPE прогнозу на створеній нейронечіткій мережі.

Проведений розрахунок показника Херста показав, що часовий ряд затримок на маршрутизаторі комп'ютерної мережі персистентний, що характеризується ефектом довгочасної пам'яті. Створена в системі MatLAB нейронечітка мережа (глибина занурення - 3), в основі якої система із  $2^3=8$  правил при наступних параметрах: Гауссовський тип приналежності для вихідних (input) нейронів; лінійний тип приналежності для результуючого нейрону; гібридний метод оптимізації навчання. Визначено, що при навчанні (90 прикладів) та тестуванні (30 прикладів) значення похибок створеної нейронечіткої мережі склали приблизно 0,011 та 0,003 відповідно. Крім того, на створеній нейронечіткій мережі за гібридним методом оптимізації проведено дослідження похибки при використанні різних функцій приналежності вихідних (input) нейронів. Виконана оцінка (на основі MAPE; взято 10 часових проміжків) прогнозу затримки на маршрутизаторі комп'ютерної мережі на створеній нейронечіткій мережі.

Ключові слова: ПОКАЗНИК ХЕРСТА, ПРОГНОЗУВАННЯ, НЕЙРОНЕЧІТКА МЕРЕЖА, СИСТЕМА ПРАВИЛ, ФУНКЦІЯ ПРИНАЛЕЖНОСТІ, ПОХИБКА, MAPE.

## ЗМІСТ

ВСТУП.....	6
1 ОГЛЯД НЕЙРОННИХ МЕРЕЖ, ЩО ПРИДАТНІ ДЛЯ ПРОГНОЗУВАННЯ ПАРАМЕТРІВ .....	8
1.1 Нейронні мережі, що придатні для прогнозування.....	8
1.1.1 Багатошаровий персептрон .....	8
1.1.2 Радіально-базисна мережа.....	10
1.1.3 Узагальнено-регресійна мережа.....	11
1.1.4 Мережа Вольтерра.....	13
1.1.5 Мережа Елмана.....	15
1.1.6 Нейронечітка мережа .....	16
1.2 Засоби моделювання нейронних мереж .....	21
1.3 Висновки до розділу.....	22
2 СТВОРЕННЯ НЕЙРОНЕЧІТКОЇ МЕРЕЖІ ДЛЯ ПРОГНОЗУВАННЯ ЗАТРИМКИ НА МАРШРУТИЗАТОРІ КОМП'ЮТЕРНОЇ МЕРЕЖІ.....	23
2.1 Постановка задачі .....	23
2.2 Розрахунок показника Херста .....	24
2.3 Нейронечітка мережа як основний метод розв'язання задачі .....	27
2.4 Створення нейронечіткої мережі за допомогою додатку Fuzzy Logic Toolbox системи MatLAB.....	29
2.5 Навчання та тестування нейронечіткої мережі.....	31
2.6 Висновки до розділу.....	35
ЗДОСЛІДЖЕННЯ НА СТВОРЕНІЙ НЕЙРОНЕЧІТКІЙ МЕРЕЖІ.....	36
3.1 Визначення оптимальних параметрів.....	36
3.2 Оцінка якості прогнозу на створеній нейронечіткій мережі .....	45
3.3 Висновки до розділу.....	49
ВИСНОВКИ ТА РЕКОМЕНДАЦІЇ.....	50
ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ .....	51
ДОДАТОК А. Розрахунок показника Херста.....	54
ДОДАТОК Б. Вибірки для ННМ .....	58
ДОДАТОК В. Програмний код створенної нейронечіткої мережі.....	62
ДОДАТОК Г. Тези доповідей.....	64

## ВСТУП

Затримки на маршрутизаторі комп'ютерної мережі мають негативний вплив на роботу мережі та зв'язаних з нею послуг і додатків, а саме: завади в реальному часі, зменшення продуктивності, погіршення якості зв'язку та інші. Завдяки зростанню обсягів даних і збільшенню навантаження на мережі, точне передбачення затримок допоможе забезпечити стабільну та ефективну роботу мережевих сервісів. Таким чином, управління та прогнозування затримок є важливим завданням для забезпечення якості роботи мережевих інфраструктур та послуг, що підтверджує актуальність теми кваліфікаційної роботи.

Мета кваліфікаційної роботи – прогнозування затримки на маршрутизаторі комп'ютерної мережі засобами нейронечіткої мережі. Відповідно до мети поставлені наступні задачі:

1. Виконати огляд наукових джерел щодо придатності нейронних та нейронечітких мереж, а також нейромережних засобів для здійснення прогнозування параметрів.
2. Провести розрахунок показника Херста для часового ряду затримок на маршрутизаторі комп'ютерної мережі Придніпровської залізниці.
3. Створити в системі MatLAB нейронечітку мережу для прогнозування затримки на маршрутизаторі в комп'ютерній мережі.
4. Визначити на створеній нейронечіткій мережі її оптимальні параметри та зробити за допомогою MARE оцінювання отриманого прогнозу.

На сучасному етапі розвитку прогнозування з використанням нейронних та нейронечітких мереж займаються такі науковці: Безсонов О. О., Константинов Д. В., Костенніков О. М., Овчинников К. А., Пахомова В. М., Романюк О. С., Руденко О. Г., Руккас К. М., Савка Н. Я. та інші. Відомо, що для здійснення прогнозування можливо використання наступних нейронних мереж: багат шарового перцептронну; радіально-базисної мережі; узагальнено-регресійної мережі; мережі Вольтерра; мережі Елмана та нейронечіткої мережі, при цьому найкращу точність прогнозу надає нейронечітка мережа.

Кваліфікаційна робота складається із вступу, трьох розділів та висновків.

У першому розділі виконаний огляд наукових джерел щодо придатності нейронних та нейронечітких мереж, а також нейромережних засобів для здійснення прогнозування параметрів. Для подальшого виконання кваліфікаційної роботи обрано нейронечітку мережу та використання додатку Fuzzy Logic Toolbox системи MatLAB.

У другому розділі подана постановка задачі прогнозування затримки на маршрутизаторі комп'ютерної мережі Придніпровської залізниці, проведено розрахунок показника Херста, створена за допомогою режиму ANFIS додатку Fuzzy Logic Toolbox системи MatLAB нейронечітка мережі, в основі якої закладена система із  $2^3=8$  правил при наступних параметрах: Гауссовський тип приналежності для вихідних нейронів (input); лінійний тип приналежності для результуючого нейрону; гібридний метод оптимізації.

У третьому розділі на створеній нейронечіткій мережі проведено дослідження її похибки при використанні різних функцій приналежності вихідних (input) нейронів та за різними методами оптимізації. Крім того, виконана оцінка (засобами MARE; 10 часових проміжків) прогнозу на створеній нейронечіткій мережі затримки на маршрутизаторі комп'ютерної мережі.

Результати кваліфікаційної роботи представлялися у вигляді тезів: Всеукраїнську науково-технічну конференцію здобувачів вищої освіти та молодих учених «Наука і сталий розвиток транспорту»; XVII Міжнародну науково-практичну конференцію «Сучасні інформаційні та комунікаційні технології на транспорті, в промисловості та освіті», що відбулися в УДУНТ 27 жовтня 2023 р. та 13-14 грудня 2023 р. відповідно..

# 1 ОГЛЯД НЕЙРОННИХ МЕРЕЖ, ЩО ПРИДАТНІ ДЛЯ ПРОГНОЗУВАННЯ ПАРАМЕТРІВ

## 1.1 Нейронні мережі, що придатні для прогнозування

### 1.1.1 Багатошаровий персептрон

Багатошаровий персептрон - це один із базових типів штучних нейронних мереж, який складається з кількох шарів нейронів, зв'язаних між собою. Кожен шар містить набір нейронів, які обчислюють ваговану суму своїх вхідних сигналів і застосовують нелінійну активаційну функцію для результату.

Багатошаровий персептрон складається з трьох типових шарів:

1. Вхідний шар – це перший шар нейронів, який отримує вхідні сигнали. Кожен нейрон вхідного шару представляє окрему вхідну ознаку або атрибут;

2. Приховані шари - ці шари знаходяться між вхідним і вихідним шарами. Кожен нейрон прихованого шару отримує сигнали від нейронів попереднього шару, обчислює їх ваговану суму і застосовує активаційну функцію до результату. Кількість прихованих шарів і кількість нейронів у кожному шарі можуть варіюватися залежно від задачі і складності моделі;

3. Вихідний шар - це останній шар нейронів, який генерує вихідні сигнали, кожен нейрон вихідного шару отримує сигнали від нейронів прихованих шарів і обчислює ваговану суму з них, застосовуючи активаційну функцію. Кількість нейронів в вихідному шарі залежить від кількості класів або вихідних значень, які потрібно передбачити.

Така мережа може моделювати функцію практично будь-якого ступеня складності, причому число шарів і число елементів в кожному шарі визначають складність функції.

Визначення числа проміжних шарів і числа елементів в них є важливим питанням при конструюванні багаторазового персептрона [1].

Одним із підходів до вирішення задачі маршрутизації являється використання апарату штучних нейронних мереж.

Багатошаровий персептрон є корисним інструментом для прогнозування затримок на маршрутизаторі комп'ютерної мережі, але він також має свої переваги і недоліки.

Переваги використання багатошарового персептрону:

- робота з різними типами даних - може працювати з різними типами входів, включаючи числові дані, категоріальні дані та послідовності;
- модульність – можливість налаштовувати кількість шарів та нейронів в кожному шарі, щоб забезпечити відповідність потребам задачі;
- здатність до навчання - можливість підлаштовуватися до змін в мережі та оточенні.

Недоліки використання багатошарового персептрону:

- не враховує часових залежностей - для прогнозування затримок, пов'язаних із змінами в мережі з часом, може бути важливо використовувати архітектуру з рекурентними шарами;
- потреба в великій кількості даних - може вимагати великої кількості тренувальних даних для ефективного навчання, особливо в складних завданнях прогнозування.

Руккас К.М. та Овчинников К.А. у своїй науковій роботі «Порівняльний аналіз методів прогнозування трафіку в телекомунікаційних системах» провели чисельний експеримент з метою порівняння ефективності різних методів прогнозування для застосування до часових рядів характеристик трафіку в телекомунікаційних системах. Результати дослідів продемонстрували, що з збільшенням інтервалу ряду точність лінійної моделі погіршується, і найменшу помилку прогнозу забезпечує багатошаровий персептрон [2]. У таблиці 1.1 наведено середні абсолютні значення перших різниць (прирощень) ряду[2].

Таблиця 1.1 - Середні абсолютні помилки прогнозу на один крок уперед тимчасового ряду обсягів вихідного трафіку

Метод/часовий інтервал	1 с.	60 с.	10 хв.
Багатошаровий персептрон	0,0203	0,0199	0,0123
Модель Холта	0,0230	0,0141	0,0192
Лінійна модель	0,0208	0,0455	0,0571
Середнє абсолютних значень перших різниць ряду	0,3596	0,3027	0,3213

### 1.1.2 Радіально-базисна мережа

Радіально-базисна мережа є одним із типів штучних нейронних мереж, який використовує радіальні базисні функції для моделювання складних залежностей між вхідними і вихідними даними.

Вона відрізняється від багатошарового персептрона тим, що має спеціальні функції активації та розміщення нейронів.

Радіально-базисні мережі надають собою гнучкий інструмент інтерполяції за умови, що безліч центрів більш-менш рівномірно покриває область визначення шуканої функції, проте, як правило в проміжних точках апроксимація досягає високої точності тільки якщо безліч радіальних базисних функцій доповнено полиномом, ортогональним до кожної з радіальної базисної функції [3].

Переваги використання радіально-базисної мережі:

- здатність моделювати нечіткі залежності - володіє здатністю моделювати нечіткі та нелінійні залежності в даних. Це корисно для прогнозування затримок в мережі, де багато факторів можуть впливати на результат;
- робота з послідовностями даних - може бути використаний для прогнозування затримок, які змінюються з часом, так і для роботи з послідовностями даних.

Недоліки використання радіально-базисної мережі:

- не враховує динаміку в часі;
- потреба в великій кількості центрів RBF - для успішного навчання мережі може знадобитися велика кількість центрів, що може призвести до значного зростання обчислювальних витрат.

Савка Н. Я. у своїй науковій роботі «Застосування штучних нейронних мереж з радіально-базисними функціями для розв'язування задач прогнозування» визначила, що найбільш ефективним кількісним методом прогнозування є використання штучних нейронних мереж з радіально-базисними функціями. Оскільки для реальних задач сьогодення характерна велика кількість факторів впливу, то в результаті дослідження встановлено, що саме алгоритм багатокрокового навчання доцільно застосовувати для

навчання штучних нейронних мереж з радіально-базисними функціями, який здатний працювати з великою вибіркою даних і в процесі навчання формувати структуру штучної нейронної мережі радіального типу, яка володіє прогностичними властивостями [4].

На рисунку 1.1 представлена структура штучних нейронних мереж з радіально-базисними функціями, з якого видно, що в мережі є вхідний шар, лише один прихований (радіальнобазисний) шар і вихідний лінійний шар [4].

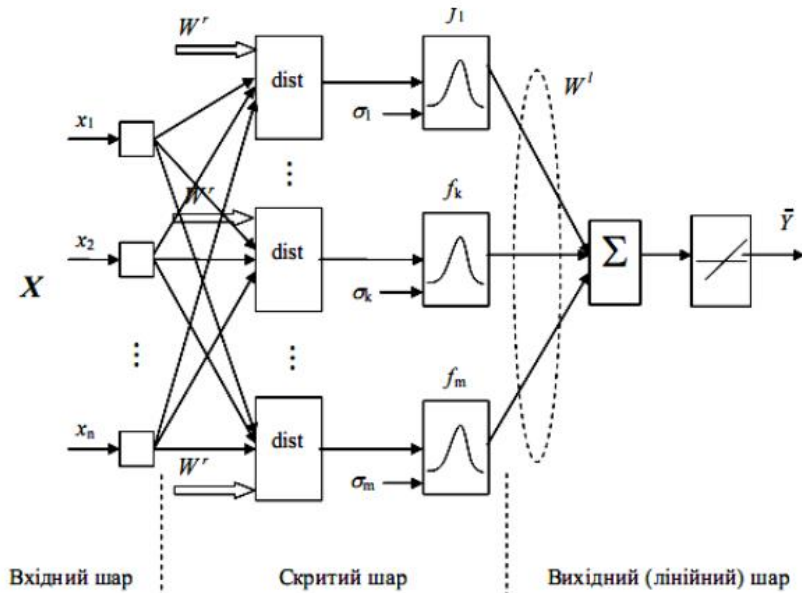


Рисунок 1.1 - Узагальнена архітектура штучної нейронної мережі з радіально-базисними функціями

### 1.1.3 Узагальнено-регресійна мережа

Узагальнено-регресійна мережа є одним із типів штучних нейронних мереж, який використовується для розв'язання задач регресії, тобто прогнозування неперервних вихідних значень на основі вхідних даних.

Основні характеристики узагальнено-регресійної мережі:

1. Функція активації - мережа використовує гаусівські функції, як функцію активації для кожного нейрона. Гаусівська функція вимірює подібність вхідного сигналу до центра нейрона;
2. Ваги - кожен нейрон узагальнено-регресійної мережі має вагу, яка відповідає його центру. Ці ваги використовуються для обчислення вагової суми вхідних сигналів;

3. Навчання - мережа навчається шляхом побудови локального моделюючого околу для кожного навчального прикладу. Це означає, що навчання відбувається шляхом адаптації центрів та ваг нейронів мережі до навчальних даних;

4. Прогнозування - після завершення навчання узагальнено-регресійна мережа може використовуватись для прогнозування вихідних значень на основі нових вхідних даних. Вона використовує гаусівські функції та ваги нейронів для обчислення вагової суми вхідних сигналів.

Узагальнено-регресійна мережа є ефективним інструментом для розв'язання задач регресії, зокрема для прогнозування значень на основі неперервних даних [5].

Переваги використання узагальненої-регресійної мережі:

- навчання без втрати - мережа відома своєю здатністю до "навчання без втрати", це означає, що під час навчання мережі не потрібно налаштовувати жодні гіперпараметри, такі як коефіцієнти ваги, і мережа має потенціал для точного навчання на невеликій кількості даних;
- високий рівень швидкодії - мережа може бути швидкою та ефективною для великих наборів даних, оскільки вона не вимагає ітеративних методів навчання та використовує аналітичні формули для розрахунку ваг;
- використання для прогнозування - мережа зазвичай використовується для прогнозування числових значень, таких як регресійні задачі, де потрібно передбачити цільову змінну на основі вхідних факторів.

Недоліки використання узагальненої-регресійної мережі:

- схильність до перенавчання - незважаючи на можливість "навчання без втрати", мережа все ж може стати схильною до перенавчання, особливо якщо навчаються на обмеженій кількості даних;
- не підходить для всіх завдань – мережа спеціалізується на задачах регресії та не є універсальною архітектурою, як деякі інші типи нейронних мереж.

Тоніца О. В., Лотарєв М. С., Решетнікова С.М. у своїй науковій роботі «Прогнозування надзвичайних ситуацій за допомогою нейронних мереж» вирішили

задачу прогнозування часових рядів, в якості нейронної мережі була обрана узагальнено-регресійна мережа, яка реалізує методи ядерної апроксимації.

На рисунку 1.2 наведена структура узагальнено-регресійної мережі [6].




Рисунок 1.2 - Загальна структура мережі GRNN

GRNN-мережа має два приховані шари - шар радіальних елементів та шар елементів, які формують зважену суму для відповідного елемента вихідного шару. Побудована мережа дозволяє виконувати прогнозування природних показників (температура, вологість) і показників технологічного процесу для визначення ймовірності надзвичайної ситуації [6].

#### 1.1.4 Мережа Вольтерра

Мережа Вольтерра - це тип нейромережі, який використовує ідеї та методологію мережі Вольтерра для моделювання нелінійних взаємодій та властивостей системи.

Вона побудована на основі математичних моделей Вольтерра та використовує нейрони для апроксимації нелінійних функцій та динаміки системи.

Нейромережі Вольтерра використовуються для моделювання складних нелінійних систем, які мають взаємодію між різними вхідними сигналами та виходами. Вони можуть бути застосовані в різних областях, таких як обробка сигналів, прогнозування, керування.

Основні переваги використання мережі Вольтерра:

- моделювання нелінійності – мережа має здатність моделювати нелінійні залежності в даних, що може бути корисним при аналізі затримок в мережі, які можуть бути нелійними за природою;

- моделювання залежностей в часі – мережа може бути використана для моделювання динаміки затримок в мережі з плином часу, що може бути важливим для прогнозування змін у затримках;
- аналіз взаємодії між факторами - мережа дозволяє аналізувати взаємодію між різними факторами, що впливають на затримки, і визначати їхню важливість.

Основні недоліки використання мережі Вольтерра:

- високі вимоги до обчислювальних ресурсів - визначення параметрів моделі Вольтерра може вимагати значних обчислювальних ресурсів і часу, особливо для великих обсягів даних;
- потреба у великій кількості даних - модель може вимагати великої кількості даних для успішного навчання, що може бути проблемою, якщо дані обмежені;
- важко інтерпретована - модель може бути важко інтерпретованою, і це може зробити складним аналіз результатів[7].

Соловійов А. І. у своїй науковій роботі «Прогнозування та нейромережеве моделювання в управлінні виробничими структурами» визначив головну перевагу нейротехнологічного підходу - він дозволяє відтворювати складні нелінійні залежності і здійснювати прогнози в управлінні виробничими процесами на середньо- та довгострокові періоди з високою надійністю [8]. Отже, використання сучасних інструментів та потужних нелінійних багатомірних методів, основаних на нейротехнологіях, дало змогу створити нелінійні системи та моделі, що можуть забезпечувати високу достовірність апроксимації надскладних процесів у просторі та часі. На рисунку 1.3 представлена структура мережі Вольтерра для моделювання нелінійних взаємодій [8].




Рисунок 1.3 – Структура мережі Вольєрра

### 1.1.5 Мережа Елмана

Мережа Елмана - це тип рекурентної штучної нейронної мережі, яка використовується для моделювання послідовних даних та виявлення залежностей у часових рядах.

Основна особливість мережі Елмана полягає у наявності рекурентного зв'язку, що дозволяє передавати інформацію з попередніх часових кроків назад у прихований шар мережі. Це дозволяє мережі зберігати контекстну інформацію та використовувати її для прогнозування майбутніх значень або класифікації.

Основні компоненти мережі Елмана включають:

1. Вхідний шар - приймає вхідні дані та передає їх у прихований шар;
2. Прихований шар - обробляє вхідні дані та зберігає контекстну інформацію з попередніх часових кроків за допомогою рекурентних зв'язків;
3. Вихідний шар - генерує вихідні значення на основі оброблених даних з прихованого шару;
4. Рекурентні зв'язки - передають інформацію з вихідного шару до прихованого шару, що дозволяє зберігати контекстну інформацію.

Мережі Елмана використовуються для моделювання та прогнозування часових рядів, розпізнавання мови, машинного перекладу, аналізу тексту, керування рухом роботів

та багатьох інших задач, де важлива взаємодія з послідовними даними та здатність моделі зберігати контекстну інформацію [9].

Переваги використання мережі Елмана:

- рекурентність – одна з головних переваг мережі Елмана - це наявність рекурентних зв'язків. Вона має прихований стан, який може зберігати інформацію про попередній стан мережі та використовувати цю інформацію для обробки нових вхідних даних;
- здатність до довгострокової залежності - завдяки рекурентним зв'язкам, мережа Елмана може враховувати залежності в даних на довший термін і вирішувати завдання, пов'язані з довгостроковою залежністю.

Недоліки використання мережі Елмана:

- проблема зникаючого та викидаючого градієнту - мережі Елмана можуть страждати від проблеми зникання та викидання градієнту, яка впливає на їхню здатність до навчання на довгих послідовностях;
- складність навчання - навчання мереж Елмана може бути складним завданням і вимагати великої кількості тренувальних даних та налаштувань;
- обчислювальна складність - може вимагати значних обчислювальних ресурсів для роботи з великими вхідними даними та складними моделями.

Руденко О. Г., Безсонов О.О., Романюк О.С. у своїй науковій роботі «Нейромережеве прогнозування часових рядів на основі багатошарового персептрона» довели, що з метою підвищення якості прогнозування слід використовувати рекурентні нейронні мережі. Структура цих мереж містить додаткові зворотні зв'язки, а для їх навчання використовується специфічний алгоритм, який дозволяє розрахувати вплив власних похибок на якість прогнозу [10].

#### 1.1.6 Нейронечітка мережа

Нейронечітка мережа є комбінацією нейромережі та нечіткої логіки, яка використовується для моделювання та аналізу систем з нечіткими вхідними даними або нечіткими вимогами.

Основна ідея нейронечітких мереж полягає в поєднанні сильних сторін нейромережі, таких як здатність до навчання на основі даних з нечіткими методами, які дозволяють моделювати нечіткі залежності та приймати розмиті рішення. Це дозволяє нейронечітким мережам працювати зі складними системами, які мають невизначені характеристики.

Нейронечіткі мережі широко використовуються для моделювання та керування системами в різних галузях, включаючи промислові процеси, системи керування та прийняття рішень, прогнозування, та інше.

На рисунку 1.4 представлена структура нейронечіткої мережі [12].




Рисунок 1.4 - Структура нейронечіткої мережі

Основні властивості нейронечіткої мережі:

1. Нечіткість - мережа здатна працювати з нечіткими даними та нечіткими вимогами;
2. Адаптивність - мережа має здатність навчатися та адаптуватися на основі навчальних даних;
3. Паралельна обробка - мережа може обробляти багато вхідних сигналів одночасно та виконувати паралельні обчислення;
4. Врахування контексту - мережа може враховувати контекстну інформацію та попередні стани прийняття рішень;
5. Розмитість - мережа може працювати з розмитими значеннями та розмитими множинами;

Переваги використання нейронечіткої мережі:

- здатність до роботи зі складними системами - можуть використовуватися для моделювання та управління складними системами, які важко описати точними математичними моделями;

- обробка невизначених даних – нейронечіткі мережі здатні ефективно обробляти дані, які мають невизначеність або розмитість.

Недоліки використання нейронечіткої мережі:

- потреба у великій кількості даних для навчання - для навчання нейро-нечітких мереж може знадобитися значна кількість тренувальних даних, особливо для складних завдань;
- висока обчислювальна складність - деякі варіанти нейро-нечітких мереж можуть вимагати значних обчислювальних ресурсів [12].

Блок-схема алгоритму роботи системи ANFIS [17] представлена на рисунку 1.5.




Рисунок 1.5 - Блок-схема алгоритму роботи системи ANFIS

Блок 1. Початок алгоритму.

Блок 2. Введення вхідних параметрів (інформативних ознак об'єкта).

Блок 3. Визначення значень функції приналежності, за наступною формулою [17]:

$$\mu_A(X_i) = \frac{1}{1 + \left(\frac{X_i - c_i}{\sigma_i}\right)^{2b_i}} \quad (1.1)$$

де  $\mu_{A_i}(X)$  – функція приналежності при конкретних значеннях входів  $x_1, x_2, \dots, x_n$ ;

$A_i$  – нечітка змінна, асоційована з данним вузлом;

$\sigma_i, b_i, c_i$  – параметри, які підлягають адаптації в процесі навчання системи.

Блок 4. Визначення ступеня істинності посилок кожного  $j$ -го правила бази знань системи, шляхом виконання нечіткої логічної операції «AND» («min») на параметрах посилок правил за наступною формулою [17]:

$$W_j = \min\{\mu_{A_1}(x_1), \mu_{A_2}(x_2), \dots, \mu_{A_j}(x_j)\} \quad (1.2)$$

де  $W_j$  - ступінь істинності посилок кожного  $j$ -го правила бази правил;

$\mu_{A_j}(X)$  – значення функції належності при конкретних значеннях входів ( $x_n$ ).

Блок 5. Розрахунок відносного ступеня виконання нечіткого правила за формулою:

$$W_j = \frac{W_j}{\sum_{j=1}^k W_j} \quad (1.3)$$

де  $W_j$  - відносний ступінь виконання  $j$ -того нечіткого правила;

$W_j$  – ступінь істинності посилок кожного  $j$ -того правила бази знань;

$\sum_{j=1}^k W_j$  – сума всіх ступенів істинності посилок кожного  $j$ -того правила бази правил.

Блок 6. Розрахунок внеску кожного нечіткого правила у вихід мережі за формулою:

$$y_j = W_j \cdot v_j \quad (1.4)$$

де  $y_j$  – внесок кожного нечіткого правила у вихід мережі;

$W_j$  - відносний ступінь виконання  $j$ -того нечіткого правила;

$v_j$  – чітке число, що задає висновок кожного  $j$ -того правила.

Блок 7. Визначення суми внесків усіх правил за формулою [17]:

$$y = \sum_{j=1}^k y_j \quad (1.5)$$

де  $y$  – вихід мережі;

$\sum_{j=1}^k y_j$  – сумарний внесок всіх нечітких правил.

Блок 8. Кінець алгоритму.

У своїй науковій роботі Пахомова В. М. за допомогою нейронечіткої логіки знайшла залежності середньої похибки навчання гібридної системи прогнозування обсягу мережного трафіка дорожнього фрагмента (Дніпропетровськ – Київ) в ІТС Придніпровської залізниці від: кількості її входів, кількості термів вхідної змінної та потужності навчальної вибірки за різними методами навчання. Показала, що прогнозування обсягу мережного трафіка в ІТС дозволить в реальному часі визначити перевантаження в мережі та здійснити контроль за потоками даних [11].

Пахомова В. М. та Мандибуря Є. С. у своїй науковій роботі «Визначення оптимального маршруту в інформаційній мережі залізничного транспорту за допомогою нейронечітких моделей» здійснили прогноз часу перебування пакета в маршрутизаторах за маршрутом його проходження на основі нейронечіткої мережі для фрагмента ІТС залізничного транспорту. Провели дослідження середньої похибки навчання нейронечіткої мережі за різних функцій належності й за різними методами оптимізації навчання. Виявлено, що найменше значення середньої похибки навчання надає нейронечітка мережа конфігурації 3–12–60–60–1 в разі використання симетричної Гаусівської функції належності за гібридним методом оптимізації [13].

Костенніков О.М. у своїй науковій роботі «Удосконалення технології формування місцевого вагонопотоку на дільниці в умовах сезонного коливання обсягів навантаження» зазначив, що прогнозування обсягів навантаження у вагонах базується на основі нейронечітких гібридних систем [14].

Солодовник М. С. та Асланов А. М. у своїй науковій роботі «Використання нейронечіткого підходу у прогнозуванні виходу з ладу модуля серверної пам'яті» дослідили, що нейронечітка моделі показує достатньо високий рівень адекватності реальним вхідним

параметрам, що дозволяє зробити висновок про можливість її практичного використання для прогнозування моменту виходу з ладу модуля серверної пам'яті на значущому відрізку часу.

Останній підхід є найточнішим та практично обґрунтованим методом прогнозування, оскільки він надає найменшу похибку порівняно з іншими розглянутими методами прогнозування. Перевага запропонованого підходу полягає в тому, що нейронечіткі системи здатні до самонавчання та роботи з нелінійними даними [15].

Кісельова О. М., Притоманова О. М. та Дон Я. Б. у своїй науковій роботі «Розробка нейронечіткої моделі короткострокового прогнозу в умовах нечіткої інформації» дослідили, що застосування нейронечіткого підходу до прогнозування таких досить унікальних процесів при невеликих вибірках статистичних даних (які можуть бути неточними) дозволяє виявляти тренди, а не надавати детальні щоденні дані з твердою гарантією їх виконання [16].

## **1.2 Засоби моделювання нейронних мереж**

На сьогоднішній день існують потужні програмні засоби, які дозволяють створювати штучні нейронні мережі різних архітектур та складності. Вони надають можливість візуалізувати структуру цих мереж, навчати їх на великих обсягах даних, налагоджувати гіперпараметри, виконувати розрахунки та прогнози, а також вирішувати різноманітні прикладні завдання, які не завжди можуть бути вирішені стандартними методами.

Штучні нейронні мережі стали потужним інструментом у багатьох галузях, включаючи машинне навчання, комп'ютерне зорове сприйняття, робототехніку та багато інших. Їх гнучкість та здатність до адаптації дозволяють вирішувати завдання, які раніше були важкі або неможливі для реалізації [12].

Прикладні програми, які можуть бути використанні для моделювання нейронних мереж:

- TensorFlow: це відкрите програмне забезпечення для машинного навчання, розроблене Google;
- CNTK (Microsoft Cognitive Toolkit): це фреймворк для глибокого навчання від Microsoft, який надає можливості для створення та навчання нейронних мереж;

- Keras: це високорівневе API для машинного навчання, яке вбудовано в TensorFlow і може використовуватися разом із PyTorch;
- MATLAB: має вбудовану мову для програмування і досить багатий інструментарій для штучних нейронних мереж, який включає в себе створення, навчання, тренування, графічний та командний інтерфейс для побудови архітектури мереж.

MATLAB - це гнучке середовище для чисельних обчислень і програмування з простим інтерфейсом та багатою функціональністю, що включає інструменти для розв'язання різних завдань, візуалізації даних та паралельних обчислень[11].

Нейропакет Fuzzy Logic Toolbox в MATLAB - це потужний інструмент для роботи з нечіткими логічними системами та логікою нечітких множин. Він надає можливості для створення та налаштування нечітких правил, визначення нечітких величин та їхньої взаємодії.

### **1.3 Висновки до розділу**

1. Проведено огляд нейронних мереж, що можуть бути використанні для прогнозування, таких як: багатошаровий персептрон, радіально-базисна мережа, узагальнено-регресійна мережа, мережа Вольтерра, мережа Елмана та нейронечітка мережа.

Для подальшого виконання кваліфікаційної роботи обрано нейронечітку мережу, тому що використання мережі дозволяє ефективно моделювати складні системи та працювати з різноманітними типами даних, що робить її потужним інструментом в багатьох галузях застосування.

2. У якості засобів моделювання можуть бути використані наступні прикладні програми: Matlab, TensorFlow, Microsoft Cognitive Toolkit, Keras. У кваліфікаційній роботі для подальшого моделювання та навчання нейронної мережі застосовується нейропакет Fuzzy Logic Toolbox, який входить до складу прикладної програми Matlab. Fuzzy Logic Toolbox дозволяє створювати моделі з нечіткими правилами, що корисно для аналізу та прогнозування в умовах нечітких даних.

## 2 СТВОРЕННЯ НЕЙРОНЕЧІТКОЇ МЕРЕЖІ ДЛЯ ПРОГНОЗУВАННЯ ЗАТРИМКИ НА МАРШРУТИЗАТОРІ КОМП'ЮТЕРНОЇ МЕРЕЖІ

### 2.1 Постановка задачі

Інформаційно-телекомунікаційна система (ІТС) залізничного транспорту – сукупність засобів обчислювальної техніки, приладів промислової автоматики, засобів зв'язку, програмного забезпечення, каналів зв'язку, а також користувачів, які працюють з ними (персоналу), призначених для ефективного розв'язування задач автоматизації виробничої та господарчої діяльності підприємств залізничного транспорту [13].

Відомо, що на сучасному етапі в інформаційно-телекомунікаційній системі (ІТС) залізничного транспорту у якості протоколу маршрутизації використовується протокол OSPF (Open Shortest Path First), в основі якого використання алгоритму вибору найкоротшого маршруту. У реальному часі збільшення потоків даних в ІТС призведе до появи пікових навантажень, які в свою чергу ведуть до істотних затримок на маршрутизаторах оптимального маршруту в комп'ютерній мережі. Визначення оптимального маршруту в комп'ютерній мережі, що складає основу ІТС залізничного транспорту, базується на відповідному часі передачі даних за маршрутом, значну частину якого складають затримки на маршрутизаторах, зважаючи на те, що час передачі пакета по каналу мережі значно менший.

Для подальшого дослідження взято часовий ряд значень затримок на маршрутизаторі комп'ютерної мережі Придніпровської залізниці, що були отримані на відповідній імітаційній моделі мережі в [13]. На основі проведеного в [11] аналізу обсягу мережевого трафіку в ІТС Придніпровської залізниці для здійснення прогнозу затримки на маршрутизаторі з використанням нейронечіткої технології прийнято рішення обрати глибину занурення  $3$ , що відповідає  $15$  хвилинному інтервалу часу. Таким чином,  $X(t-3)$ ,  $X(t-2)$ ,  $X(t-1)$  – це затримки на маршрутизаторі комп'ютерної мережі в часові моменти  $t-3$ ,  $t-2$ ,  $t-1$  відповідно. У якості результуючого нейрону  $X(t)$  – це затримка на маршрутизаторі комп'ютерної мережі в часовий момент  $t$ .

## 2.2 Розрахунок показника Херста

Для аналізу часового ряду затримок на маршрутизаторі комп'ютерної мережі необхідно використати показник Херста.

Довгою пам'яттю називають кореляційний структуру часових рядів, що мають великі зрушення. R / S - аналіз може відображати деяку стійкість (або нестійкість) тренда випадкового процесу, причому стійкість характеризується наявністю довгострокових ефектів.

Для формування методу необхідно використовувати часовий ряд  $X_1 \dots X_n$  значень. В основі R / S – аналізу лежить наступне співвідношення [18]:

$$\left(\frac{R}{S}\right) = (aN)^H \quad (2.1)$$

де H – показник Херста;

S – середнє квадратичне відхилення ряду спостережень X;

N – кількість періодів спостережень;

– накопичене відхилення ряду X від середнього значення;

R – розмах накопиченого відхилення;

a – задана константа, позитивне число

Згідно з відношення аналізу, значення показника Херста розраховується наступним чином [18]:

$$H = \log\left(\frac{R}{S}\right) / \log(aN) \quad (2.2)$$

Стандартне відхилення S розраховується за наступною формулою [18]:

$$S = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - X_{\text{сеп}})^2} \quad (2.3)$$

де – середнє арифметичне ряду спостережень X за N періодів.

Розмах накопиченого відхилення R розраховується за наступною формулою [18]:

$$R = \max_{1 \leq n \leq N} Z_n - \min_{1 \leq n \leq N} Z_n \quad (2.4)$$

де  $Z_n$  - накопичене відхилення ряду X від середнього значення, яке розраховується за наступною формулою [18]:

$$Z_n = \sum_{i=1}^n (X_i - X_{\text{сеп}}) \quad (2.5)$$

Значення показника Херста склало приблизно 0,59 ( $a=0,25$ ;  $N=120$ ), що перевищує 0,5; отже часовий ряд затримок на маршрутизаторі персистентний і характеризується ефектом довгочасної пам'яті. У додатку А представлено розрахунок показника Херста. Таким чином, математично доведено, що вхідний часовий ряд не є випадковим, тобто є персистентним, що означає, якщо ряд буде зростати (уменшуватись) в попередній період, то він збереже цю тенденцію і в майбутньому періоді. Але також відомо, що класичний метод Херста має ряд недоліків, серед яких неможливість обчислення показника в реальному масштабі часу при значному зростанні обсягу обчислення, тому доцільно використання саме засобів нейронної мережі чи нейронечіткої мережі.

### **2.3 Нейронечітка мережа як основний метод розв'язання задачі**

Нейронечіткі мережі дозволяють об'єднати в собі переваги нейронних мереж і систем нечіткого висновку. Основна ідея, полягає в тому, щоб використовувати існуючі вибірки даних для визначення параметрів функцій належності, які б найкраще відповідали конкретній системі нечіткого виводу. Для знаходження цих параметрів застосовуються відомі процедури навчання.

Гібридна система являє собою багатошарову структуру беззворотніх зв'язків, в якій використовуються не нечіткі сигнали, ваги та функції активації, а виконання операції підсумовування, засноване на використанні фіксованої T-норми, T-конорми. При цьому значення входів, виходів і ваг гібридної нейронної мережі являють собою дійсні числа з відрізка  $[0,1]$ . Існуюча вибірка даних використовується для визначення параметрів функцій належності, які найкраще відповідають деякій системі нечіткого виводу. При цьому для знаходження параметрів функцій належності використовуються відомі процедури навчання нейронних мереж. Для вирішення задачі прогнозування затримки на маршрутизаторі комп'ютерної мережі обрано нейронечітку мережу (ННМ), загальний алгоритм функціонування якої складається з 8-ми блоків [17], що представлений в додатку В (рис. В.1).

Процес створення ННМ можна розділити на наступні етапи: обробка вхідних даних, розробка системи, перевірка системи. На початку вводу даних в систему, варто з'ясувати, скільки попередніх значень знадобиться для виявлення закономірності.

Експериментальним шляхом виявлено, що чим більше попередніх даних одержить система, тим точніше буде прогноз, але зворотною стороною медалі є надмірна складність системи, що призводить до значного збільшення часу обробки даних і навіть до зависання системи.

Структура нейронечіткої мережі (ННМ), що пропонується для прогнозування затримки на маршрутизаторі комп'ютерної мережі, представлена на рисунку 2.1.




Рисунок 2.1 — Запропонована структура ННМ для прогнозування затримки на маршрутизаторі комп'ютерної мережі

У першому шарі  $X(t-3)$ ,  $X(t-2)$ ,  $X(t-1)$ , що відповідають значенням затримок на маршрутизаторі комп'ютерної мережі в часові моменти  $t-3$ ,  $t-2$ ,  $t-1$  відповідно. Отже, кількість вихідних нейронів дорівнює 3. Перший шар виконує ділення фази кожної змінної, визначаючи для кожного  $j$ -го правила виведення коефіцієнта належності відповідно до застосовної функції фазування.

Загальна кількість термів для другого шару дорівнює 6, тому що кожній вихідній змінній відповідає 2 терми, виконується агрегація змінних  $X_i$ , визначаючи результуюче значення коефіцієнта приналежності для вектора  $X$ . Терми відповідають значенням MIN та MAX, що дорівнюють 675 та 2100 відповідно. Шар не є параметричним.

Третій шар - є генератором функції TSK; це параметричний шар, який включає адаптацію лінійної ваги, що визначає функцію виведення моделі TSK.

Четвертий шар складається з функцій належності для кожного правила нечіткого виведення; цей шар не є параметричним.

Кількість правил можна знайти за  $2^3=8$ .

Отже, прогнозуюча система матиме 8 правил:

1. If (input1 is inmf1) and (input2 is inmf2) and (input3 is inmf1) then (output is outmf1) (1)
2. If (input1 is inmf1) and (input2 is inmf2) and (input3 is inmf2) then (output is outmf2) (1)
3. If (input1 is inmf1) and (input2 is inmf2) and (input3 is inmf3) then (output is outmf3) (1)
4. If (input1 is inmf1) and (input2 is inmf2) and (input3 is inmf4) then (output is outmf4) (1)
5. If (input1 is inmf2) and (input2 is inmf1) and (input3 is inmf1) then (output is outmf5) (1)
6. If (input1 is inmf2) and (input2 is inmf1) and (input3 is inmf2) then (output is outmf6) (1)
7. If (input1 is inmf2) and (input2 is inmf2) and (input3 is inmf3) then (output is outmf7) (1)
8. If (input1 is inmf2) and (input2 is inmf2) and (input3 is inmf4) then (output is outmf8) (1)

П'ятий шар є нормалізуючим, він має один вузол, який відповідає результуючому нейрону  $X(t)$  — спрогнозована затримка на маршрутизаторі комп'ютерної мережі в часовий момент  $t$ ; цей шар також не є параметричним.

#### **2.4 Створення нейронечіткої мережі за допомогою додатку Fuzzy Logic Toolbox системи MatLAB**

Побудова ННМ виконана в режимі ANFIS за допомогою додатку Fuzzy Logic Toolbox системи MatLAB: задана кількість вихідних нейронів (їх три); задана кількість терм для кожного вихідного нейрону (їх два); обраний тип функції приналежності для вихідних (input) нейронів (gaussmf) та результуючого (output) нейрону (linear), як це показано на рисунку 2.2.

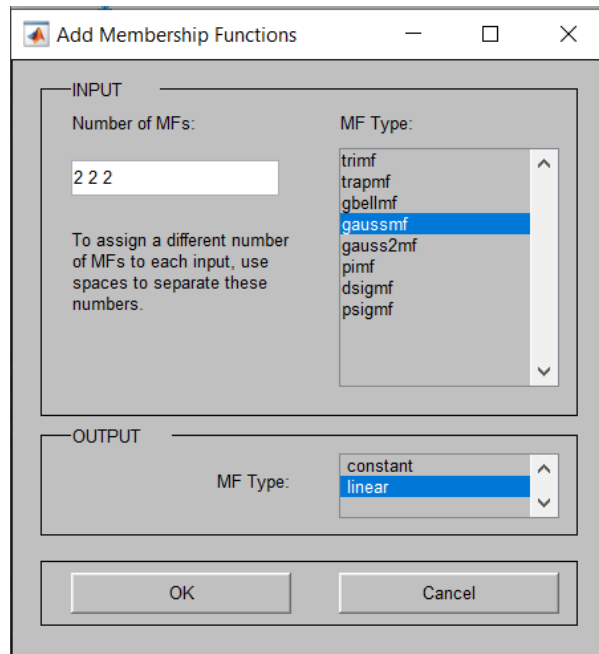


Рисунок 2.2 - Завдання параметрів ННМ

Створена в MatLAB ННМ, структура якої показана на рис. 2.3, що співпадає із запропонованою структурою ННМ, яка була представлена на рис. 2.1.

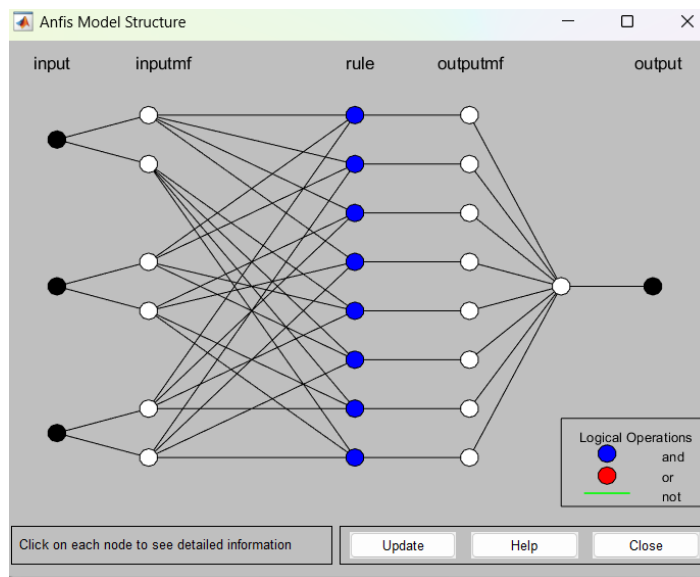


Рисунок 2.3 – Структура створеної в MatLAB ННМ

Для створення ННМ обрано алгоритм Сугено, який використовується для апроксимації функцій та моделювання систем на основі даних. Модель використовує нечіткі правила у формі "якщо-то" та лінійні вирази для виводу.

У цій моделі кожне нечітке правило визначає лінійну функцію, яка описує взаємозв'язок між вхідними змінними та вихідними змінними. На базі обраного алгоритму закладена система правил, яка представлена на рисунку 2.4.

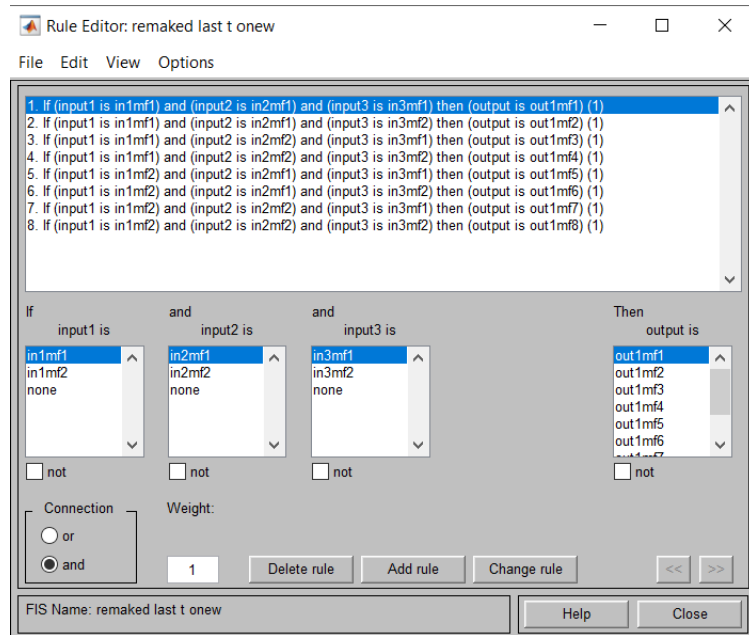


Рисунок 2.4 – Система правил для нейронечіткої мережі

Закладання системи правил є важливою частиною процесу моделювання ННМ, таких як ANFIS. Правила визначають взаємозв'язок між вихідними та результуючими змінними ННМ і встановлюють, яким чином вихідні змінні впливають на результуючі значення. У якості прикладу на рисунку 2.5 відображений результат апробації ННМ.



Рисунок 2.5 - Результат апробації створеної ННМ

Із рисунку видно, що при затримках на маршрутизаторі 1388 мкс, 1392 мкс та 1390 мкс спрогнозовано значення затримки на ННМ склало 1389 мкс.

При апробації ННМ для кожного вихідного нейрона (input) обрано Гауссовський (першого порядку) тип функції приналежності, який представлено на рисунку 2.6.

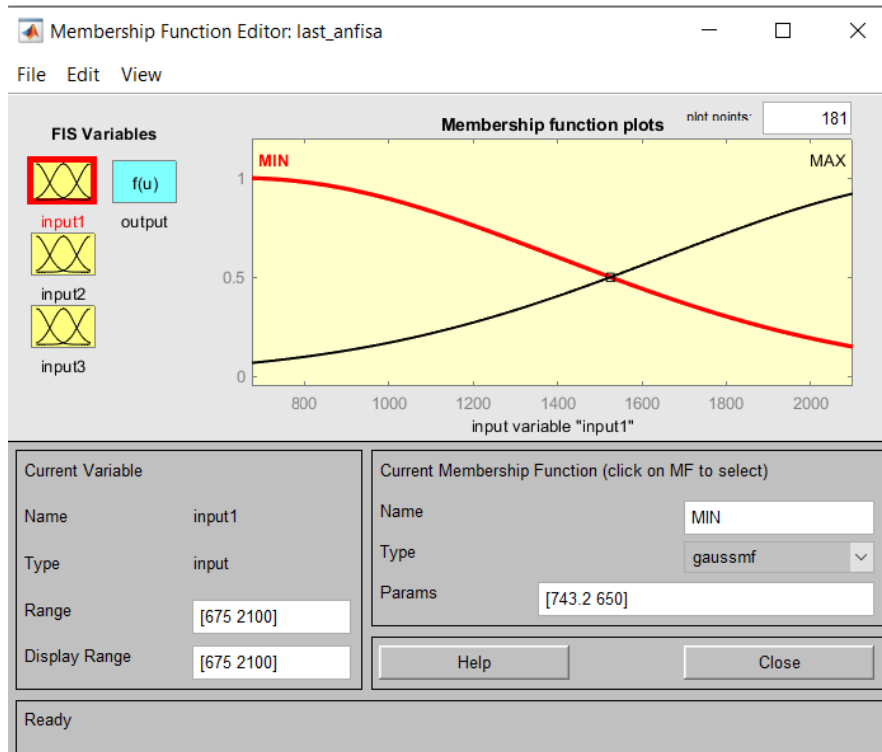


Рисунок 2.6 – Гауссовський тип функції приналежності

Функція Гауссовського типу приналежності (першого порядку) широко використовується в нечіткій логіці та нечітких системах для моделювання нечітких змінних та визначення їх ступенів належності до нечітких множин. Вона дозволяє враховувати ступінь впливу кожного значення на належність до множини, в залежності від відстані, центру та розмаху гауссовського розподілу.

Для створення ННМ в MatLAB обрано метод Сугено.

При апробації ННМ для результуючого нейрону (output) обрано лінійний тип функції приналежності, який представлено на рисунку 2.7.

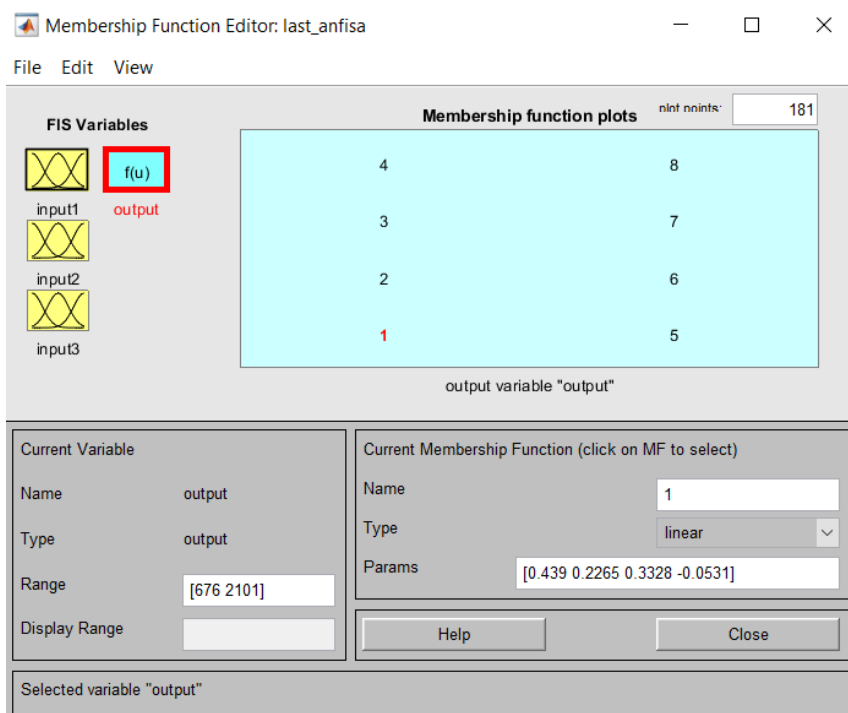


Рисунок 2.7 – Тип функції приналежності для результуючого нейрона

## 2.5 Навчання та тестування нейронечіткої мережі

Для навчання, тестування та валідації створеної ННМ необхідно скласти відповідні вибірки: навчальну, тестову та валідаційну. Від сформованих вибірок залежить, наскільки ефективним буде процес навчання та тестування, а також здатність ННМ вирішувати поставленні перед нею проблеми під час експлуатації. Для підготовки цих вибірок потрібен спеціальний масив із значень, які наближені до реальних.

Для навчання ННМ використана навчальна вибірка із 90 прикладів, фрагмент якої показаний на рисунку 2.8; повний обсяг навчальної вибірки наведений в додатку Б (див. таблицю Б.1).

The screenshot shows a Notepad window titled '\*training.txt - Notepad'. The content is a table of training data with four columns:  $x(t-1)$ ,  $x(t-2)$ ,  $x(t-3)$ , and  $x(t)$ . The data consists of 90 rows of numerical values.

$x(t-1)$	$x(t-2)$	$x(t-3)$	$x(t)$
675	679	677	676
705	709	707	706
850	854	852	851
1100	1104	1102	1101
1480	1484	1482	1481
1920	1924	1922	1921
1921	1925	1923	1922
1922	1926	1924	1923
1924	1928	1926	1925
1926	1930	1928	1927
1927	1931	1929	1928
1928	1932	1930	1929
1929	1933	1931	1930
1930	1934	1932	1931
1932	1936	1934	1933
1933	1937	1935	1934
1934	1938	1936	1935
1936	1940	1938	1937

Рисунок 2.8 – Фрагмент навчальної вибірки

За обраними параметрами проведено навчання ННМ протягом 40 епох, при цьому значення похибки склало 0,010797 (рисунок 2.9).

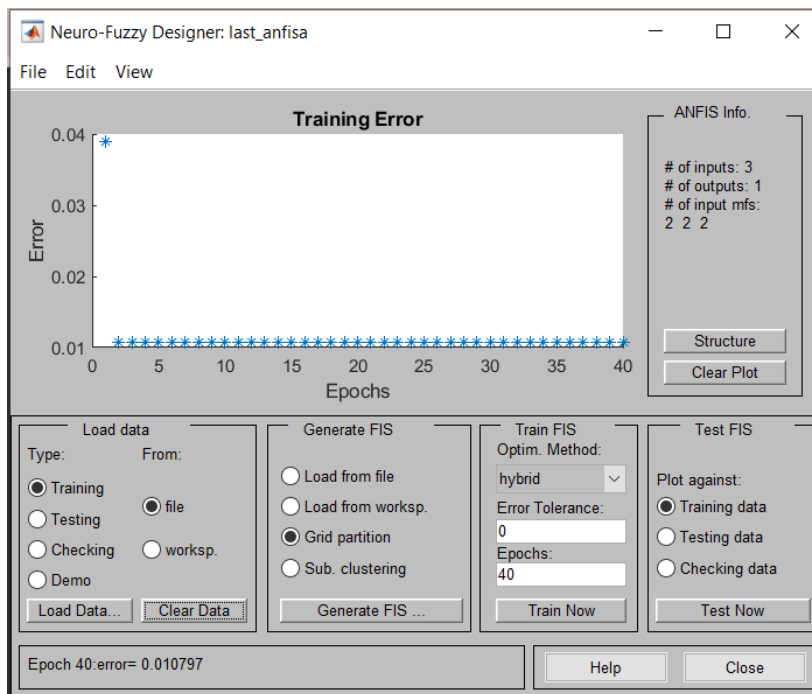


Рисунок 2.9 – Результат навчання нейронечіткої мережі

Для тестування ННМ використана тестова вибірка із 30 прикладів, фрагмент якої показаний на рисунку 2.10; повний обсяг тестувальної вибірки наведений в додатку Б (див. таблицю Б.2).

\*testing.txt - Notepad

File	Edit	Format	View	Help
x(t-1)	x(t-2)	x(t-3)	x(t)	
1660	1664	1662	1661	
1923	1927	1925	1924	
1925	1929	1927	1926	
1931	1935	1933	1932	
1935	1939	1937	1936	
1937	1941	1939	1938	
1943	1947	1945	1944	
1947	1951	1949	1948	
1949	1953	1951	1950	
1955	1959	1957	1956	
1959	1963	1961	1960	
1961	1965	1963	1962	
1967	1971	1969	1968	
1971	1975	1973	1972	
1973	1977	1975	1974	
1979	1983	1981	1980	
1983	1987	1985	1984	
1985	1989	1987	1986	
1991	1995	1993	1992	

Рисунок 2.10 – Фрагмент тестової вибірки

При тестуванні створенної ННМ похибка склала 0,00331654 (рисунок 2.11).

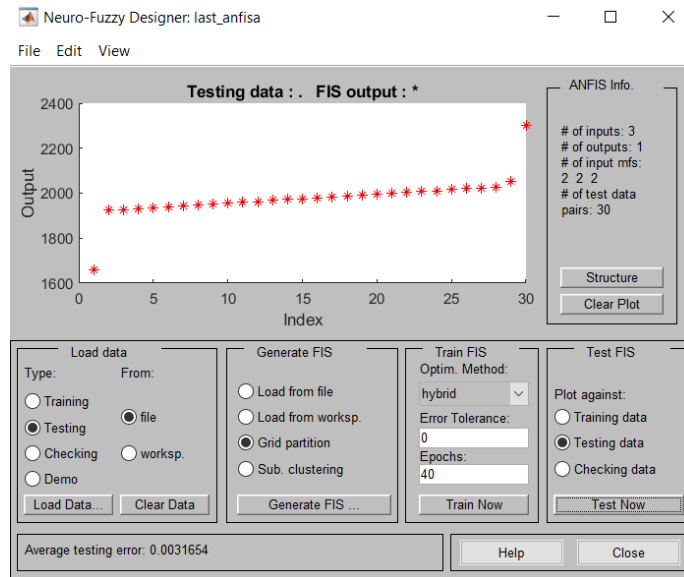


Рисунок 2.11 - Результати тестування нейронечіткої мережі

## 2.6 Висновки до розділу

1. Значення показника Херста склало приблизно 0,59 ( $\alpha=0,25$ ;  $N=120$ ), що перевищує 0,5; отже часовий ряд затримок на маршрутизаторі комп'ютерної мережі Придніпровської залізниці, які були отримані в [13] на відповідній імітаційній моделі мережі, персистентний і характеризується ефектом довгочасної пам'яті.

2. На основі проведеного в [11] аналізу обсягу мережевого трафіку в ІТС Придніпровської залізниці для здійснення прогнозу затримки на маршрутизаторі комп'ютерної мережі з глибиною занурення 3, що відповідає 15 хв., запропоновано обрати ННМ, на вхід якої подаються  $X(t-3)$ ,  $X(t-2)$ ,  $X(t-1)$  – це затримки на маршрутизаторі в часові моменти  $t-3$ ,  $t-2$ ,  $t-1$  відповідно; у якості результуючого нейрону  $X(t)$  – це затримка на маршрутизаторі в часовий момент  $t$ .

3. У режимі ANFIS за допомогою додатку Fuzzy Logic Toolbox системи MatLAB створена ННМ, апробація якої здійснено при наступних параметрах: кількість правил складало  $2^3=8$ ; Гауссовський тип приналежності для вихідних нейронів; лінійний тип приналежності для результуючого нейрону; гібридний метод оптимізації навчання. Проведено навчання (90 прикладів) та тестування (30 прикладів) створеної ННМ, при цьому значення похибок склали приблизно 0,011 та 0,003 відповідно.

## 3 ДОСЛІДЖЕННЯ НА СТВОРЕНІЙ НЕЙРОНЕЧІТКІЙ МЕРЕЖІ

### 3.1 Визначення оптимальних параметрів

Для визначення оптимальних параметрів нейронечіткої мережі проведено навчання та тестування з використанням наступних функцій приналежності нейронів: трикутна (trimf), трапецієподібна (trapmf), узагальнена дзвоноподібна (gbellmf), Гаусова першого та другого порядку (gaussmf та gauss2mf), S-подібні (pimf), різниця двох сигмоїдних (dsigmf) та добуток двох сигмоїдних (psigmf).

Отримані результати похибок ННМ при навчанні та тестуванні за різними функціями приналежності нейронів представлені на рис. 3.1 — рис. 3.21, що зведені до підсумкової таблиці 3.1.

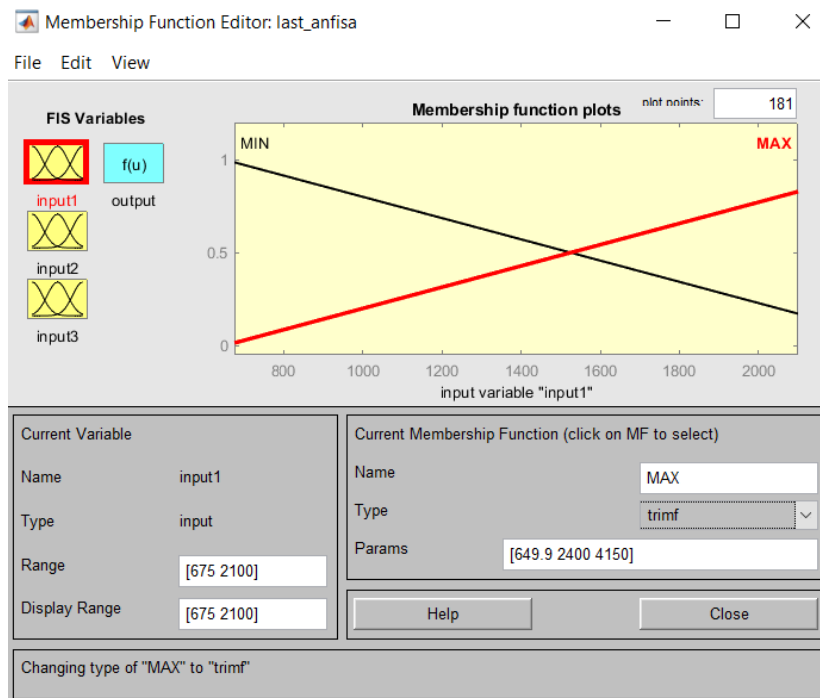


Рисунок 3.1 – Трикутна функція приналежності

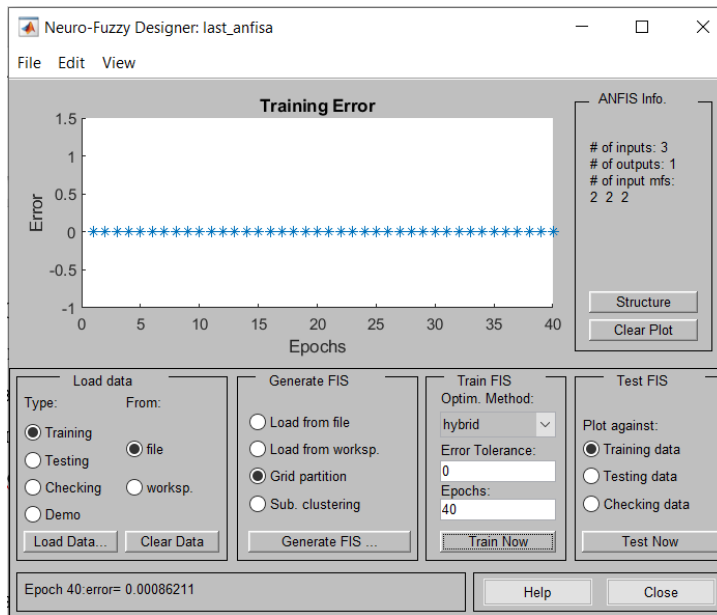


Рисунок 3.2 – Результати навчання ННМ з трикутною функцією приналежності



Рисунок 3.3 – Результати тестування ННМ з трикутною функцією приналежності

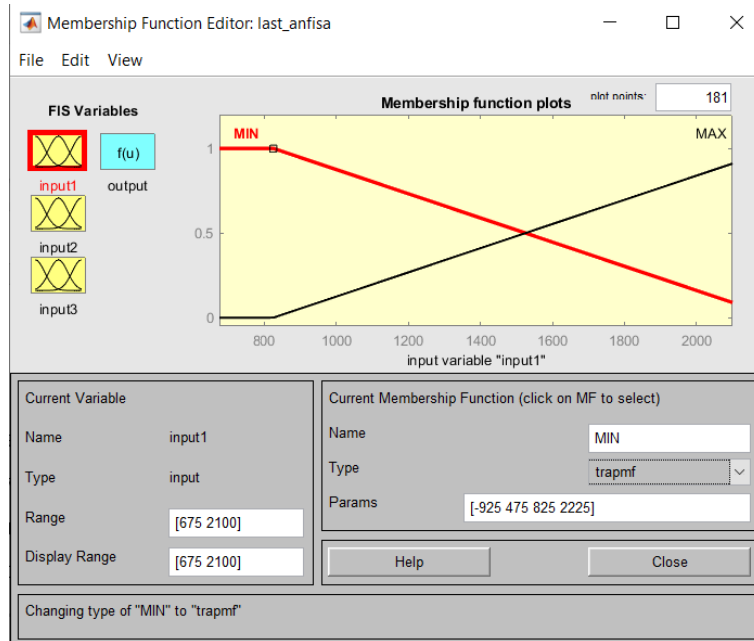


Рисунок 3.4 – Трапецієподібна функція приналежності

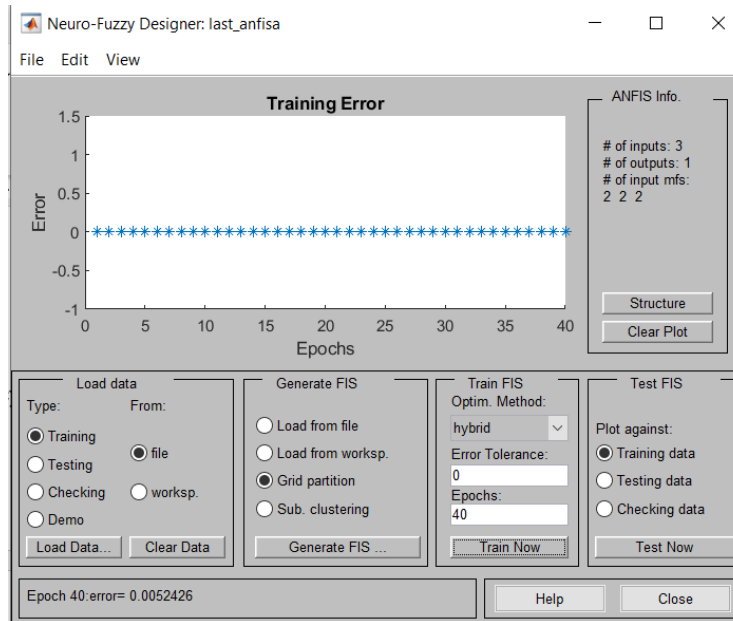


Рисунок 3.5 – Результати навчання ННМ з трапецієподібною функцією приналежності

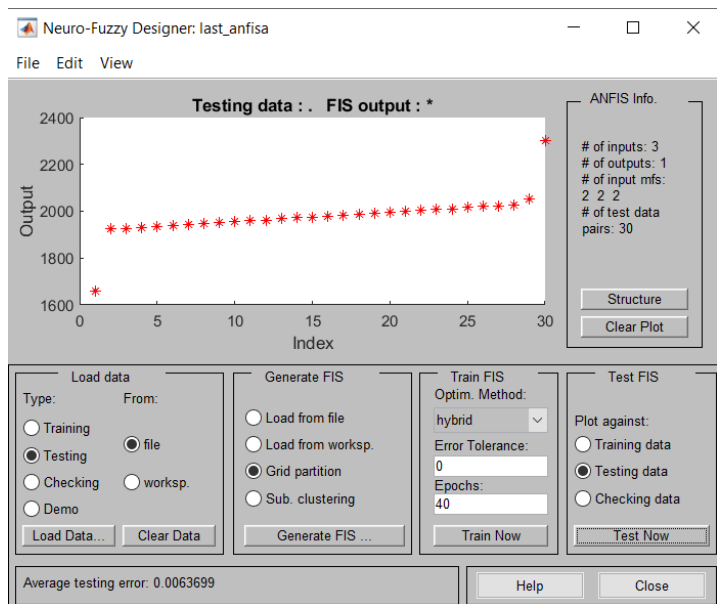


Рисунок 3.6 - Результати тестування НМ з трапецієподібною функцією приналежності

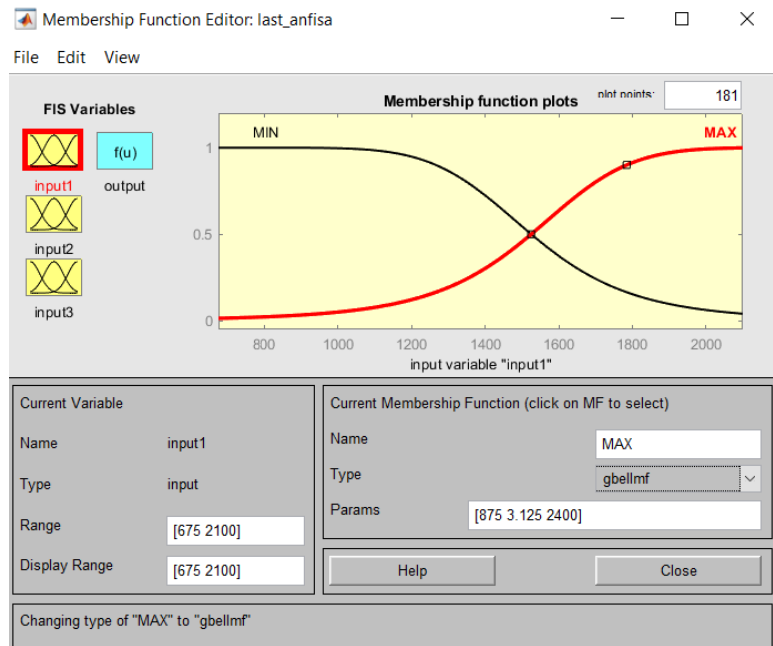


Рисунок 3.7 - Узагальнена дзвоноподібна функція приналежності

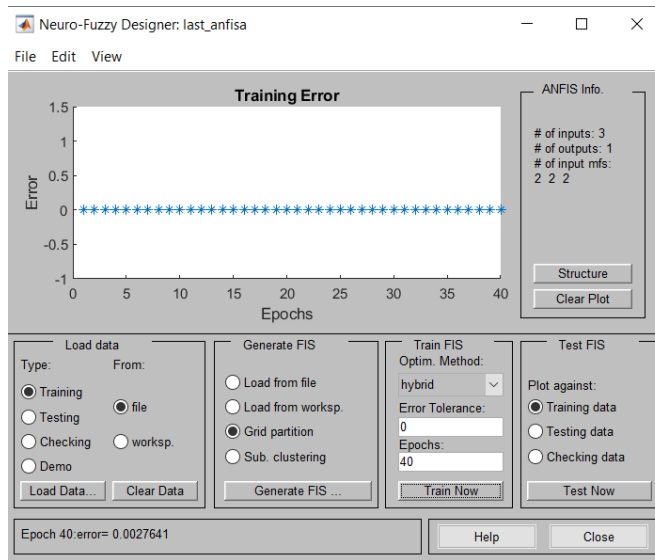


Рисунок 3.8 - Результати навчання ННМ з узагальнено дзвоноподібною функцією приналежності



Рисунок 3.9 - Результати тестування ННМ з узагальнено дзвоноподібною функцією приналежності

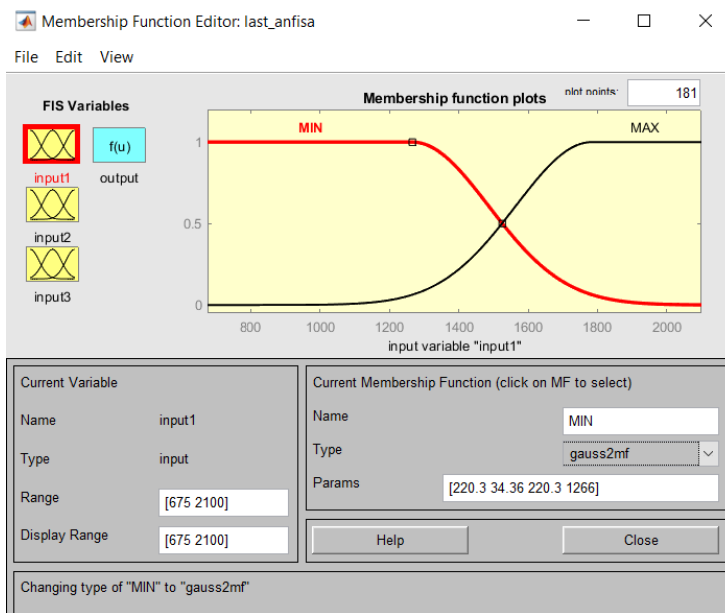


Рисунок 3.10 - Гаусова (2-го порядку) функція приналежності

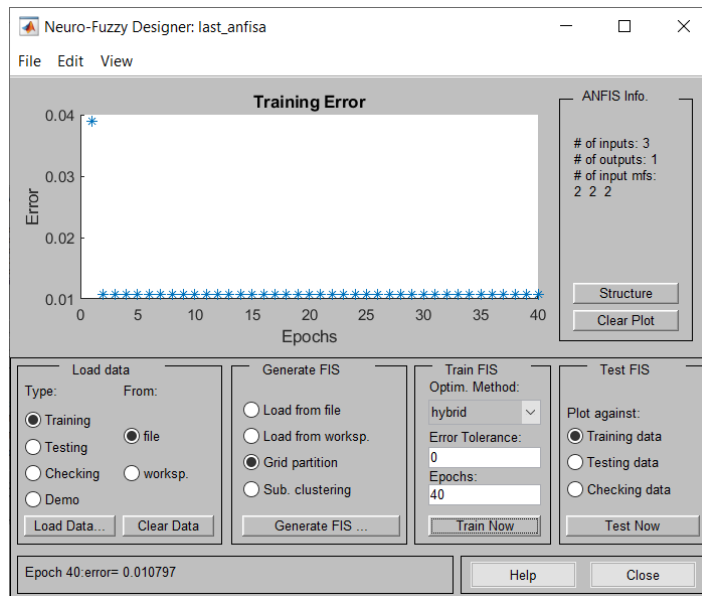


Рисунок 3.11 - Результати навчання ННМ з Гаусовою (2-го порядку) функцією приналежності

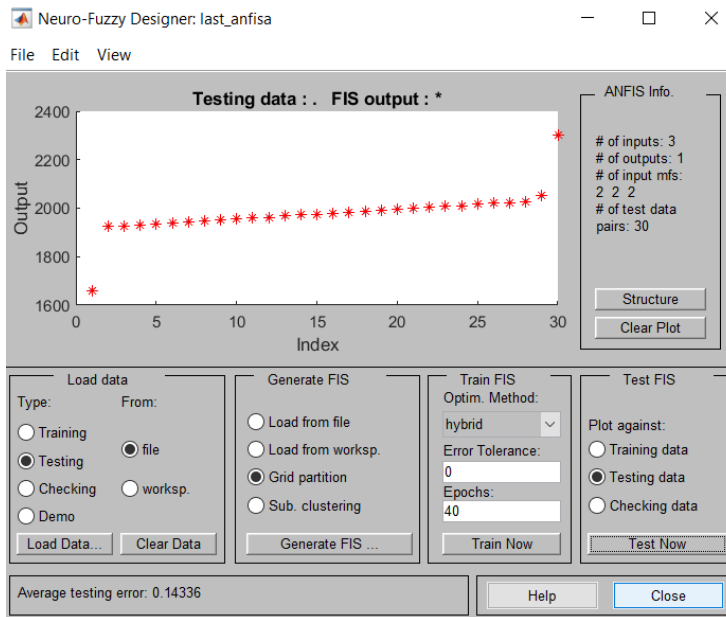


Рисунок 3.12 - Результати тестування ННМ з Гаусовою (2-го порядку) функцією приналежності

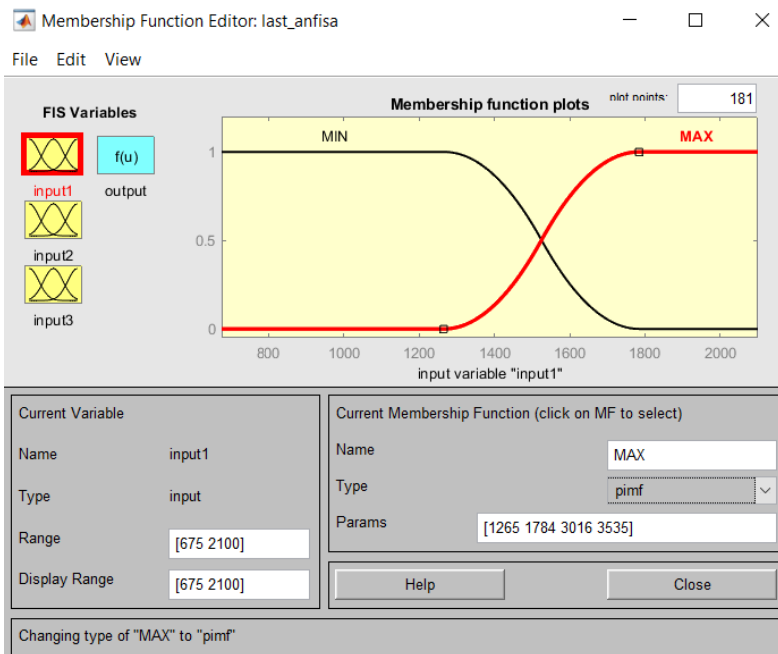


Рисунок 3.13 - S-подібна функція приналежності

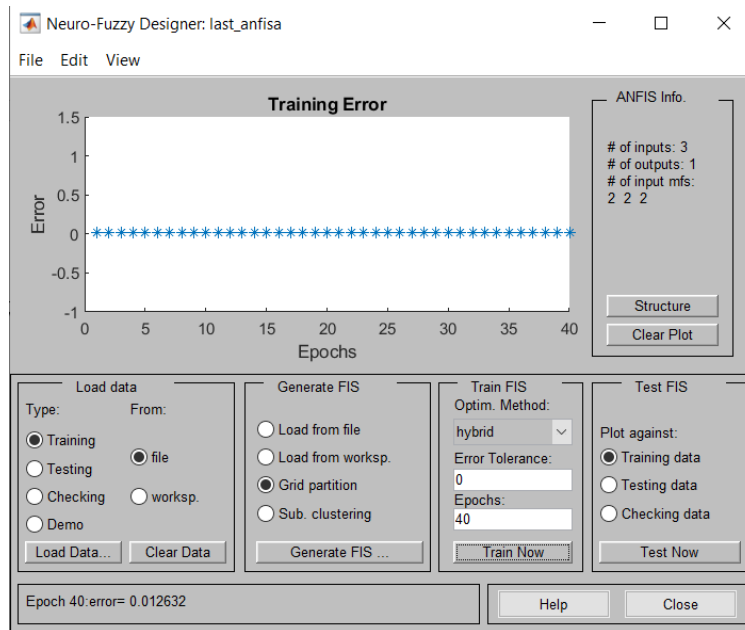


Рисунок 3.14 - Результати навчання ННМ з S-подібною функцією приналежності



Рисунок 3.15 - Результати тестування ННМ з S-подібною функцією приналежності

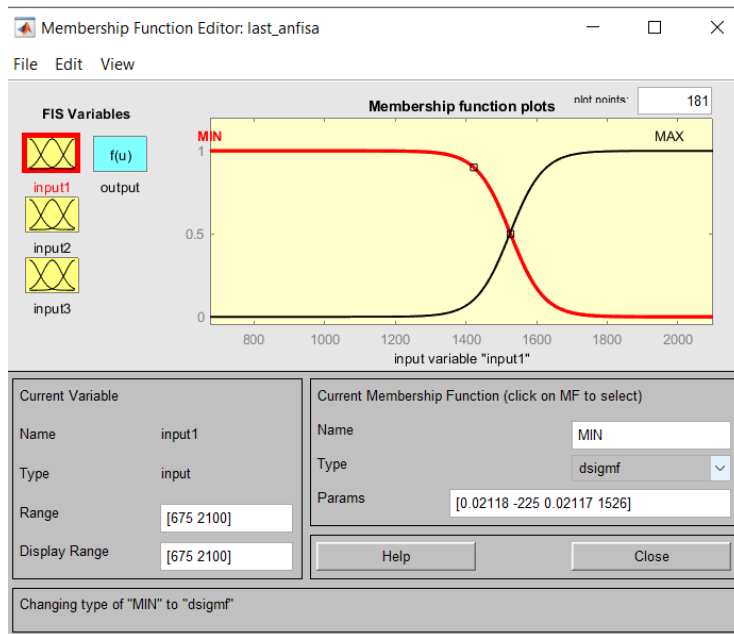


Рисунок 3.16 – Функція приналежності різниці двох сигмоїдних

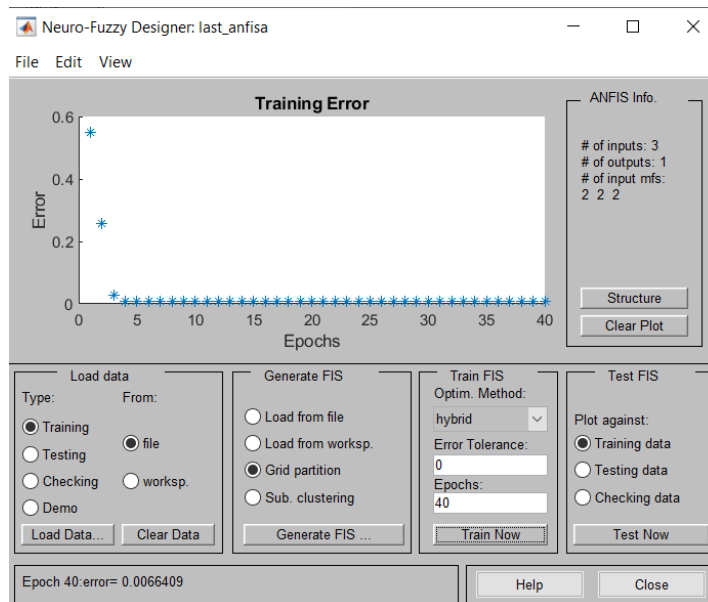


Рисунок 3.17 - Результати навчання ННМ з різницею двох сигмоїдних функцій приналежності



Рисунок 3.18 - Результати тестування ННМ з різницею двох сигмоїдних функцій приналежності

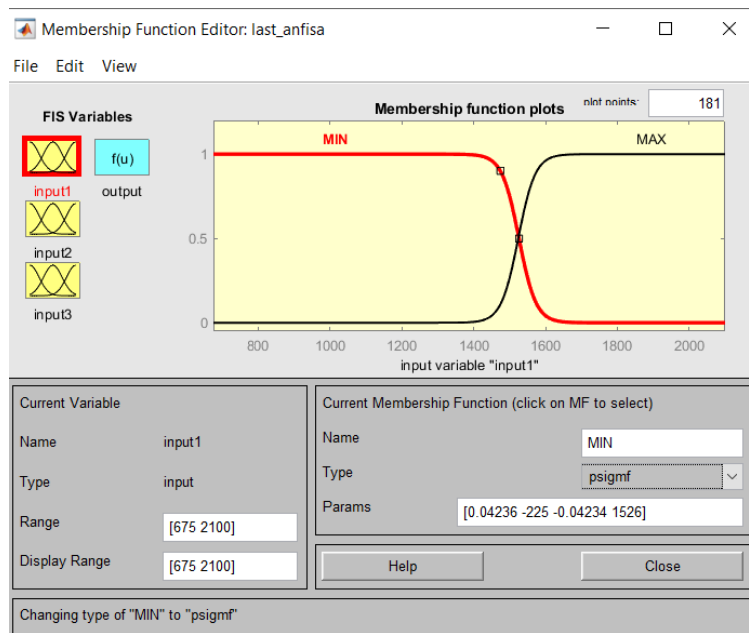


Рисунок 3.19 – Функція приналежності добутку двох сигмоїдних

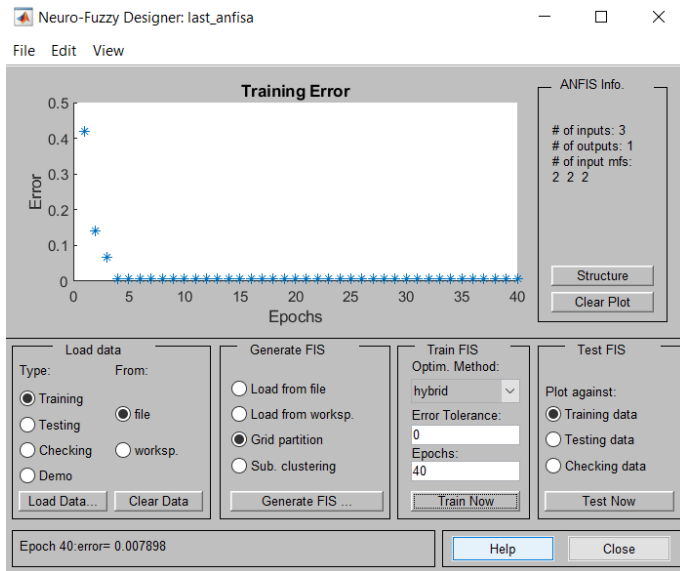


Рисунок 3.20 - Результати навчання ННМ з добуток двох сигмоїдних функцій приналежності



Рисунок 3.21- Результати тестування ННМ з добуток двох сигмоїдних функцій приналежності

Таблиця 3.1 – Значення похибок ННМ за гібридним методом

Тип функції приналежності нейронів	Похибка ННМ	
	навчання	тестування
Трикутна	0,00086211	0,01766700
Трапецієподібна	0,00524260	0,00636990
Узагальнена дзвоноподібна	0,00276410	0,02231600
Гаусова (2-го порядку)	0,01079700	0,14336000
S-подібні	0,01263200	0,16072000
Різниця двох сигмоїдних функцій	0,00664090	0,06590300
Добуток двох сигмоїдних функцій	0,00789800	0,06593000

Із таблиці видно, що найменше значення похибки навчання ННМ досягнуто при використанні трикутної функції приналежності вихідних (input) нейронів.

Крім того, проведено дослідження ННМ за різними алгоритмами оптимізації навчання: зворотнього поширення помилки (backpropa) та гібридний (hybrid).

Виконано навчання ННМ при використанні трикутної функції приналежності та алгоритму зворотнього поширення помилки, значення похибки склало 0,8211. Таким чином, найкращі значення похибки ННМ при використанні гібридного методу оптимізації.

### 3.2 Оцінка якості прогнозу на створеній нейронечіткій мережі

Для оцінки якості та точності прогнозу розраховано значення MAPE (Mean Absolute Percentage Error) за формулою [13]:

$$MAPE = \frac{1}{N} \sum_{t=1}^N \frac{|Z(t) - Z_1(t)|}{Z(t)} \quad (3.1)$$

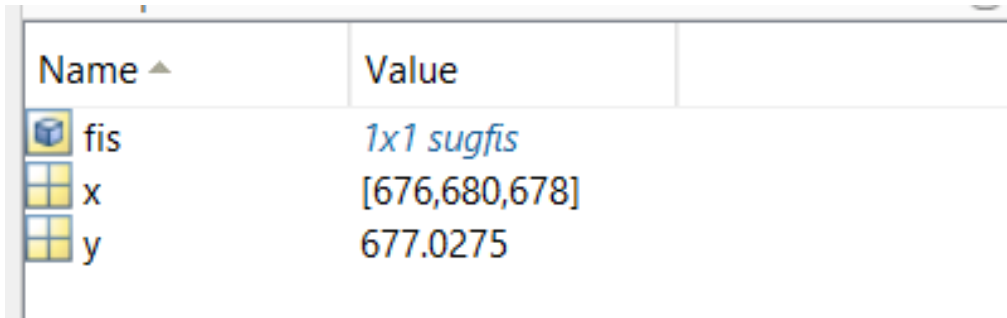
де N – кількість годин;

Z(t) – реальні дані в момент часу t;

Z<sub>1</sub>(t) – прогнозовані дані в момент часу t.

Розрахунок MAPE виконаний на контрольній вибірці (10 прикладів), при цьому отримані результати спрогнозованої затримки на маршрутизаторі засобами ННМ показані на рис. 3.22 - рис. 3.31. Крім того, проведено співставлення отриманих

результатів прогнозування різними засобами: з використанням НМ (з глибиною занурення - 4), що була створена в [19], та ННМ (з глибиною занурення - 3); при цьому використана одна контрольна вибірка. Отримані результати зведені до таблиці 3.2.






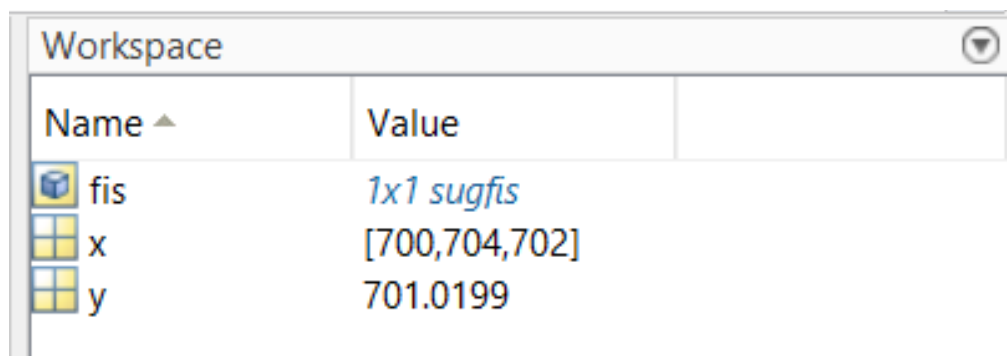
Name ▲	Value
 fis	<i>1x1 sugfis</i>
 x	[676,680,678]
 y	677.0275

Рисунок 3.22 – Результати першого прогнозу






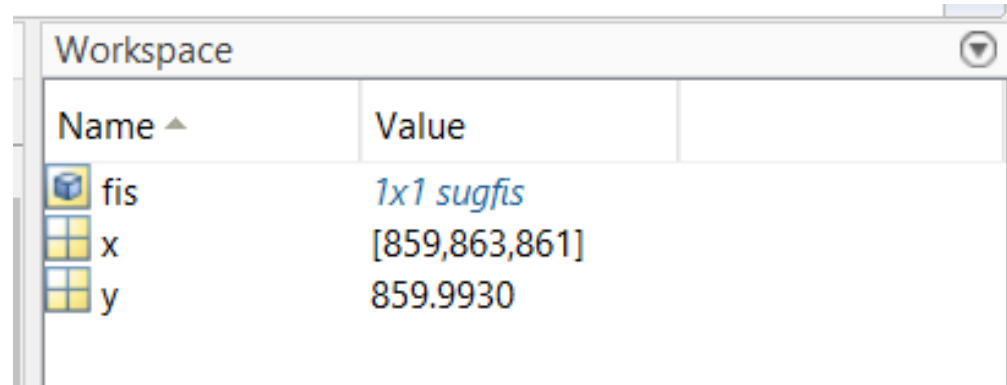
Name ▲	Value
 fis	<i>1x1 sugfis</i>
 x	[700,704,702]
 y	701.0199

Рисунок 3.23 – Результати другого прогнозу






Name ▲	Value
 fis	<i>1x1 sugfis</i>
 x	[859,863,861]
 y	859.9930

Рисунок 3.24 – Результати третього прогнозу




Workspace	
Name ▲	Value
 fis	<i>1x1 sugfis</i>
 x	[1119,1123,1121]
 y	1.1200e+03

Рисунок 3.25 – Результаты четвертого прогнозу




Workspace	
Name ▲	Value
 fis	<i>1x1 sugfis</i>
 x	[1495,1499,1497]
 y	1.4960e+03

Рисунок 3.26 – Результаты п'ятого прогнозу




Workspace	
Name ▲	Value
 fis	<i>1x1 sugfis</i>
 x	[1667,1671,1669]
 y	1.6680e+03

Рисунок 3.27 – Результаты шостого прогнозу




Workspace	
Name ▲	Value
 fis	<i>1x1 sugfis</i>
 x	[1688,1692,1690]
 y	1.6890e+03

Рисунок 3.28 – Результаты сьомого прогнозу




Workspace	
Name ▲	Value
 fis	<i>1x1 sugfis</i>
 x	[2121,2125,2123]
 y	2.1220e+03

Рисунок 3.29 – Результаты восьмого прогнозу




Workspace	
Name ▲	Value
 fis	<i>1x1 sugfis</i>
 x	[2221,2225,2223]
 y	2.2220e+03

Рисунок 3.30 – Результаты дев'ятого прогнозу




Workspace	
Name ▲	Value
 fis	<i>1x1 sugfis</i>
 x	[2298,2302,2300]
 y	2.2990e+03

Рисунок 3.31 – Результаты десятого прогнозу

Таблиця 3.2 - Оцінка прогнозу з використанням різних нейромережних засобів

Час, год.	Контрольна вибірка, мкс	НМ (глибина занурення - 4)		ННМ (глибина занурення - 3)	
		Прогноз, мкс	$( Z(t)-Z_1(t) )/Z(t)$	Прогноз, мкс	$( Z(t)-Z_1(t) )/Z(t)$
8..9	676	690	0,02071006	677	0,00147929
9..10	700	715	0,02142857	701	0,00142857
10..11	859	845	0,01629802	860	0,00116414
11..12	1119	1120	0,00089366	1120	0,00089366
12..13	1495	1499	0,00267559	1496	0,00066896
13..14	1667	1703	0,02159568	1668	0,00059988
14..15	1688	1782	0,05568720	1689	0,00059242
15..16	2121	2035	0,04054691	2122	0,00047148
16..17	2221	2205	0,00720396	2222	0,00045025
17..18	2298	2280	0,00783289	2299	0,00043516
<b>MAPE, %</b>			<b>1,94872548</b>		<b>0,08183739</b>

Із таблиці видно, що отримане значення MAPE на створеній ННМ (з глибиною занурення - 3) склало приблизно 0,08 %, що навіть негірше за отриманий прогноз засобами НМ (з глибиною занурення - 4).

### 3.3 Висновки до розділу

1. На створеній ННМ, в основі якої 8 правил, за гібридним алгоритмом оптимізації навчання проведено дослідження похибки при використанні різних функцій приналежності вихідних (input) нейронів: трикутна (trimf); трапецієподібна (trapmf); узагальнена дзвоноподібна (gbellmf); Гаусова (gausmf та gauss2mf); S-подібні (pimf); різниця двох сигмоїдних (dsigmf); добуток двох сигмоїдних, при цьому найменше значення похибки отримано при трикутній функції приналежності.

2. На створеній ННМ, в основі якої 8 правил, при використанні трикутної функції приналежності для вихідних (input) нейронів проведено дослідження похибки за різними алгоритмами оптимізації навчання: Backprop та Hybrid, при цьому найкраще значення похибки надав Hybrid, результат помилки склав 0,00086211.

3. Виконана оцінка прогнозу затримки на маршрутизаторі компютерної мережі на створеній ННМ, при цьому взято 10 часових проміжків. Отримане значення MAPE на створеній ННМ (з глибиною занурення - 3) склало приблизно 0,08 %, що навіть негірше за отриманий прогноз засобами НМ (з глибиною занурення - 4).

## ВИСНОВКИ ТА РЕКОМЕНДАЦІЇ

1. Виконаний огляд наукових джерел щодо придатності нейронних мереж для прогнозування: багат шарового персептрону; радіально-базисної мережі; узагальнено-регресійної мережі; мережі Вольтерра; мережі Елмана та нейронечіткої мережі, для здійснення прогнозування затримки на маршрутизаторі комп'ютерної мережі обрано нейронечітку мережу (ННМ) та систему MatLAB для її створення.

2. Проведений розрахунок показника Херста для часового ряду затримок на маршрутизаторі комп'ютерної мережі Придніпровської залізниці, які були отримані в [13] на відповідній імітаційній моделі мережі. Значення показника Херста склало приблизно 0,59 ( $a=0,25$ ;  $N=120$ ), що перевищує 0,5; отже часовий ряд затримок на маршрутизаторі комп'ютерної мережі персистентний і характеризується ефектом довгочасної пам'яті.

3. На основі проведеного в [11] аналізу обсягу мережевого трафіку в ІТС Придніпровської залізниці для здійснення прогнозу затримки на маршрутизаторі комп'ютерної мережі з глибиною занурення 3, що відповідає 15 хв., запропоновано ННМ, на вхід якої подаються  $X(t-3)$ ,  $X(t-2)$ ,  $X(t-1)$  – це затримки на маршрутизаторі в часові моменти  $t-3$ ,  $t-2$ ,  $t-1$  відповідно; у якості результуючого нейрону  $X(t)$  – це затримка на маршрутизаторі в часовий момент  $t$ .

4. У режимі ANFIS за допомогою додатку Fuzzy Logic Toolbox системи MatLAB створена ННМ, в основі якої система із  $2^3=8$  правил, при наступних параметрах: Гауссовський тип приналежності для вихідних (input) нейронів; лінійний тип приналежності для результуючого нейрону; гібридний метод оптимізації навчання. Проведено навчання (90 прикладів) та тестування (30 прикладів) створеної ННМ, при цьому значення похибок склали приблизно 0,011 та 0,003 відповідно.

5. На створеній ННМ проведено дослідження похибки при використанні різних функцій приналежності вихідних (input) нейронів за різними методами оптимізації: зворотнього поширення помилки (Backpropa) та гібридним (Hybrid). Крім того, виконана оцінка (засобами MAPE; 10 часових проміжків) прогнозу затримки на маршрутизаторі комп'ютерної мережі. Отримане значення MAPE на створеній ННМ (глибина занурення - 3) склало приблизно 0,08 %, що навіть негірше за отриманий прогноз в [19] засобами НМ (глибина занурення - 4).

## ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Багатошаровий персептрон. Програмна інженерія. URL: [https://studwood.net/1860377/informatika/bagatosharoviy\\_perseptron](https://studwood.net/1860377/informatika/bagatosharoviy_perseptron).
2. Руккас К. М., Овчинников К. А. Порівняльний аналіз методів прогнозування трафіку в телекомунікаційних системах. Проблеми телекомунікацій. 2014. С. 93.
3. Радіально базисна мережа. Навчальна інформація. URL: [http://ni.biz.ua/15/15\\_6/15\\_68262\\_radialnie-bazisnie-seti.html](http://ni.biz.ua/15/15_6/15_68262_radialnie-bazisnie-seti.html).
4. Савка Н. Я. Застосування штучних нейронних мереж з радіально-базисними функціями для розв'язування задач прогнозування. Комунальне господарство міст. 2019. С. 353.
5. Узагальнено- регресійна мережа. StudFiles. URL: <https://studfile.net/preview/9068614/page:127>.
6. Тоніца О. В., Лотарєв М. С., Решетнікова С.М. Прогнозування надзвичайних ситуацій за допомогою нейронних мереж. Інформаційні технології. 2022. С. 2.
7. Мережа Вольтерра. Volterra Neural Networks. URL: <https://ar5iv.labs.arxiv.org/html/1910.09616#:~:text=,Raleigh%2C%20NC%2027606%2C%20USA>.
8. Соловійов А. І. Прогнозування та нейромережеве моделювання в управлінні виробничими структурами. Науковий вісник УжНУ. 2021. С. 89.
9. Мережа Елмана. Нейронні мережі. URL: [https://www.wikidata.ukua.nina.az/%D0%9C%D0%B5%D1%80%D0%B5%D0%B6%D0%B0\\_%D0%95%D0%BB%D0%BC%D0%B0%D0%BD%D0%B0.html](https://www.wikidata.ukua.nina.az/%D0%9C%D0%B5%D1%80%D0%B5%D0%B6%D0%B0_%D0%95%D0%BB%D0%BC%D0%B0%D0%BD%D0%B0.html)
10. Руденко О. Г., Безсонов О.О., Романюк О.С. Нейромережеве прогнозування часових рядів на основі багатошарового персептрона. Development Management. 2019. С. 33. Doi:10.1007/978-3-030-27192-321.
11. Pakhomova V. M. Network traffic forecasting in information-telecommunication system of Prydniprovsk railways based on neuro-fuzzy network. Наука та прогрес транспорту. 2016. № 6(66). С. 105-114. DOI: 10.15802/stp2016/90485.
12. Нейронечітка мережа. Нечітка логіка в MatLab. URL: <https://studfile.net/preview/5474324/page:3/>.

13. Pakhomova V. M., Mandybura Y. S. Optimal route definition in the railway information network using neural-fuzzy models. Наука та прогрес транспорту. 2019. № 5(83). С. 81-98. DOI: 10.15802/stp2019/184385.
14. Костенніков О. М. Удосконалення технології формування місцевого вагонопотоку на дільниці в умовах сезонного коливання обсягів навантаження. автореф. дисерт. на здоб. наук. ступ. к.т.н. Харків. 2012, 20 с. DOI: [10.16452/0323-8412](https://doi.org/10.16452/0323-8412).
15. Солодовник М. С., Асланов А. М. Використання нейро-нечіткого підходу у прогнозуванні виходу з ладу модуля серверної пам'яті. Ret Journal. 2022. С. 14. DOI: 10.15673/0453-8307.
16. Кісельова О. М., Притоманова О. М., Дон Я. Б. Розробка нейронечіткої моделі короткострокового прогнозу в умовах нечіткої інформації. Прикладні питання математичного моделювання. 2022. С. 82. DOI: 10.15421/322008.
17. Пахомова В. М., Дмитрієв С. Ю. Розробка підсистеми оперативного прогнозування простоїв прибуваючих поїздів на основі ANFIS-системи. Інформаційно-керуючі системи на залізничному транспорті. 2013. С. 46 - 55. URL: [http://nbuv.gov.ua/UJRN/Ikszt\\_2013\\_4\\_10](http://nbuv.gov.ua/UJRN/Ikszt_2013_4_10).
18. Волошко А. В., Бедерак Я. С. Визначення показника Херста при фрактальному аналізі електричних навантажень. Енергетика: економіка, технології. 2020. С. 22-28. DOI:0000-0002-2669-0965.
19. Ріпка Є. В. Прогнозування затримок маршрутизаторів з використанням нейромережної технології. Дипломна робота на здобуття кваліфікаційного ступеня бакалавра : спец. 123 – Комп'ютерна інженерія / наук. керівник В. М. Пахомова; Укр. держ. ун-т науки і техн. Дніпро, 2020.
20. Хрестян А. В., керівник доц. Пахомова В. М. Прогнозування затримки на маршрутизаторі комп'ютерної мережі залізничного транспорту засобами нейронечіткої мережі. Всеукраїнська науково-технічна конференція здобувачів

вищої освіти та молодих учених “Наука і сталий розвиток транспорту” (27 жовтня 2023 р.), УДУНТ. Збірник тез. Том 2. Дніпро: УДУНТ, С. 12.

21. Пахомова В. М., Хрестян А. В. Прогнозування затримки на маршрутизаторі в інформаційно-телекомунікаційній системі залізничного транспорту засобами нейронечіткої мережі. XVII Міжнародна науково-практична конференція “Сучасні інформаційні та комунікаційні технології на транспорті, в промисловості та освіті” (13-14 грудня 2023 р.), УДУНТ. Дніпро: УДУНТ, 2023. С. 86.