

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет _____ Комп'ютерних наук
(повна назва)

Кафедра _____ Штучного інтелекту
(повна назва)

АТЕСТАЦІЙНА РОБОТА
Пояснювальна записка

Рівень вищої освіти _____ другий (магістерський)
(рівень вищої освіти)

_____ Ансамбль нейро-фаззі систем
_____ для потокової обробки даних
(тема)

Виконав:
студент 2 курсу, групи СШМ-18-1
Писаренко Д.О.
(прізвище, ініціали)

Спеціальність 122 – Комп'ютерні науки
(код і повна назва спеціальності)

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

Освітня програма Системи штучного
інтелекту (СШІ)
(повна назва освітньої програми)

Керівник _____ проф. Бодянський Є.В.
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри _____
(підпис)

В.О. Філатов
(прізвище, ініціали)

2019 р.

Харківський національний університет радіоелектроніки

Факультет _____ Комп'ютерних наук _____

Кафедра _____ Штучного інтелекту _____

Рівень вищої освіти _____ другий (магістерський) _____

Спеціальність _____ 122 – Комп'ютерні науки _____
(код і повна назва)

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

Освітня програма _____ Системи штучного інтелекту (СШІ) _____
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

«_____» _____ 2019 р.

ЗАВДАННЯ

НА АТЕСТАЦІЙНУ РОБОТУ

студентові _____ Писаренко Дмитру Олеговичу _____
(прізвище, ім'я, по батькові)

1. Тема роботи _____ Ансамбль нейро-фаззі систем для потокової обробки даних _____

затверджена наказом по університету від 04 листопада 2019 р. № 1623Ст

2. Термін подання студентом роботи до екзаменаційної комісії 18 грудня 2019 р.

3. Вихідні дані до роботи Науково-технічні публікації, дані Інтернет-джерел та відомих наукових проектів щодо розробки та дослідження еволюційних нейронних мереж та еволюційних нейро-фаззі систем, дані відомих наукових проектів щодо розробки та дослідження алгоритмів прогнозування, науково-технічні публікації стосовно розробки ансамблів нейро-фаззі систем для вирішення різних задач, часові ряди різної нестационарної природи, деталі технічної реалізації

4. Перелік питань, що потрібно опрацювати в роботі Мета роботи, аналіз предметної області і постановка задачі дослідження, ансамбль нейро-фаззі систем з ядерними функціями належності, гібридні методи навчання нечітких систем, методи навчання еволюційного ансамблю нейро-фаззі систем з ядерними функціями належності, експериментальні дослідження, імітаційне моделювання.

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (п.5 включається до завдання за рішенням випускової кафедри)
Рисунок 1 – Архітектура нечіткої системи з фаззифікатором і дефаззифікатором, Рисунок 2 – Структура нечіткої нейронної мережі ТСК нульового порядку, Рисунок 3 – Архітектура нечіткої нейронної мережі Ванга-Менделя, Рисунок 4 – Модель узагальненої регресійної нейро-фаззі мережі, Рисунок 5 – Ансамбль нейро-фаззі систем, Рисунок 6 – Результати ідентифікації динамічного об'єкта за допомогою ансамблю нейро-фаззі систем – пакетний режим навчання, Рисунок 7 – Результати ідентифікації динамічного об'єкта за допомогою еволюційної нейро-фаззі системи – режим послідовної обробки інформації, Рисунок 8 – Графічне відображення даних по споживанню електроенергії, Рисунок 9 – Результати роботи в режимі навчання мережі, Рисунок 10 – Результати прогнозування часового ряду споживання електроенергії, Рисунок 11 – Графік зміни помилки прогнозування на тимчасовому ряді споживання електроенергії, Рисунок 12 – Прогноз на 60 спостережень, Рисунок 13 – Результати апроксимації часового ряду споживання електроенергії, Рисунок 14 – Графік зміни похибки апроксимації часового ряду споживання електроенергії.

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
Основна частина	проф. Бодянський Є.В.		

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Отримання завдання на атестаційну роботу	04.11.19	виконано
2	Аналіз предметної області і постановка завдання	04.11.19-12.11.19	виконано
3	Дослідження методів навчання	13.11.19-16.11.19	виконано
4	Створення імітаційної моделі	17.11.19-21.11.19	виконано
5	Тестування і відладка імітаційної моделі	22.11.19-28.11.19	виконано
6	Обробка і оформлення результатів	29.11.19-01.12.19	виконано
7	Оформлення пояснювальної записки	02.12.19-10.12.19	виконано
8	Нормоконтроль	11.12.19	виконано
9	Попередній захист	16.12.19	виконано
10	Захист перед ЕК	18.12.19	

Дата видачі завдання 04 листопада 2019 р.

Студент _____
 (підпис)

Керівник роботи _____ проф. Бодянський Є.В.
 (підпис) (посада, прізвище, ініціали)

РЕФЕРАТ

Пояснювальна записка: 76 сторінок, 14 рисунків, 63 формул, 2 таблиці, 2 додатки, 37 джерел.

АНАСАМБЛЬ НЕЙРО-ФАЗЗИ СИСТЕМ, ГІБРИДНА СИСТЕМА ОБЧИСЛЮВАЛЬНОГО ІНТЕЛЕКТУ, ДЗВОНУВАТА ФУНКЦІЯ НАЛЕЖНОСТІ, ЕВОЛЮЦІЙНА НЕЙРОННА МЕРЕЖА, ІМІТАЦІЙНЕ МОДЕЛЮВАННЯ, НЕЙРО-ФАЗЗИ СИСТЕМА, НЕЧІТКА МАНИНА ОПОРНИХ ВЕКТОРІВ, НЕСТАЦІОНАРНИЙ РЯД СПОЖИВАННЯ ЕЛЕКТРОЕНЕРГІЇ, ОБЧИСЛЮВАЛЬНИЙ ІНТЕЛЕКТ, СИСТЕМА ТАКАГІ-СУГЕНА-КАНГА

Об'єктами дослідження є методи побудови еволюційного ансамблю нейро-фаззі систем з дзвонуватими функціями належності.

Метою даної роботи є дослідження методів побудови еволюційних нейронних мереж та нейро-фаззі систем, що на даний момент є найбільш передовим напрямком розвитку обчислювального інтелекту.

Предметом дослідження є моделювання еволюційної нейро-фаззі систем, основним завданням якої буде прогнозування нестационарних рядів. Проведення імітаційного моделювання на даних, згенерованих за допомогою диференційного рівняння та даних по споживання електроенергії. Буде створено програмний комплекс для прогнозування споживання електроенергії, комплекс буде включати в себе модуль, який генерує дані на основі диференційного рівняння.

Методи дослідження – аналіз літератури та джерел в мережі Internet.

РЕФЕРАТ

Пояснительная записка: 76 страниц, 14 рисунков, 2 таблицы, 63 формул, 2 приложения, 37 источников.

АНАСАМБЛЬ НЕЙРО-ФАЗЗИ СИСТЕМ, ВЫЧИСЛИТЕЛЬНЫЙ ИНТЕЛЛЕКТ, ГИБРИДНАЯ СИСТЕМА ВЫЧИСЛИТЕЛЬНОГО ИНТЕЛЛЕКТА, ЭВОЛЮЦИОННАЯ НЕЙРОННЫХ СЕТЕЙ, ИМИТАЦИОННОЕ МОДЕЛИРОВАНИЕ, НЕЙРО-ФАЗЗИ СИСТЕМА, НЕЧЕТКАЯ МАШИНА ОПОРНЫХ ВЕКТОРОВ, НЕСТАЦИОНАРНЫЙ РЯД ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ, СИСТЕМА ТАКАГИ-СУГЕНО-КАНГ, ЯДЕРНАЯ ФУНКЦИЯ ПРИНАДЛЕЖНОСТИ

Объектами исследования являются методы построения эволюционного ансамбля нейро-фаззи систем с ядерными функциями принадлежности.

Целью данной работы является исследование методов построения эволюционных нейронных сетей и нейро-фаззи систем, что на данный момент является наиболее передовым направлением развития вычислительного интеллекта.

Предметом исследования является моделирование эволюционной нейро-фаззи систем, основной задачей которой будет прогнозирование нестационарных рядов. Проведения имитационного моделирования на данных, сгенерированных с помощью дифференциального уравнения и данных по потреблению электроэнергии. Будет создан программный комплекс для прогнозирования потребления электроэнергии.

Методы исследования - анализ литературы и источников в сети Internet.

ABSTRACT

Explanatory note: 76 pages, 14 figures, 2 tables, 63 formulas, 37 sources, 2 annex.

EVOLUTIONARY NEURAL NETWORKS, COMPUTATIONAL INTELLIGENCE, IMITATIONAL MODELLING, NONSTATIONARY VALUE, ENERGY CONSUMPTION

Evolutionary neural networks are objects of study in this work.

The objective of this work is researching development of evolutionary neural networks. This field of study is actual in computational intelligence.

The main task of this work is to develop evolutionary neuro-fuzzy system which will predict non-stationary values. For modelling real data purposes imitational modelling will be performed. For this purpose we will use values derived from equation.

Literature analysis and web-resources analysis are the main study methods used for this work.

Application will be developed for predicting energy consumption values, and module responsible for generating data from equation.

ЗМІСТ

Перелік умовних позначень, символів, одиниць, скорочень і термінів.....	8
Вступ.....	9
1 Мета роботи.....	11
2 Аналіз предметної області і постановка задачі дослідження.....	12
2.1 Поняття еволюційної нейронної мережі.....	12
2.2 Нечітка логіка та системи нечіткого висновку.....	13
2.3 Системи нечіткого висновку Мамдані-Заде.....	16
2.4 Нейро-фаззі системи.....	19
2.5 Постановка задачі дослідження.....	20
3 Ансамбль нейро-фаззі систем з ядерними функціями належності.....	21
3.1 Біологічні основи нейронної мережі.....	21
3.2 Нейро-фаззі система типа Такаги-Сугено-Канга.....	23
3.3 Нечітка нейронна мережа Ванга-Менделя.....	28
3.4 Гібриді методи навчання нечітких систем.....	30
3.5 Узагальнена регресійна нейро-фаззі мережа.....	34
3.6 Нечітка машина опорних векторів.....	37
3.7 Метод навчання еволюційного ансамблю нейро-фаззі систем з ядерними функціями належності.....	40
4 Експериментальні дослідження та імітаційне моделювання.....	45
4.1 Сутність і класифікація прогнозів.....	47
4.2 Опис використовуваного інструментарію.....	49
4.3 Прогнозування часових рядів за допомогою розробленої архітектури нейро-фаззі мережі.....	50
4.4 Ідентифікація динамічного об'єкта в режимі послідовної обробки інформації.....	52
4.5 Прогнозування за допомогою ансамблю нейро-фаззі систем в задачах електроенергетики.....	54
Висновки.....	64

Перелік посилань.....	66
Додаток А.....	69
Додаток Б.....	75

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

TCK – система нечіткого виведення Такагі-Сугено-Канга;

ФБФ – фаззі-базисна функція;

ШНМ – штучна нейронна мережа;

FSVM – fuzzy support vector machine – нечітка машина опорних векторів;

GRNFN – general regression neuro-fuzzy network –узагальнена регресійна
нейро-фаззі мережа;

NFS – neuro-fuzzy system – нейро-фаззі система;

SVM – support vector machine – машина опорних векторів.

ВСТУП

Одне з найбільш перспективних напрямків розробки принципово нових архітектур обчислювальних систем тісно пов'язане зі створенням комп'ютерів нового покоління на основі принципів обробки інформації, закладених в штучних нейронних мережах (ШНМ). Найважливіша особливість мережі, яка свідчить про її широкі можливості і величезний потенціал, полягає в паралельній обробці інформації усіма ланками. При величезній кількості міжнейронних зв'язків це дозволяє значно прискорити процес обробки інформації.

Перші практичні роботи по штучним нейромережам і нейрокомп'ютерів почалися ще в 40-50-і роки. З початку 21-го століття існує об'єктивна практична потреба навчитися відтворювати нейрокомп'ютери, тобто необхідно апаратно реалізувати безліч паралельно діючих нейронів з мільйонами фіксованих або паралельно адаптивних модифікованих зв'язків-синапсів, з декількома повнозв'язними шарами нейронів. У той же час технологія інтегральної електроніки близька до вичерпання своїх фізичних можливостей. Геометричні розміри транзисторів більше не можна фізично зменшувати. Тривалий час вважалося, що нейрокомп'ютери ефективні для вирішення, так званих, неформалізованих і погано формалізованих задач, пов'язаних з необхідністю включення в алгоритм вирішення задачі процесу навчання на реальному експериментальному матеріалі.

Для вирішення такого роду завдань досить часто використовуються штучні нейронні мережі, завдяки їх універсальним апроксимуючим можливостям і здатності навчатися по ходу отримання нової інформації.

Штучні нейронні мережі складаються з елементів, функціональні можливості яких аналогічні більшості елементарних функцій біологічного нейрона. Ці елементи потім організовуються за способом, який може відповідати (або не відповідати) анатомії мозку. Незважаючи на таку поверхневу подібність, штучні нейронні мережі демонструють дивовижне число властивостей, властивих мозку. Наприклад, вони навчаються на основі досвіду, узагальнюють попередні знання на

нові випадки і знаходять певні властивості та закономірності в даних, що надходить на опрацювання.

Питання передбачення майбутнього було і залишається актуальним по сьогоднішній день. Великий інтерес представляють задачі прогнозування споживання електроенергії, курсів валют, погоди за результатами відповідних атмосферних вимірювань, селекціонування нових видів рослин і тварин, визначень можливостей індивідуумів в певних областях за допомогою відповідної системи контрольних тестів і т.д. Особливо важливе значення прогнозування має в таких областях, як індустрія, економіка, комерція (прогнозування економічних показників, динаміки цін на той чи інший продукт, курсу акцій на якийсь час вперед і т.д.).

Штучні нейронні мережі можуть зніювати свою поведінку в залежності від зовнішнього середовища. Цей фактор більшою мірою, ніж будь-який інший, відповідає за той інтерес, який вони викликають. Після надходження вхідних сигналів (можливо, разом з необхідними виходами) вони налаштовуються, щоб забезпечувати необхідну реакцію. На даний час було розроблено безліч алгоритмів та методів прогнозування, кожен зі своїми сильними і слабкими сторонами. Хоча, все ще існують проблеми щодо того, чому нейромережа може навчитися і як навчання повинно проводитися.

Однією з переваг використання нейронних мереж є їх здатність до навчання, яка може реалізовуватися у вигляді зміни внутрішніх властивостей нейронної мережі для виконання необхідних функцій.

У даній роботі розглядаються так звані нейронні мережі четвертого покоління – еволюційні нейронні мережі. Еволюційні обчислення включають сімейство алгоритмів і підходів евристичного пошуку і часто використовуються для вирішення задач оптимізації, апроксимації і моделювання.

1 МЕТА РОБОТИ

Метою даної роботи є дослідження нейронних мереж та нейро-фаззі систем, що належать до класу еволюційних.

Еволюційні нейронні мережі належать до четвертого покоління нейронних мереж. Такі системи дозволяють маніпулювати не тільки синаптичними вагами, а також дають можливість коригувати власну архітектуру. Одночасне вирішення двох окремих завдань – налаштування ваг зв'язків і структури нейронної мережі, дозволяє в деякій мірі компенсувати недоліки, властиві кожній з них окремо і об'єднати їх переваги. З іншого боку, «платою» за це є величезний простір пошуку, а також об'єднання ряду недоліків, викликаних використанням еволюційного підходу.

У даній роботі вирішується задача створення нейро-фаззі системи, яка вирішувала б завдання прогнозування хаотичних часових рядів. Навчання та тестування працездатності мережі планується робити на реальних даних, а саме на даних про фактичне споживання електроенергії. Для апробації запропонованої архітектури нейро-фаззі мережі буде розглянута задача прогнозування хаотичного ряду, описуваного диференціальним рівнянням та задачу прогнозування споживання електроенергії по території України. Робота ансамблю нейро-фаззі систем з ядерними функціями належності буде організована в два етапи – на першому етапі буде проводитися навчання з вчителем для налаштування синаптичних ваг; на другому етапі буде проводитися прогнозування ряду з подальшим збереженням значень, і, нарешті, на третьому етапі – розрахунок помилки прогнозування.

2 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ І ПОСТАНОВКА ЗАДАЧІ ДОСЛІДЖЕННЯ

2.1 Поняття еволюційної нейронної мережі

На даний час штучні нейронні мережі набули широкого поширення для вирішення великого класу задач обробки інформації, перш за все інтелектуального управління, ідентифікації, розпізнавання образів, класифікації, кластеризації, прогнозування, емуляції в умовах невизначеності і суттєвої нелінійності.

Головною властивістю нейронних мереж є їх здатність до навчання і екстраполяції отриманих результатів. В рамках основної парадигми навчання з вчителем можна виділити два основні підходи до вирішення завдання навчання. Одне з них - це так зване навчання, засноване на оптимізації, при якому в розгляд вводиться якийсь критерій навчання, а сама задача навчання зводиться до мінімізації цього критерію за допомогою тих чи інших процедур оптимізації. Другий напрямок, це так зване навчання, засноване на пам'яті, в основі якого лежить принцип «нейрони в точках даних». Найбільш яскравими представниками систем, навчання яких заснована на цьому принципі, є узагальнені регресивні нейронні мережі, проте вони вирішують задачу інтерполяції, а не апроксимації. Одним з найпотужніших напрямків в рамках обчислювального інтелекту є нейро-фаззі системи, які об'єднують у собі універсальні апроксимуючі властивості штучних нейронних мереж (ШНМ) та прозорість і інтерпретованість систем нечіткого висновування. На цей час в рамках інтелектуального аналізу даних існує багато методів навчання нейро-фаззі систем. Однак слід зазначити їх громіздкість, а також вибір параметрів і форми функцій активації-належності, що проводиться емпіричним шляхом. Це, в свою чергу, веде до збільшення кількості функцій активації-належності, з чого випливає необхідність збільшення навчальних вибірок для налаштування таких систем. Крім того, традиційні процедури навчання, які використовуються для навчання нейро-фаззі систем, базуються на алгоритмі зворотного поширення похибки, характеризуються низькою швидкістю, що

обмежує їх застосування при роботі в послідовному режимі.

Варто відзначити, що спроби створити еволюційну нейро-фаззі систему ведуться досить давно. Основною перевагою таких систем є той факт, що вони розраховані на користувача, у якого немає апіорних даних про предметну область.

Нейронні мережі та нейро-фаззі системи використовуються для налаштування функцій належності в нечітких системах, які застосовуються в якості систем прийняття рішень. Нечітка логіка може описувати наукові знання безпосередньо, використовуючи правила лінгвістичних міток, проте багато часу зазвичай займає процес проектування і налаштування функцій належності, які визначають ці мітки. Методи навчання нейронних мереж автоматизують цей процес, істотно скорочуючи час розробки і витрати на отримання даних функцій. Теоретично нейронні мережі і системи нечіткої логіки рівноцінні, проте на практиці кожна з них має свої переваги і недоліки. Доцільно розробити таку систему, яка б в процесі навчання використовувала б обидва принципи навчання, налаштовуючи при цьому не тільки синаптичні ваги, а ще й власну архітектуру, еволюціонуючи в часі і пристосовуючись до розв'язуваної задачі. Найбільш поширеною системою в класі нейро-фаззі систем є ANFIS, вихідний шар якої може бути налаштований за допомогою традиційних процедур ідентифікації.

2.2 Нечітка логіка та системи нечіткого висновку

Нечітка логіка була вперше запропонована Л. Заде в середині 60-х років для подання нечітких і неточних знань [1]. Вона забезпечує приблизний, але ефективний спосіб опису поведінки дуже складних, погано структурованих або погано аналізованих математично систем. Дії з нечіткими змінними утворюють систему, звану нечіткою логікою. Вона включає в себе фаззіфікацію, нечіткий висновок і дефаззіфікацію. Процес фаззіфікації переводить чітке вхідне значення в нечітку. Нечіткий висновок відповідає за вилучення даних з бази знань. Процес дефаззіфікації переводить нечіткий результат в чіткий.

Нехай X – це множина об'єктів, які складаються з елементів x . Належність класичної підмножини A множині X можливо описати характеристичною функцією μ_A (формула 2.1):

$$\mu_A = \begin{cases} 1, & \text{если } x \in A, \\ 0, & \text{если } x \notin A. \end{cases} \quad (2.1)$$

Якщо значення належності приймає значення з інтервалу $[0,1]$, то A називається нечіткою множиною [1]. В такому випадку $\mu_A(x)$ називається рівнем належності до. Чим ближче значення x до A . Чим ближче значення більше $\mu_A(x)$ до 1, тим більше x належить до A . Звідси, A є підмножиною X , яка не має чітких меж [31].

Множина A в X визначається як множина упорядкованих пар $A = \{(x, \mu_A(x)) | x \in X\}$, в якій $\mu_A(x)$ – функція належності елементу x в A , яка відображує X на відрізок $M = [0,1]$.

Якщо M містить тільки два граничних елементів 0 та 1, то множина A стає чіткою, тобто є класичною.

Вадливою перевагою нечітких множин є можливість їх до лінгвістичної інтерпретації. Тобто, використовуючи нечіткі множини, є можливість легко визначати різні лінгвістичні терміни. Наприклад, зріст людини: нехай X = «Зріст» і може приймати значення A_1 = «низький», A_2 = «середній», A_3 = «високий». Кожне з цих значень описується своєю функцією належності: μ_1 , μ_2 та μ_3 відповідно. Частіше всього використовуються гаусівська функція належності (формула 2.2)

$$\mu_A(x) = \left(-\frac{(x - c_A)^2}{2\sigma_A^2} \right), \quad (2.2)$$

де c_A – центр функції;

σ_A – параметр «ширини» функції.

Над нечіткими множинами можуть вводитися логічні операції, такі як AND, OR і NOT – кон'юнкція (перетин), диз'юнкція (об'єднання) і заперечення (інверсія). Ці операції для множин A і B над X визначаються як (формула 2.3)

$$\begin{aligned}(A \cap B) &= \min \{A(t), B(t)\} = A(t) \wedge B(t), \forall t \in X, \\(A \cup B) &= \max \{A(t), B(t)\} = A(t) \vee B(t), \forall t \in X, \\(\neg A) &= 1 - A(t), \forall t \in X,\end{aligned}\tag{2.3}$$

де $A(t)$, $B(t)$ – функція належності множин A і B відповідно.

На підставі лінгвістичної інтерпретації нечітких множин і логічних операцій вводиться поняття нечітких правил «якщо-то». Для системи з вектором входів $x = (x_1, x_2, \dots, x_n)^T$ і одним виходом y в загальному вигляді нечіткі правила записуються як (формула 2.4)

$$\mathfrak{R}_i : \underbrace{\text{If } x_1 \text{ is } A_1 \text{ and } x_2 \text{ is } A_2 \text{ and } \dots x_n \text{ is } A_n}_{\text{antecedent}} \text{ then } \underbrace{y \text{ is } B_i}_{\text{consequent}}, \quad i = 1, 2, \dots, m. \tag{2.4}$$

На базі нечітких правил будується система нечіткого виведення. Прийняття рішень в системах нечіткого виведення ґрунтується найчастіше на узагальненому правилі імплікації Generalized Modus Ponens [2]. Існує три основних типи систем нечіткого виводу: Мамдані (тип 1), Цукамото (тип 2) і Такагі-Сугено (тип 3). Перший тип систем є найбільш загальним і найкращим чином підходить для використання лінгвістичних правил, однак вимагає значних обчислювальних витрат. Найменш вимогливий до обчислювальних ресурсів третій тип систем – Такагі-Сугено, який в той же час дозволяє успішно застосовувати автоматичні методи настройки/навчання завдяки малій кількості параметрів, що настроюються.

Система нечіткого виводу третього типу розроблялася для автоматичної побудови нечітких правил за заданою вибіркою (вхід/вихід). Отже, вид правил дещо змінений (формула 2.5):

$$\mathcal{R}_i : \text{If } x_1 \text{ is } A_1 \text{ and } x_2 \text{ is } A_2 \text{ and } \dots x_n \text{ is } A_n \text{ then } y = f(x_1, x_2, \dots, x_n), \quad (2.5)$$

де A_i , $i = 1, 2, \dots, n$ – нечіткі множини антецеденту;

$y = f(\bullet)$ – консеквент правила, наведений чіткою формою.

Зазвичай в якості функції $f = (\bullet)$ беруть поліном від вхідних змінних. У цьому випадку порядок системи Такагі-Сугено збігається зі ступенем полінома (якщо $f = \text{const}$, то відповідна система має нульовий порядок).

2.3 Системи нечіткого висновку Мамдані-Заде

Елементи теорії нечітких множин, правила імплікації і нечітких міркувань утворюють систему нечіткого виводу. У ній можна виділити безліч використовуваних в системі нечітких правил, базу даних, яка містить описи функцій приналежності, а також механізм виведення і агрегування, який формується застосовуваними правилами імплікації. Слід згадати, що в разі технічної реалізації в якості вхідних і вихідних сигналів виступають вимірювані величини, однозначно зіставляють вхідним значенням відповідні вихідні значення [2]. Для забезпечення взаємодії множин цих двох видів вводиться нечітка система з так званими фаззіфікатором (перетворювачем безлічі вхідних даних в нечітку множину) на вході і дефаззіфікатором (перетворювачем нечітких множин в конкретне значення вихідної змінної) на виході. M нечітких множин, що визначають діапазон зміни вихідної змінної. Дефаззіфікатор перетворює цей діапазон в одне конкретне значення, яке приймається на виході в якості вихідного сигналу всієї системи. Необхідно відзначити, що також існують системи нечіткого виведення, в яких виконавчий механізм безпосередньо генерує чіткі значення, які

вже не потрібно піддавати процедурі дефаззифікації.

Фаззифікатор перетворює N -мірний вхідний вектор $x = [x_1, x_2, \dots, x_N]^T$ в нечітку множину A , Що характеризується функцією приналежності $\mu_A(x)$ з чіткими змінними. Незважаючи на те, що нечіткі системи можуть мати функції приналежності довільної структури, з практичної точки зору найбільш популярними є функції гаусівського типу, а також трикутні і трапецеїдальні функції.

Загальна форма гауссовской функції для змінної x з центром c і варіацією σ для безлічі F має вид (формула 2.6):

$$\mu_A(x) = \exp \left[- \left(\frac{x - c}{\sigma} \right)^2 \right], \quad (2.6)$$

де c – центр нечіткої множини;

σ – коефіцієнт широти.

Дефаззифікатор трансформує нечітка множина в повністю детерміноване точкове рішення y . Нечітке безліч представляє залежність $\mu(y) = \mu_{A \rightarrow B}(y)$ як функцію від вихідної змінної y . Перетворення цієї множини в єдине точкове рішення можливо багатьма способами. Найбільш відомі серед них:

– дефазифікація щодо центру області (формула 2.7):

$$y_c = \frac{\int y \mu(y) dy}{\int \mu(y) dy}, \quad (2.7)$$

– дефаззифікація щодо середнього центру (формула 2.8):

$$y_c = \frac{\sum_i^M \mu(y_{ci}) y_{ci}}{\sum_i^M \mu(y_{ci})}, \quad (2.8)$$

– дефаззифікація щодо середнього максимуму (формула 2.9):

$$y_m = \frac{\sum_i^m y_i}{m}, \quad (2.9)$$




Рисунок 2.1 – Архітектура нечіткої системи з фаззифікатором і дефаззифікатором

Таким чином в роботі буде розроблено адаптивний метод навчання-самонавчання, еволюційних нейро-фаззі систем, що дозволяє налаштовувати не тільки всі параметри мережі, але і кількість функцій належності, що дозволило забезпечити необхідну точність при мінімальній кількості параметрів, що настроюються.

2.4 Нейро-фаззі системи

Нечіткі системи, як і нейронні мережі мають універсальні апроксимуючі властивості, тобто з їх допомогою можна моделювати довільні функціональні залежності. І нечітка логіка, і нейронні мережі успішно вирішують безліч нелінійних завдань, які залежать від часу. Союз нечіткої логіки і нейронних мереж може подолати труднощі, пов'язані з кожною з цих технологій [3]. Нейронна мережа може вчитися на вхідних і вихідних даних для визначення поведінки системи. Ці знання можуть бути використані для створення нечітких правил і функцій належності, що істотно зменшує час, необхідний на розробку.

Таке об'єднання також допомагає вирішити проблему неінтерпретовності результатів, одержуваних за допомогою нейронних мереж. Вираз ваг нейронної мережі за допомогою нечітких правил забезпечує розуміння роботи нейронної мережі, що, у свою чергу, допомагає створювати більш ефективні програми.

Нейро-фаззі системи можуть генерувати нечіткі логічні правила і функції належності для складних систем, для яких не достатньо стандартного нечіткого підходу. Для таких систем стандартна нечітка логіка використовує складні ієрархічні правила, для зменшення кількості самих правил, що відповідно знижує ефективність і точність рішення.

Нейро-фаззі системи зазвичай використовують нелінійні функції належності. Перевагою таких функцій є те, що системні знання можуть бути рівномірно розподілені між базою правил і базою функцій належності. Це відбивається в скороченні обсягу бази правил.

Найбільш важливим є те, що властивості узагальнення і здатність до навчання нейро-фаззі систем дозволяють генерувати правила і функції належності, що забезпечують більш достовірне і точне рішення в порівнянні з альтернативними методами. За допомогою коректної комбінації нечіткої логіки і нейронних мереж представляється можливим повне відображення знань нейронної мережі нечіткою логікою в разі, якщо алгоритми нечіткої логіки повністю засновані на архітектурі

нейронної мережі. Це дозволяє генерувати нечіткі логічні рішення зі заздалегідь заданою точністю виходу [3-5].

2.5 Постановка задачі дослідження

Основна мета атестаційної роботи магістерта полягає в тому, щоб синтезувати послідовні або «on-line» алгоритми локальних модулів і побудувати процедуру об'єднання вихідних сигналів окремих модулів в вихідному шарі з метою отримання оптимального вихідного сигналу, який не поступається за точністю найкращому з локальних моделей.

В роботі ведеться розробка нечіткої нейронної мережі-прогнозатора, яка дозволяла б обробляти нестационарні часові ряди.

Таку мережу пропонується навчати, одночасно використовуючи навчання, засноване як на пам'яті, так і навчання, засноване на оптимізації.

Метою даного дослідження є розробка адаптивних методів навчання ансамблів еволюційних нейро-фаззі систем з ядерними функціями належності, які дозволяють налаштовувати не тільки синаптичні ваги і параметри функцій належності, але і архітектури в on-line режимі, що, в свою чергу, дозволяє забезпечити оптимальну точність вихідного сигналу в умовах апріорної та поточної невизначеності. Відповідно до поставленої мети необхідно розв'язати такі наукові задачі:

- аналіз існуючих методів та підходів до навчання еволюційних штучних нейронних мереж та нейро-фаззі систем;
- розробка еволюційної архітектури та адаптивного методу навчання на основі різних принципів нейро-фаззі систем з ядерними функціями належності та їх ансамблів, не схильних до «прокльону розмірності»;
- розв'язання за допомогою розроблених методів тестових задач різної фізичної природи.

3 АНСАМБЛЬ НЕЙРО-ФАЗЗИ СИСТЕМ З ЯДЕРНИМИ ФУНКЦІЯМИ НАЛЕЖНОСТІ

В даному розділі розглянуто задачу створення методу навчання архітектури еволюційного ансамблю нейро-фаззі систем з ядерними функціями належності, що не схильна до прокльону розмірності, здатна обробляти інформацію в on-line режимі, адаптуючи при цьому свої параметри і структуру до умов задачі.

3.1 Біологічні основи нейронної мережі

Вузли штучної нейронної мережі, іменовані також штучними нейронами (нейронними клітинами, формальними нейронами) представляють собою елементарні процесори і є спрощеними моделями біологічних нейронів. Це спрощення визначається перш за все тим, що інженерів цікавлять тільки функції нейронів, пов'язані з переробкою інформації. Крім того, не слід забувати про високу складність біологічних систем, які в повній мірі просто не піддаються математичному опису. Тому в теорії нейромереж нейрон – це система відображення з n -вимірному простору входів, формованого сигналу з виходів інших нейронів, або зовнішнім середовищем, в одновимірний простір (скалярний сигнал) на виході нейронної клітини. Більшість нейронних мереж утворено однотипними нейронами - це гомогенні (однорідні) мережі, хоча відомі гетерогенні мережі, сконструйовані з різних нейронів. Треба зазначити, що нейрони бувають аналоговими і цифровими, хоча цей поділ чисто умовний, оскільки один і той же формальний нейрон може функціонувати як в аналоговому, так і в цифровому режимах.

Біологічний нейрон є особливою біологічною системою, призначеної для передачі і обробки інформації в живих організмах.

Тіло клітини включає ядро, яке містить інформацію про спадкові властивості, і плазму, що володіє молекулярними засобами для створення необхідних нейронам

матеріалів. Саме в сомі реалізуються основні функції, пов'язані з генетичними і метаболічними механізмами, необхідними для життєдіяльності, а також інформаційні функції. Нейрон складається з тіла клітини, або соми, дендритів, аксона і синапсів.

Аксон – це нервеве волокно, поєднане з сомой і є провідником вихідного сигналу. Аксон має розгалуження – волокна, звані аксонів терміналами, за якими нервові імпульси проходять до інших нейронів.

Дендрити – дуже розгалужене дерево волокон, з'єднаних з сомой. Кожен нейрон має від 10^3 до 10^4 дендритів, які пов'язують його з безліччю інших клітин. Дендрити отримують сигнал від інших аксонів – терміналів через спеціальні контакти – синапси.

Синапс є функціональним інтерфейсом між двома нейронами (аксонний термінал одного нейрона і дендрит іншого) і здатний підсилювати або придушувати сигнал подібно електронного підсилювача, визначаючи характер обробки інформації в сомі. Синапси умовно можна поділити на збудливі і гальмуючі, які збільшують або зменшують (блокують) сигнал. Нейрони передають інформацію, використовуючи потенціал дії. Обробка цієї інформації включає комбінацію електричних і хімічних процесів, що протікають в синапсах. Коли імпульс з аксонного терміналу одного нейрона досягає синапсу іншого, утворюються спеціальні хімічні речовини, названі нейротрансмітерами. Нейротрансмітери дифундують через синапс, збуджуючи або гальмуючи здатність приймаючої нейрона генерувати електричні імпульси. Характеристики синапсів можуть перебудовуватися проходять через них сигналами так, що синапси навчаються в залежності від типів протікають в них процесів.

Спрощено процес функціонування біологічного нейрона можна описати таким чином. Соматримує сигнали від інших нейронів через синаптичні з'єднання і перетворює його в послідовність нервових імпульсів. Перетворення сигналу в сомі в загальному випадку має суттєво нелінійний характер, хоча нейрофізіологи виявили, що в певних режимах вихідний сигнал пропорційний лінійної комбінації вхідних, тобто нейрон в деякому вузькому діапазоні може бути описаний лінійною

функцією передачі. Вихідний сигнал передається вздовж разветвляючогося аксона до синапсах інших нейронів. Інтенсивність вихідного сигналу залежить як від рівня вхідних сигналів, так і провідності відповідних синаптичних зв'язків. Інформація між нейронами передається за допомогою короткої серії імпульсів, як правило, тривалістю кілька мілісекунд. Повідомлення передається за допомогою частотно-імпульсної модуляції, при цьому частота може змінюватися від одиниць до тисяч імпульсів в секунду. Як видно, за швидкістю обробки інформації нейрон істотно поступається сучасним електронним схемам, однак, як ми вже відзначали, висока швидкість обробки інформації в мозку забезпечується розпаралелюванням протікають в ньому процесів.

3.2 Нейро-фаззі система типа Такагі-Сугено-Канга

Природним розвитком нейронних мереж є нейро-фаззі системи [4, 6], що поєднують можливості до навчання нейронних мереж з прозорістю і інтерпретовністю систем нечіткого виводу. У загальному випадку нейро-фаззі системи являють собою нечіткі моделі, які навчаються за допомогою алгоритмів, прийнятих в теорії нейронних мереж і використовують замість багатовимірних радіально-базисних функцій одновимірні фаззі-базисні функції, які по суті є дзвонуватими (колокооподібними) функціями належності, прийнятими в нечіткій логіці. Використання колоколооподібних фаззі-базисних функцій дозволяє поєднувати локальні особливості ядерних функцій з властивостями традиційних сигмоїдальних активаційних функцій нейронних мереж, що забезпечують глобальні апроксимуючі властивості. Володіючи апроксимуючими та інтерполяційними характеристиками радіально-базисних мереж, нейро-фаззі системи в меншій мірі схильні до «прокльону розмірності», що забезпечує їм перевагу в порівнянні зі звичайними нейромережами.

Серед нейро-фаззі систем найбільшого поширення набула адаптивна нейро-фаззі система нечіткого виведення Такагі-Сугено-Канга (ТСК) [6, 7]. Узагальнену

схему виведення в моделі ТСК при використанні h правил і n змінних x_i можна представити у вигляді (формула 3.1)

$$\begin{aligned}
 & IF(x_1.IS.A_{11}).AND.(x_2.IS.A_{21}).AND.(x_n.IS.A_{n1}), \\
 & \quad THEN \hat{y}_1 = p_{10} + \sum_{i=1}^n p_{1i}x_i \\
 & \quad \dots \quad \dots \quad \dots \quad \dots \\
 & IF(x_1.IS.A_{1h}).AND.(x_2.IS.A_{2h}).AND.(x_n.IS.A_{nh}), \\
 & \quad THEN \hat{y}_h = p_{h0} + \sum_{i=1}^n p_{hi}x_i.
 \end{aligned} \tag{3.1}$$

Умова $IF(x_i. IS. A_i)$ реалізується функцією належності, яка зазвичай представляється узагальненої функцією Гауса окремо для кожної змінної x_i (формула 3.2):

$$\mu_A^{NF}(x_i) = \frac{1}{1 + \left(\frac{x_i - c_i}{\sigma_i} \right)^{2b_i}}, \tag{3.2}$$

де функція належності $\mu_A^{NF}(x_i)$ представляє оператор A_i . В нечітких мережах доцільно ставити цю умову в формі алгебраїчного твору, з якої випливає, що для l – го правила виведення [7] (формула 3.3)

$$\mu_{Al}^{NF}(x_i) = \prod_{i=1}^n \left[\frac{1}{1 + \left(\frac{x_i - c_{il}}{\sigma_{il}} \right)^{2b_{il}}} \right]. \tag{3.3}$$

При h правилах виведення агрегування вихідного результату мережі проводиться таким чином (формула 3.4):

$$\hat{y}^{NF}(x) = \frac{1}{\sum_{l=1}^n w_l^{NF}} \sum_{l=1}^h w_l^{NF} y_l(x), \quad (3.4)$$

де $\hat{y}_l^{NF}(x) = p_{l0} + \sum_{i=1}^n p_{li} x_i$. Присутні в цьому виразі ваги w_k інтерпретуються як значимість компонентів $\mu_{Al}^{NF}(x)$, визначених формулою (3.3). за цієї умови формулою (3.4) можна зіставити багат шарову структуру мережі, зображену на рисунку 3.1. – в такій мережі формується п'ять шарів.

Перший шар виконує роздільну фаззифікації кожної змінної $x_i = (i=1, 2, \dots, n)$, визначаючи для кожного l -го правила виведення значення коефіцієнта належності $\mu_{Al}^{NF}(x_i)$ відповідно до застосовуваної функцією фаззифікації. Це параметричний шар з параметрами c_{il} , σ_{il} , b_{il} , підлягають адаптації в процесі навчання.

Другий шар виконує агрегування окремих змінних x_i , визначаючи результуюче значення коефіцієнта належності $w_l^{NF} = \mu_{Al}^{NF}(x)$ для вектора x (рівень активації правила виводу) відповідно до формули (3.3). Цей шар непараметричний.

Третій шар являє собою генератор функцій ТСК, що розраховує значення антецедента $\hat{y}_l^{NF}(x) = p_{l0} + \sum_{i=1}^n p_{li} x_i$. У цьому випадку також проводиться множення сигналів $\hat{y}_l^{NF}(x)$ на значення w_l^{NF} , сформовані в попередньому шарі. Це параметричний шар, в якому адаптації підлягають лінійні ваги для $l=1, 2, \dots, h$ і $i=1, 2, \dots, n$, що визначають функцію слідства моделі ТСК.

Четвертий шар складають два нейрона-суматора, один з яких розраховує зважену суму сигналів $\hat{y}_l^{NF}(x)$, а другий визначає суму ваг $\sum_{l=1}^h w_l^{NF}$. Це непараметричний шар.

Останній, п'ятий шар, що складається з єдиного вихідного нейрона $\sum_{l=1}^h w_l^{NF}$, - це шар нормалізації, в якому ваги піддаються нормалізації відповідно до формули (3.4). вихідний сигнал $\hat{y}^{NF}(x)$ визначається виразом (формула 3.5),

$$\hat{y}^{NF}(x) = f(x) = \frac{f_1}{f_2}. \quad (3.5)$$

це також є непараметричний шар.

З наведеного опису випливає, що нечітка мережа ТСК містить тільки два параметричних шари (перший і третій), параметри яких корегуються в процесі навчання. Параметри першого шару прийнято називати нелінійними параметрами, оскільки вони відносяться до нелінійної функції (3.2), а параметри третього шару - лінійними вагами, так як вони відносяться до параметру p_{li} лінійної функції ТСК.

При уточненні функціональної залежності (3.4) для мережі ТСК отримуємо [7] (формула 3.6):

$$\hat{y}^{NF}(l) = \frac{1}{\sum_{l=1}^h \left[\prod_{i=1}^n \mu_{Al}^{NF}(x_i) \right]} \sum_{l=1}^h \left[\prod_{i=1}^n \mu_{Al}^{NF}(x_i) \right] \left[p_{l0} + \sum_{i=1}^n p_{li} x_i \right] \quad (3.6)$$

Якщо прийняти, що в певний момент часу параметри умови зафіксовані, то функція $\hat{y}^{NF}(x)$ є лінійною щодо змінних $(i=1,2,...,n)$.

При наявності n вхідних змінних кожне правило формує $n+1$ змінних p_{li} лінійної залежності ТСК. При h правилах виведення це дає $h(n+1)$ лінійних

параметрів мережі. У свою чергу, кожна функція належності використовує три параметри (c, s, b) , які підлягають адаптації.




Рисунок 3.1 – Структура нечіткої нейронної мережі ТСК нульового порядку

Якщо прийняти, що кожна змінна x_i характеризується власною функцією належності, то при h правилах виведення ми отримаємо $3hn$ нелінійних параметрів, значення яких повинні підбиратися в процесі навчання мережі.

На практиці для зменшення кількості параметрів, що адаптуються, оперують меншою кількістю незалежних функцій належності для окремих змінних, керуючись правилами, в яких комбінуються функції належності різних змінних. Якщо прийняти, що кожна змінна x_i має m різних функцій належності, то максимальна кількість правил, яке можна створити при їх комбінації, складе $h = m^n$: (при трьох функціях належності, що поширюються на дві змінні, це $3^2=9$ правил виводу). Таким чином сумарна кількість нелінійних параметрів мережі при правилах виведення зменшується з $3hn$ в загальному випадку до $3nh^{1/n}$. Кількість лінійних параметрів при подібній модифікації залишається без змін, тобто $h(n+1)$.

3.3 Нечітка нейронна мережа Ванга-Менделя

На принципах нечіткої логіки побудовано велику кількість нейронних мереж, розглянемо ще одну нейро-фаззі систему, ведення Л. Вангом і Дж. Менделем [6, 7], ця нечітка система по суті являє собою нечітку нейросистему TSK нульового порядку. На рисунку 3.2. наведене класична архітектура нечіткої нейронної мережі Ванга-Менделя.

Це структура містить чотири шари, в якій перший шар виконує фаззіфікацію вхідних змінних, другий – агрегування значень активації умови, третій (лінійний) – агрегування M правил виведення (перший нейрон) і генерацію нормалізує сигналу (другий нейрон), тоді як що складається з одного нейрона вихідний шар здійснює нормалізацію, формуючи вихідний сигнал $\hat{y}^{NF}(x)$. Тільки перший і третій шари є параметричними.




Рисунок 3.2 – Архітектура нечіткої нейронної мережі Ванга-Менделя

У першому шарі це параметри функції фаззифікації $(c_{li}, \sigma_{li}, b_{li})$, а в третьому шарі – ваги w_1^{NF} , w_2^{NF} , ..., w_h^{NF} , що інтерпретуються як центр c_l функції належності слідства l – го нечіткого правила. Представлена на рисунку 3.2 архітектура реалізує функцію апроксимації, яку можна представити в наступному вигляді (формула 3.7):

$$\hat{y}^{NF}(x) = \frac{1}{\sum_{l=1}^h \left[\prod_{i=1}^n \mu_{Al}^{NF}(x_i) \right]} \sum_{l=1}^h w_l^{NF} \left[\prod_{i=1}^n \mu_{Al}^{NF}(x_i) \right]. \quad (3.7)$$

Слід відмітити велику схожість архітектур обох нечітких мереж. Частково, що визначають умови – перший і другий шари – у них ідентичні, оскільки вони відповідають компонентам правил виведення "IF ...", що так само ж представляється, і в моделі ТСК. Відмінності спостерігаються у відображенні компонентів "THEN ...". У мережі Ванга-Менделя результат представляється

константою ($w_l^{NF} = c_l$), яку можна розглядати, як поліном нульового порядку, що визначає центр функції належності слідства. Таким чином, з функціональної точки зору мережа Ванга-Менделя подібна мережі ТСК, а точніше – є її окремим випадком.

Задача обох мереж (ТСК і Ванга-Менделя) складається в такому відображенні пар даних (x, y) , щоб очікуване значення, відповідне вхідному вектору x , формувалося вихідною функцією мережі $\hat{y}^{NF}(x)$. Незважаючи на те, що наведені міркування стосуються мереж з одним вихідним нейроном, вони можуть бути узагальнені на випадок систем з декількома виходами.

Навчання нечітких мереж, так само як і класичних мереж, може проводитися або за алгоритмом з вчителем, заснованому на мінімізації цільової функції, що задається, як правило, з використанням евклідової норми як (формула 3.8)

$$E = \frac{1}{2} \sum_{i=1}^n \left(\hat{y}^{NF}(x_i) - y_i \right)^2, \quad (3.8)$$

де p – це кількість пар $(x, \hat{y}^{NF})$, що треба налаштовувати (навчати), або за алгоритмом самонавчання, згідно з яким виконується групування (кластеризація) даних.

3.4 Гібриді методи навчання нечітких систем

Гібридний алгоритм застосовується до обох наведених вище нечітких систем. Мережа Ванга-Менделя може при цьому трактуватися як мережа ТСК, в якій всі параметри (крім $w_l^{NF} = p_{l0}$, який підлягає уточненню) $w_l^{NF} = p_{l0}$ тотожно рівні нулю.

У гібридному алгоритмі параметри, що підлягають адаптації поділяються на дві групи. Перша з них складається з лінійних параметрів p_{li} третього шару, а друга

група – з параметрів нелінійної функції належності першого шару. Уточнення параметрів проводиться в два етапи.

На першому етапі при фіксації певних значень параметрів функції належності (в першому циклі – це значення, отримані в результаті ініціалізації) шляхом рішення системи лінійних рівнянь розраховуються лінійні параметри p_{li} полінома ТСК. При відомих значеннях функції належності залежність (3.6) можна представити в лінійній формі (формула 3.9)

$$\hat{y}^{NF}(x) = \sum_{l=1}^h w_l^{NF} \left(p_{l0} + \sum_{i=1}^n p_{li} x_i \right), \quad (3.9)$$

де (формула 3.10)

$$w_l^{NF} = \frac{\prod_{i=1}^n \mu_{Al}^{NF}(x_i)}{\sum_{r=1}^n \left[\prod_{i=1}^n \mu_{Ar}^{NF}(x_i) \right]} = const \quad (3.10)$$

для $h=1,2,...,M$. При p навчальних вибірках (x_l, y_l) ($l=1,2,...,p$) і заміні вихідного сигналу мережі очікуваним значенням y_l отримуємо систему з p лінійних рівнянь виду (формула 3.11)

$$\begin{bmatrix} w_{11}^{NF} & w_{11}^{NF} x_{11} & \dots & w_{11}^{NF} x_{1n} & \dots & w_{1h}^{NF} & w_{1h}^{NF} x_{11} & \dots & w_{1h}^{NF} x_{1n} \\ w_{11}^{NF} & w_{11}^{NF} x_{21} & \dots & w_{21}^{NF} x_{2n} & \dots & w_{2h}^{NF} & w_{2h}^{NF} x_{21} & \dots & w_{2h}^{NF} x_{2n} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ w_{p1}^{NF} & w_{p1}^{NF} x_{p1} & \dots & w_{p1}^{NF} x_{pn} & \dots & w_{ph}^{NF} & w_{ph}^{NF} x_{p1} & \dots & w_{ph}^{NF} x_{pn} \end{bmatrix} \begin{bmatrix} p_{10} \\ \dots \\ p_{1n} \\ \dots \\ p_{h0} \\ \dots \\ p_{hn} \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_p \end{bmatrix}, \quad (3.11)$$

де w_{li}^{NF} позначає рівень активації (вага) умови i – го правила при представленні l – го вхідного вектора x . Цей вираз можна записати в скороченій матричній формі (формула 3.12)

$$A p = y. \quad (3.12)$$

Розмірність матриці A дорівнює $p \times (n+1)h$, при цьому зазвичай кількість рядків значно більше кількості стовпців $(n+1)h$. Вирішення цієї системи рівнянь можна отримати за один крок за допомогою псевдоінверсії матриці A (формула 3.13):

$$p = A^+ y. \quad (3.13)$$

На другому етапі після фіксації значень лінійних параметрів p_{kj} розраховуються фактичні вихідні сигнали $\hat{y}^{NF}(i)$ мережі для $i=1,2,\dots,p$, для чого використовується лінійна залежність (формула 3.14)

$$\hat{y}^{NF} = \begin{bmatrix} \hat{y}_1^{NF} \\ \hat{y}_2^{NF} \\ \dots \\ \hat{y}_p^{NF} \end{bmatrix} = A p \quad (3.14)$$

і слідом за ними – вектор помилки $e = y - \hat{y}^{NF}$. Сигнали помилок направляються через підключену мережу у напрямку до входу мережі (зворотне поширення) аж до першого шару, де можуть бути розраховані компоненти градієнта цільової функції щодо конкретних параметрів c_{li} , σ_{li} , b_{li} . Після формування вектора градієнта параметри корегуються з використанням одного з градієнтних методів навчання.

Якщо застосовується найпростіший метод найшвидшого спуску, то відповідні формули навчання приймають форму (формула 3.15, 3.16, 3.17):

$$c_{li}(n+1) = c_{li}(n) - \eta_c \frac{\partial E(n)}{\partial c_{li}}, \quad (3.15)$$

$$\sigma_{li}(n+1) = \sigma_{li}(n) - \eta_\sigma \frac{\partial E(n)}{\partial \sigma_{li}}, \quad (3.16)$$

$$b_{li}(n+1) = b_{li}(n) - \eta_b \frac{\partial E(n)}{\partial b_{li}}, \quad (3.17)$$

де l – позначає номер чергової ітерації.

Після уточнення нелінійних параметрів знову запускається процес адаптації лінійних параметрів функції ТСК (перший етап) і нелінійних параметрів (другий етап). Цей цикл повторюється аж до стабілізації всіх параметрів процесу. Формули (3.15)-(3.17) вимагають розрахунку градієнта цільової функції щодо параметрів функції належності. Остаточний вигляд цих формул залежить як від використовуваного визначення функції помилки на виході мережі, так і від форми функції належності. Наприклад, при використанні узагальненої функції Гауса (3.3) (формула 3.18) [8]

$$\mu_A(x) = \frac{1}{1 + \left(\frac{x - c}{\sigma} \right)^{2b}} \quad (3.18)$$

вигляд градієнту цільової функції для однієї пари навчальних даних набуває вигляду (формула 3.19, 3.20, 3.21)

$$\frac{\partial E}{\partial c_{li}} = \left(y(x) - \hat{y}^{NF} \right) \sum_{r=1}^h \left[p_{r0} + \sum_{i=1}^n p_{ri} x_i \right] \frac{\partial w_r^{NF}}{\partial c_{li}}, \quad (3.19)$$

$$\frac{\partial E}{\partial \sigma_{li}} = \left(y(x) - \hat{y}^{NF} \right) \sum_{r=1}^h \left[p_{r0} + \sum_{i=1}^n p_{ri} x_i \right] \frac{\partial w_r^{NF}}{\partial \sigma_{li}}, \quad (3.20)$$

$$\frac{\partial E}{\partial b_{li}} = \left(y(x) - \hat{y}^{NF} \right) \sum_{r=1}^h \left[p_{r0} + \sum_{i=1}^n p_{ri} x_i \right] \frac{\partial w_r^{NF}}{\partial b_{li}}. \quad (3.21)$$

При практичній реалізації гібридного методу навчання нечітких мереж домінуючим фактором їх адаптації вважається перший етап, на якому ваги p_{kj} підбираються з використанням псевдоінверсії за один крок. Для врівноваження його впливу другий етап (підбір нелінійних параметрів градієнтним методом) багаторазово повторюється в кожному циклі. Але це пакетний режим обробки інформації при якому вся вихідна вибірка задана апріорі. У разі, коли дані на обробку надходять послідовно з якоюсь частотою в часі, відомий підхід видається неефективним.

Наведений гібридний алгоритм – один з найбільш ефективних способів навчання нечітких мереж. Його головна риса полягає в розділенні процесу навчання на два відокремлених у часі етапи. На кожному етапі корегується тільки частина параметрів мережі. Якщо взяти до уваги, що обчислювальна складність кожного алгоритму оптимізації пропорційна кількості параметрів, то зменшення розмірності задачі оптимізації істотно скорочує кількість математичних операцій і збільшує швидкість алгоритму. Завдяки цьому, гібридний алгоритм значно ефективніший, ніж тривіальний градієнтний алгоритм першого порядку, згідно з яким уточнення всіх параметрів мережі проводиться паралельно і одночасно.

3.5 Узагальнена регресійна нейро-фаззі мережа

Узагальнена регресійна нейро-фаззі мережа (General Regression Neuro-Fuzzy Network – GRNFN) являє собою нейро-фаззі систему (Neuro-Fuzzy System – NFS), яка навчається за типом узагальненої регресійної нейронної мережі (GRNN), що забезпечує їй апроксимуючі можливості TSK і швидкість навчання мереж, заснованих на пам'яті.

Так, для розв'язання задачі ідентифікації нелінійного об'єкта, $y(k) = F(x(k))$, $(y(k), x(k))$ – скаляр і $(n \times 1)$ – вектор вихідних і вхідних сигналів відповідно в дискретний момент часу $k = 1, 2, \dots$, $F(\bullet)$ – невідомий нелінійний оператор об'єкта) за допомогою GRNN необхідно сформувати навчальну вибірку $\{x(k), y(k)\}$, $k = 1, 2, \dots, l$, після чого можна отримати оцінку $\hat{y}^{GRNF}(k)$ реакції об'єкта на довільний вхідний сигнал x у вигляді (формула 3.25)

$$\hat{y}^{GRNF}(x) = \frac{\sum_{k=1}^N y(k) \varphi(D(k))}{\sum_{k=1}^N \varphi(D(k))}, \quad (3.25)$$

де $D(k)$ – міра відстані в прийнятій метриці між x та $x(k)$;

$\varphi(\bullet)$ – деяка ядерна функція, найчастіше Гаусіан.

В якості відстані зазвичай використовується евклідова метрика (формула 3.26)

$$D^2(k) = \sum_{i=1}^n \left(\frac{x_i - x_i(k)}{\sigma} \right)^2, \quad (3.26)$$

(тут σ – скалярний параметр, визначає радіус рецепторного поля ядерної функції $\varphi(\bullet)$), хоча в більш загальному випадку можливе використання метрики Мінковського (формула 3.27)

$$D^p(k) = \sum_{i=1}^n \left| \frac{x_i - x_i(k)}{\sigma} \right|^p, \quad p \geq 1. \quad (3.27)$$

Зі збільшенням обсягу навчальної вибірки N GRNFN асимптотично сходиться до оптимальної нелінійної регресійної поверхні [9].

Процес навчання GRNFN досить просто організувати в реальному часі. При цьому навчальні пари $x(k)$, $y(k)$ надходять в мережу послідовно, формуючи нові радіально-базисні функції-нейрони. При цьому постійно оцінюється відстань між новосформованою і вже наявними функціями. Якщо ця відстань менше деякого наперед заданого порогового значення r , новий нейрон виключається з мережі.

Архітектура узагальненої регресійної нейро-фаззі мережі, наведена на рисунку 3.3 і складається з п'яти послідовно з'єднаних шарів. Перший прихований шар складається з N блоків по n фаззі-базисних функцій (ФБФ) в кожному і виконує фаззіфікацію вектора вхідних змінних. Другий прихований шар здійснює агрегування рівнів належності, обчислених в першому шарі, і складається з I блоків множення. Третій прихований шар – це шар синаптичних ваг, що визначаються спеціальним способом. Четвертий шар утворений двома суматорами і обчислює суми вихідних сигналів другого і третього шарів. І, нарешті, в п'ятому (вихідному) шарі проводиться нормалізація, в результаті якої обчислюється вихідний сигнал мережі.

Архітектура FGRNN близька до архітектури нейро-фаззі системи Ванга-Менделя [64], що є, в свою чергу, модифікацією системи нечіткого виведення Такагі-Сугено [10] нульового порядку. Однак, якщо нейро-фаззі системи навчаються за допомогою тих чи інших процедур оптимізації [6-11], то GRNFN налаштовується за допомогою одного проходу алгоритму навчання, що істотно підвищує швидкість обробки даних.

Оскільки GRNFN відноситься до мереж, заснованих на пам'яті, її навчання проводиться за принципом «нейрони в точках даних», що робить його вкрай простим і швидким в порівнянні з навчанням за допомогою алгоритмів оптимізації.

Оскільки процес навчання відбувається практично миттєво, питання про стежати властивості алгоритму налаштування взагалі не виникає. Що розвивається ідея «нейрони в точках даних» в поєднанні з нечіткою логікою дозволяє вирішувати

більш широкий клас задач в режимі послідовної обробки даних в умовах нестационарності.




Рисунок 3.3 – Модель узагальненої регресійної нейро-фаззі мережі

3.6 Нечітка машина опорних векторів

Мащини опорних векторів (SVM) є своєрідним гібридом систем, одночасно базуються як на оптимізації, так і на пам'яті. За конструкцією їх архітектура збігається з архітектурою радіально-базисної нейромережі і узагальненої регресійної нейронної мережі, їх синаптичні ваги визначаються в результаті рішення задачі оптимізації, а центри активаційних функцій встановлюються за принципом «нейрони в точках даних». І хоча ці мережі мають цілий ряд безперечних переваг, їх навчання з обчислювальної точки зору є досить трудомістким, оскільки пов'язано з вирішенням завдання нелінійного програмування високої розмірності. У зв'язку з цим, в якості альтернативи SVM були запропоновані машини опорних векторів,

засновані на методі найменших квадратів (LS-SVM) [11], навчання яких зводиться до вирішення системи лінійних рівнянь.

Фаззі-аналогом SVM є нечітка машина опорних векторів (FSVM) [12], в якій багатовимірні активаційні функції замінені одновимірними функціями належності. В [13] була розглянута FSVM, заснована на методі найменших квадратів (LS-FSVM) і призначена для вирішення задачі розпізнавання образів, коли в процесі навчання сигнали можуть приймати значення +1 або -1.

В рамках цієї роботи, перетворення, яке реалізується на основі LS-FSVM (далі використовується позначення FS), може бути записано у вигляді (формула 3.28)

$$\hat{y}^{FS}(x) = \sum_{k=1}^N w_k^{FS} \frac{\prod_{i=1}^n \mu_{ki}(x_i)}{\sum_{k=1}^N \prod_{i=1}^n \mu_{ki}(x_i)} = \sum_{k=1}^N w_k^{FS} \varphi^{FS}(x(k)) = (w^{FS})^T \varphi^{FS}(x), \quad (3.28)$$

а її навчання зводиться до установки центрів функцій належності $\mu_{ki}(x_i)$ в $x_i(k)$ точках і оптимізації квадратичного критерію навчання (формула 3.29)

$$E^{FS} = \frac{1}{2} \|w^{FS}\|^2 + \frac{\gamma}{2} \sum_{k=1}^N e^2(k) \quad (3.29)$$

з урахуванням обмежень у вигляді системи з N лінійних рівнянь (формула 3.30)

$$y(k) = (w^{FS})^T \varphi^{FS}(x(k)) + e(k), \quad (3.30)$$

де $\gamma > 0$ – параметр регуляризації (формула 3.31),

$$e(k) = y(k) - \hat{y}^{FS}(x(k)). \quad (3.31)$$

Оптимізація критерію (3.29) без урахування обмежень (3.30) веде до вираження (формула 3.32)

$$w^{FS}(N) = \left(\sum_{k=1}^N \varphi^{FS}(x(k))(\varphi^{FS}(x(k)))^T + \gamma^{-1} I_{N,N} \right)^{-1} \left(\sum_{k=1}^N \varphi^{FS}(x(k))y(k) \right), \quad (3.32)$$

що по суті є рідж-оцінкою при $\delta = \gamma^{-1}$.

Для обліку системи обмежень (3.35) введемо в розгляд функцію Лагранжа (формула 3.33)

$$\begin{aligned} L(w^{FS}, e(k), \lambda(k)) &= E^{FS} + \sum_{k=1}^N \lambda(k)(y(k) - (w^{FS})^T \varphi^{FS}(x(k)) - e(k)) = \\ &= \frac{1}{2} (w^{FS})^T w^{FS} + \frac{\gamma}{2} \sum_{k=1}^N e^2(k) + \sum_{k=1}^N \left(y(k) - (w^{FS})^T \varphi^{FS}(x(k)) - e(k) \right) \end{aligned} \quad (3.33)$$

(тут $\lambda(k)$ – N невизначених множників Лагранжа) і систему рівнянь Каруша-Куна-Таккера (формула 3.34):

$$\begin{cases} \nabla_{w^{FS}} L = w^{FS} - \sum_{k=1}^N \lambda(k) \varphi^{FS}(x(k)) = \vec{0}_N, \\ \frac{\partial L}{\partial e(k)} = \gamma e(k) - \lambda(k) = 0, \\ \frac{\partial L}{\partial \lambda(k)} = y(k) - (w^{FS})^T \varphi^{FS}(x(k)) - e(k) = 0, \end{cases} \quad (3.34)$$

де $\vec{0}_N - (N \times 1)$ – вектор, сформований нулями.

Із виразу (3.34) випливає (формула 3.35)

$$\begin{cases} w^{FS}(N) = \sum_{k=1}^N \lambda(k) \varphi^{FS}(x(k)), \\ \lambda(k) = \gamma e(k), \\ y(k) = (w^{FS})^T \varphi^{FS}(x(k)) + e(k), \end{cases} \quad (3.35)$$

або в матричному вигляді (формула 3.36)

$$\left(\gamma^{-1} I_{N,N} + \Omega \right) \begin{pmatrix} \lambda(1) \\ \lambda(2) \\ \vdots \\ \lambda(N) \end{pmatrix} = \begin{pmatrix} y(1) \\ y(2) \\ \vdots \\ y(N) \end{pmatrix}, \quad (3.36)$$

(тут $\Omega = \{ \Omega_{ij} = (\varphi^{FS}(x(i)))^T \varphi^{FS}(x(j)) \}$),

звідки (формула 3.37)

$$\vec{\lambda} = (\gamma^{-1} I_{N,N} + \Omega)^{-1} Y. \quad (3.37)$$

Остаточно вираз (3.28) з урахуванням (3.36) і (3.37) набуває вигляду (формула 3.38)

$$\hat{y}^{FS}(x) = \left(\sum_{k=1}^N \lambda(k) \varphi^{FS}(x(k)) \right)^T \varphi^{FS}(x). \quad (3.38)$$

3.7 Метод навчання еволюційного ансамблю нейро-фаззі систем з ядерними функціями належності

Архітектура еволюційної нейро-фаззі системи складається з п'ятих послідовно з'єднаних шарів. На вхідний (нульовий) шар подається $(n \times 1)$ – вимірний вектор вхідних сигналів $x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T$, $k = 1, 2, \dots, N$, що

підлягає обробці. Перший прихований шар містить nh функцій належності $\mu_{il}(x)$, $i = 1, 2, \dots, n$; $l = 1, 2, \dots, h$ і виконує фазифікацію вхідних змінних, при цьому значення h може змінюватися в процесі навчання (еволюції) системи. Другий прихований шар здійснює агрегування рівнів належностей, обчислених у першому шарі, і складається з h блоків множення. Третій прихований шар – це шар синаптичних ваг, що підлягають визначенню в процесі навчання системи. Четвертий шар утворено двома суматорами й обчислює суми вихідних сигналів другого й третього шарів. І, нарешті, у п'ятому (вихідному) шарі проводиться нормалізація, в результаті якої обчислюється вихідний сигнал системи $\hat{y}^F$. Схематичне представлення ансамблю нейро-фаззі систем наведено на рисунку 3.4.

Вводячи в розгляд (3×1) вектори вихідних сигналів $\hat{y}(k) = (\hat{y}^{TS}(k), \hat{y}^{GF}(k), \hat{y}^{FS}(k))^T$ і параметрів об'єднання $w^F = (w_{TS}^F, w_{GF}^F, w_{FS}^F)^T$, будемо шукати оптимальний вихідний сигнал у вигляді (формула 3.38)

$$\hat{y}^F(k) = (w^F)^T \hat{y}(k) \quad (3.38)$$

при обмеженнях на незміщення $I_3^T w^F = 1$, де $I_3 - (3 \times 1)$ – вектор, утворений одиницями.

Невідомий вектор параметрів w^F може бути визначений за допомогою методу штрафних функцій, для чого вводиться $(N \times 3)$ матриця вихідних сигналів $\hat{Y} = (\hat{y}(1), \hat{y}(2), \dots, \hat{y}(N))^T$ і критерій оптимізації (формула 3.39)

$$E^F = (Y - \hat{Y}w^F)^T (Y - \hat{Y}w^F) + \rho^{-2} (1 - I_3^T w^F), \quad (3.39)$$

де ρ – штрафний коефіцієнт.




Рисунок 3.4 – Ансамбль нейро-фаззі систем

Мінімізація (3.29) по w^F веде до виразу (формула 3.40)

$$w^F(\rho) = (\hat{Y}^T \hat{Y} + \rho^{-2} I_3 I_3^T)^{-1} (\hat{Y}^T Y + \rho^{-2} I_3), \quad (3.40)$$

який після нескладних перетворень набуває вигляд (формула 3.41)

$$w^F(N) = \lim_{\rho \rightarrow 0} w^F(\rho) = w^{LS}(N) + P^F(N) \frac{1 - I_3^T w^{LS}(N)}{I_3^T P^F(N) I_3}, \quad (3.41)$$

де (формула 3.42)

$$w^{LS}(N) = (\hat{Y}^T \hat{Y})^{-1} \hat{Y}^T Y = P^F(N) \hat{Y}^T Y \quad (3.42)$$

– звичайна оцінка найменших квадратів.

Елементом вектора $w^F(N)$ (3.41) можна надати сенс належностей кожної з підсистем ансамблю ТСК, GRNFN і FSVМ до деякої гіпотетичної оптимальної системи, якщо забезпечити їх невід'ємність у процесі об'єднання.

Вводячи у розгляд лагранжіан (формула 3.43)

$$L(\mu^F, \lambda^F, \rho^F) = (Y - \hat{Y}\mu^F)^T (Y - \hat{Y}\mu^F) + \lambda^F (I_3^T \mu^F - 1) - (\rho^F)^T \mu^F, \quad (3.43)$$

де $\mu^F - (3 \times 1)$ – вектор рівнів належності;

λ^F – невизначений множник Лагранжа;

$\rho^F - (3 \times 1)$ – вектор невід'ємних множників Лагранжа,

Систему рівнянь можна записати у вигляді (формула 3.50)

$$\begin{cases} \nabla_{\mu^F} L = \vec{0}_3, \\ \frac{\partial L}{\partial \lambda^F} = 0, \end{cases} \quad (3.50)$$

розв'язок якої має вигляд (формула 3.51)

$$\begin{cases} \mu^F = P^F(N) (\hat{Y}^T \hat{Y} + 0,5 \lambda^F I_3 + 0,5 \rho^F), \\ \lambda^F = \frac{I_3^T P^F(N) \hat{Y}^T Y - 1 + 0,5 I_3^T P^F(N) \rho^F}{0,5 I_3^T P^F(N) I_3}, \end{cases} \quad (3.51)$$

і використовуючи процедуру Ерроу-Гурвіца-Удзави, одержуємо метод навчання векторів μ^F та ρ^F у вигляді

$$\begin{cases} \mu^F(k+1) = w^{LS}(k+1) - P^F(k+1) \times \\ \times (I_3^T w^{LS}(k+1) - 1 + 0,5 I_3^T P^F(k+1) \rho^F(k)) (I_3^T P^F(k+1) I_3)^{-1} I_3 + \\ + 0,5 P^F(k+1) \rho^F(k), \\ \rho^F(k+1) = \text{Pr}_+(\rho^F(k) - \eta_\rho(k+1) \mu^F(k+1)), \end{cases} \quad (3.52)$$

де w^{LS} – визначається виразом (3.47);

$\text{Pr}_+(\cdot)$ – проектор на додатний ортант.

Можна показати, що метод навчання (3.52) елементарно поширюється на довільну кількість систем, що входять в ансамбль та дозволяє синтезувати оптимальний вихідний сигнал і встановлювати рівні належності до деякої гіпотетичної оптимальної системи.

4 ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ТА ІМІТАЦІЙНЕ МОДЕЛЮВАННЯ

Імітаційне моделювання – метод, що дозволяє будувати моделі, що описують процеси так, як вони відбувалися б в дійсності. Таку модель можна «програти» в часі як для одного випробування, так і заданої їх безлічі. При цьому результати будуть визначатися випадковим характером процесів. За цими даними можна отримати достатньо стійку статистику. Імітаційна модель – це логіко-математичний опис об'єкта, яке може бути використане для експериментування на комп'ютері в цілях проектування, аналізу та оцінки функціонування об'єкта [14].

Метод імітаційного моделювання доцільно застосовувати, коли:

- дорого або неможливо експериментувати на реальному об'єкті;
- неможливо побудувати аналітичну модель: в системі є час, причинні зв'язки, наслідки, нелінійності, стохастичні (випадкові) змінні;
- необхідно зімітувати поведінку системи в часі.

Метою імітаційного моделювання є відтворення поведінки досліджуваної системи на основі результатів аналізу найбільш суттєвих взаємозв'язків між її елементами або іншими словами – розробці симулятора досліджуваної предметної області для проведення різних експериментів.

Імітаційне моделювання дозволяє імітувати поведінку системи в часі. Причому перевагою є те, що часом моделі можна управляти: уповільнювати у випадку з швидкоплинними процесами і прискорювати для моделювання систем з повільною нестационарністю. Можна імітувати поведінку тих об'єктів, експерименти з якими дорого коштують, неможливі або небезпечні.

Для того щоб перевірити, наскільки точно побудована модель проводить ідентифікацію або прогнозує дані спостережень, необхідно порівняти їх при однакових впливах. Ця процедура називається верифікацією моделі. Оскільки в дійсній роботі розглядається випадок де моделлю буде та чи інша архітектура нейронної мережі, процедура її верифікації формально зводиться до наступних етапів:

- визначення вхідних і вихідних параметрів для навчальної вибірки;
- визначення вхідних і вихідних параметрів для тестової вибірки;
- вибір методу налаштування вагових коефіцієнтів системи;
- навчання нейронної мережі і нейро-фаззі системи з використанням навчальної або навчальної та тестової вибірок (в залежності від методу налаштування вагових коефіцієнтів);
- розрахунок помилки на виході нейронної мережі або нейро-фаззі системи, що дозволяє зробити висновок про якість її роботи.

Однак, крім помилки на виході нейронної мережі або нейро-фаззі системи, необхідно враховувати і інші кількісні та якісні параметри, такі як:

- кількість елементів (нейронів) всередині системи;
- час навчання системи;
- можливість навчання в реальному режимі часу;
- можливість лінгвістичної інтерпретації отриманих результатів.

При вирішенні за допомогою нейронних мереж і нейро-фаззі систем прикладних задач необхідно зібрати достатній і представницький обсяг даних для того, щоб навчити систему. Навчальний набір даних – це набір спостережень, що містять характерні ознаки досліджуваного об'єкта. Однією з головних проблем є вибір вхідних параметрів мережі, а також питання про те, скільки і яких спостережень треба провести.

Вибір ознак, принаймні, початковий, здійснюється евристичний на основі наявного досвіду, який може підказати, які ознаки є найбільш важливими. Спочатку слід включити всі ознаки, які, на думку аналітиків або експертів, є суттєвими, на наступних етапах це безліч може бути скорочено.

Питання про те, скільки потрібно мати спостережень для навчання мережі, в більшості випадків не має строгого відповіді. Відомий ряд евристичних правил, які встановлюють зв'язок між кількістю необхідних спостережень і розмірами мережі. Найпростіше з них говорить, що кількість спостережень має бути, як мінімум, в 10 разів більше числа зв'язків в мережі. Насправді це число залежить від складності того відображення, яке має відтворювати нейронна мережа або нейро-фаззі

система. Для більшості реальних задач буває досить кілька сотень або тисяч спостережень. Для складних завдань може знадобитися більше, дуже рідко зустрічаються завдання, для яких можна отримати прийнятні результати, маючи менше 100 спостережень.

В даному розділі наведені результати імітаційного моделювання розробленої в попередньому розділі архітектури нейро-фаззі мережі і алгоритму її синаптичної і структурної адаптації. Для оцінки точності одержуваних результатів використовувався стандартний критерій – величина середньоквадратичної помилки (формула 4.1)

$$RMSE = \sqrt{\frac{\sum_{k=1}^N e^2(k)}{N}}, \quad (4.1)$$

де $e(k)$ – помилка на вході мережі для k – го спостереження;

N – обсяг тестової вибірки.

Для підтвердження теоретичних дослідження точність роботи розробленого ансамблю нейро-фаззі систем було порівняно зі стандартною нейро-фаззі системою ТСК, радіально-базисною нейронною мережею та узагальненою регресійною нейромережею.

4.1 Сутність і класифікація прогнозів

Прогнозування – це вид пізнавальної діяльності людини, спрямованої на формування прогнозів розвитку об'єктів, на основі аналізу тенденцій і закономірностей його розвитку.

Прогнозування – це розділ інтелектуального аналізу даних, засноване на системі встановлених причинно-наслідкових зв'язків і закономірностей, виявлення стану і імовірнісних шляхів розвитку явищ і процесів.

Прогнозування зумовлює оцінку показників і дає характеристику явищ і процесів в майбутньому. Прогнозування поширюється на такі процеси управління,

які в момент вироблення прогнозів можна визначити в дуже малому діапазоні, або зовсім неможливо, або можливо, але вимагає врахування дії таких факторів, вплив яких не може бути повністю або однозначно визначено.

Залежно від ступеня конкретності і характеру впливу на хід досліджуваних процесів і явищ можна виділити три основні поняття прогнозування:

- гіпотеза;
- передбачення;
- прогноз.

Дані поняття тісно взаємопов'язані в своїх проявах один з одним і з досліджуванним об'єктом і являють собою послідовні ступені пізнання поведінки явища і об'єкту в майбутньому.

Гіпотеза – це науково обгрунтоване припущення або про факти, що безпосередньо не спостерігаються, або про послідовність, котра пояснює відому сукупність явищ.

На рівні гіпотези дається якісна характеристика об'єкта, що виражає загальні закономірності його поведінки.

Гіпотезою є не всяка думка, а лише припущення, яке носить ймовірний характер. Встановивши, що група явищ, закономірний зв'язок яких невідомий, має ряд тотожних рис з іншою групою явищ, закономірний зв'язок яких вже встановлена, робиться висновок про ймовірність часткової подібності шуканої закономірності у зв'язку з визначеною.

Розвиваючись, гіпотеза одночасно піддається перевірці, необхідність якої випливає із самої сутності гіпотези як припущення.

Перевірка гіпотези полягає в тому, що всі слідства, отримані за допомогою теоретичного аналізу основного допущення гіпотези зіставляються з емпіричними даними.

Якщо по одній і тій же задачі, проблеми і так далі виникає одночасно кілька гіпотез і відомо, які гіпотези тут взагалі можливі, а які – ні, то доказом істинності однієї з розглянутих гіпотез є встановлення хибності всіх інших.

Ступінь ймовірності гіпотези тим вище, чим різноманітніше і більш

численною її слідства, підтверджені емпіричним шляхом.

Достатність умов реалізації гіпотез, їх вірогідність теоретично і практично межує з високим ступенем достовірності. Гіпотеза впливає на процес через прогноз, будучи важливим джерелом інформації для його складання.

Передбачення – це передбачення таких подій, кількісна характеристика яких неможлива або утруднена.

Прогноз – це кількісний, розподіл усіх твердження в майбутньому про стан об'єкта або явища з відносно високим ступенем достовірності, на основі аналізу тенденцій і закономірностей минулого і сьогодення.

Прогноз в порівнянні з гіпотезою має більшу визначеність і достовірність, так як ґрунтується як на якісних, так і на кількісних характеристики. В окремих випадках прогноз може носити якісний характер, але в його основі завжди лежать кількісні явища.

Для здійснення прогнозу, тобто визначення понять, як буде здійснюватися і розвиватися прогнозовані явища в майбутньому, необхідно знати тенденції та закономірності минулого і сьогодення. При цьому слід пам'ятати, що майбутнє залежить від багатьох випадкових факторів, складне переплетення і поєднання яких врахувати практично неможливо. Отже, всі прогнози носять імовірнісний характер.

4.2 Опис використовуваного інструментарію

Для вирішення поставленого завдання була використана система для математичних обчислень GNU Octave. Octave використовує сумісний з MATLAB мову високого рівня.

Octave являє собою інтерактивний командний інтерфейс для вирішення лінійних і нелінійних математичних задач, а також проведення інших численних експериментів. Крім того, Octave можна використовувати для пакетної обробки. Мова Octave оперує арифметикою дійсних і комплексних скалярів і матриць, має розширення для вирішення лінійних алгебраїчних задач, знаходження коренів

систем нелінійних алгебраїчних рівнянь, роботи з поліномами, рішення різних диференціальних рівнянь, інтегрування систем диференційних і диференційно-алгебраїчних рівнянь першого порядку, інтегрування функцій на кінцевих і нескінченних інтервалах. Цей список можна легко розширити, використовуючи мову Octave (або використовуючи динамічно завантажувані модулі, створені на мовах C, C ++, Фортран та ін.).

Octave написаний на C ++ з використанням бібліотеки стандартної бібліотеки шаблонів. Для запуску скриптів Octave використовує інтерпретатор. Octave можна доповнювати динамічно модулями ядра. Для створення і роздруківки графіків Octave використовує gnuplot і Grace.

Octave був написаний з урахуванням сумісності з MATLAB і реалізує багато його можливості:

- матриці в якості основних типів даних;
- вбудована підтримка комплексних чисел;
- потужні вбудовані математичні функції і великі бібліотеки функцій;
- розширюваність, завдяки можливості створення призначених для користувача функцій.

4.3 Прогнозування часових рядів за допомогою розробленої архітектури нейро-фаззи мережі

Одним з найбільш популярних формалізмів вирішення завдань, зокрема, задач прогнозування споживання електроенергії є парадигма експертної системи. Така система може використовувати найрізноманітніші методи штучного інтелекту для запам'ятовування і вилучення даних. Ранні експертні системи використовували або традиційні методи з послідовною обробкою даних, які статистичні методи. Більш успішним виявилось застосування в якості ядра експертної системи нейромережових структур. Зокрема, нейромережові алгоритми не передбачають використання експерта в галузі застосування.

Нейромережові системи володіють декількома відмінними властивостями,

які роблять їх найбільш привабливим засобом для вирішення багатьох завдань штучного інтелекту. Прогнозування фінансових показників, як правило, пов'язане з урахуванням великої кількості параметрів, що впливають на поведінку системи.

Електроенергія як продукт виробництва має однією істотною властивістю - процес споживання цього продукту не може бути відділений від процесу власне виробництва, вироблений товар повинен бути негайно доставлений до споживача і витрачений. В таких умовах всі суб'єкти системи організаційного управління Об'єднаної електроенергетичної системою (виробники електроенергії, постачальники електроенергії, Національна енергетична компанія «Укренерго», ДП «Енергоринок», споживачі електричної енергії, Міністерство палива та енергетики, Національна комісія регулювання електроенергетики) зацікавлені в прогнозі необхідної електричного навантаження. Кожен із суб'єктів системи при реалізації функцій управління вирішує свої специфічні завдання, для вирішення яких необхідні свої конкретні прогнози електричного навантаження. Приблизно з другої половини XX століття вчені і практики стали все частіше і частіше помічати, що традиційні методи розрахунку, проектування і прогнозування великих технічних систем, засновані на класичній математичній статистиці, далеко не завжди дають коректні результати. Технічні об'єкти, технологічні процеси, багатогранність структури сучасного промислового підприємства, вимагають ефективних підходів до прогнозування виробничих показників і мінімізації різних видів витрат, що в кінцевому підсумку спрямоване на підтримку прийняття управлінських рішень [15-20].

Останнім часом значного поширення набули методи, засновані на нелінійних моделях. Велика частина таких методів належить до розряду, так званих, технік штучного інтелекту. Це, в першу чергу, штучні нейронні мережі і новітні засоби оптимізації, до числа яких відносяться, наприклад, що еволюціонують нейронні мережі та багато інших. Як правило, такі методи вимагають значних обчислювальних ресурсів. Сучасне бурхливий розвиток обчислювальної техніки значно спрощує процес побудови і реалізації таких моделей.

4.4 Ідентифікація динамічного об'єкта в режимі послідовної обробки інформації

Розроблений в попередніх розділах ансамбль гібридних нейро-фаззі систем та адаптивний алгоритм його навчання застосовувалися для розв'язання задачі ідентифікації динамічного об'єкта, запропонованого в [21] і описуваного наступним рівнянням (формула 4.2):

$$y(k) = 0.3y(k-1) + 0.6y(k-2) + f(u(k-1)), \quad (4.2)$$

де $f(u) = 0.6\sin u(k-1) + 0.3\sin 3u(k-1) + 0.1\sin 5u(k-1)$.

Була згенерована послідовність, що містить 1500 значень сигналу для $k = 1, 2, \dots, 1500$. При цьому відзначимо, що сигнал $u(k)$ не був однаковий на всій послідовності, а змінювався таким чином: $u(k) = \sin 2k / 250$ для $k = 1, 2, \dots, 1000$, і $u(k) = 0.5\sin 2k / 250 + 0.5\sin 2k / 25$ при $k = 1001, \dots, 1500$. Отримані значення сигналу були попередньо нормалізовані на інтервал $[-1, 1]$.

Задача ідентифікації нелінійної функції вирішувалася в пакетному режимі навчання і в режимі послідовної обробки інформації. З метою підтвердження отриманих в попередньому розділі теоритичних результатів ансамбль нейро-фаззі систем з ядерними функціями належності було порівняно з традиційними нейромережевими архітектурами: радіально-базисної мережі і узагальненої регресійної нейромережі. Для навчання в пакетному режимі використовувалися перші 500 елементів послідовності, а останні 1000 розглядалися як перевірюча вибірка. Зауважимо, що саме на перевірючій вибірці сигнал змінював свою форму. Така ж точно послідовність використовувалася в режимі послідовної обробки інформації, проте в цьому випадку, очевидно, що вибірка не ділилася на навчальну і перевірючу. Отримані результати імітаційного моделювання наведені на рисунках 4.1 та 4.2 і в таблиці 4.1.




Рисунок 4.1 – Результати ідентифікації динамічного об'єкта за допомогою ансамблю нейро-фаззі систем – пакетний режим навчання




Рисунок 4.1 – Результати ідентифікації динамічного об'єкта за допомогою еволюційної нейро-фаззі системи – режим послідовної обробки інформації

Таблиця 4.1 – Результати ідентифікації динамічного об'єкта

Архітектура нейронної мережі/нейро-фаззі системи	Кількість функцій належності/активації	Режим навчання (пакетне/послідовне)	Помилка ідентифікації
Ансамбль нейро-фаззі систем	15	пакетне	0,012
		послідовне	0,015
Радіально-базисна нейронна мережа	9	пакетне	0,126
		послідовне	0,134
Узагальнена регресійна нейро-фаззі мережа	26	пакетне	0,011
		послідовне	0,013

Таким чином проведене імітаційне моделювання розробленого ансамблю нейро-фаззі систем та його адаптивного методу навчання доводить, що запропонована архітектура та її адаптивний метод навчання має високі апроксимуючі здібності і дозволяє опрацьовувати великі масиви інформації у послідовному режимі.

4.5 Прогнозування за допомогою ансамблю нейро-фаззі систем в задачах електроенергетики

Актуальність проблеми енергозбереження як в рамках всього народногосподарського комплексу України, так і для окремих споживачів на місцях, не викликає сумнівів. Рішення задач енергозбереження в системах електропостачання неможливо без надійного коротко- і довгострокового прогнозування електроспоживання [22-25]. Результати такого прогнозування виступають в якості необхідної базової інформації для багатьох завдань енергозбереження.

Організація прогнозів електроспоживання ускладнюється тим, що процес електроспоживання не є детермінованим і не завжди статистично стійкий. Невизначеність цього процесу особливо проявляється в умовах енергетичної і

фінансової кризи. Також на рівень електроспоживання впливає велика кількість чинників, таких як технологічні і економічні характеристики споживачів, умови навколишнього середовища, соціальні та демографічні особливості регіону і т.п.

Труднощі побудови моделей для прогнозування полягає в тому, що між зовнішніми факторами, що впливають на саму модель, існують внутрішні взаємозв'язки, які повністю не виявлені і складно піддаються формалізації. Те ж можна сказати і про дослідження зв'язків між факторами, що впливають і величиною навантаження. Серед різних методик, які пропонувалися для вирішення задачі прогнозування добових графіків споживання електричної потужності, слід зазначити моделювання методами екстраполяції часових рядів і регресійний аналіз.

Недоліком таких моделей є необхідність для їх побудови великої кількості статистичної інформації за багатьма взаємопов'язаними технологічними, комерційними, екологічними і соціальними факторами, яка не завжди є в наявності. Непогані результати були досягнуті при застосуванні імітаційної моделі, побудованої методом самоорганізації на основі МГУА - методу групового урахування аргументів, проте дана модель не була пристосована для обліку поточних значень-факторів, що впливають на модель. При моделюванні статистичними методами необхідною умовою є статистична стійкість параметрів прогнозування (як, власне, і для попередніх двох методів), яке в умовах дії нестационарних факторів складно задовільнити. Те ж стосується і методики моделювання графіків енергонавантаження за допомогою лінійного періодичного випадкового процесу [26-29].

Для вирішення задачі прогнозування електроспоживання був запропонований також підхід, заснований на використанні нейронних мереж. Основною перевагою такого підходу в порівнянні з іншими є можливість безпосереднього прогнозу добових графіків електричних навантажень з урахуванням заданих факторів, що впливають (тип доби, сезонність, середньодобова температура повітря, перехід на літній чи зимовий час) з перспективою на десять діб, що забезпечується попереднім навчанням прогнозуючої нейронної мережі за допомогою навчальної вибірки добових

графіків річної передісторії. Такий підхід дозволяє обійти труднощі опису статистичних закономірностей традиційними методами, проте при цьому є і ряд недоліків.

По-перше, для навчання нейронної мережі застосовується згадуваний вище алгоритм зворотнього поширення похибок, що не дозволяє вирішити проблему локальних оптимумів. По-друге, громіздкість моделі, обумовлена великою кількістю нейронів, які забезпечують різні комбінації факторів, що впливають. По-третє, викликає сумнів ступінь довіри до графіків побудованих прогнозів, які були отримані у вигляді детермінованих часових рядів. Оскільки навіть дуже досконала модель не в змозі врахувати всі чинники, що впливають на точність прогнозу, то така форма прогнозу не забезпечується інструментарієм оцінки його похибки. Підсумувавши вищевикладений аналіз, можна виділити такі основні проблеми, властиві задачі прогнозування добових графіків споживання електричної потужності:

1) практична відсутність статистичної стійкості для даних електроспоживання в сучасних умовах, що ставить під сумнів ступінь довіри до моделей, побудованих методами теорії ймовірностей і математичної статистики;

2) недостатня достовірність представлення результатів прогнозування у вигляді детермінованих графіків електричних навантажень, оскільки багато що впливають фактори мають якісну природу і складно піддаються формалізації при застосуванні традиційних методів моделювання.

Останнім часом значного поширення набули методи, засновані на нелінійних моделях. Велика частина таких методів належить до методів обчислювального інтелекту. Це, в першу чергу, що еволюційні системи обчислювального інтелекту і новітні засоби оптимізації, до числа яких відносяться, наприклад, що еволюційні нейронні мережі та нейро-фаззі системи. Як правило, такі методи вимагають значних обчислювальних ресурсів. Сучасний бурхливий розвиток обчислювальної техніки значно спрощує процес побудови і реалізації таких моделей.

Для реалізації задачі прогнозування споживання електроенергії використовується вибірка, що складається з 2611 спостережень, які

характеризують споживання електроенергії по Україні в період з 01 грудня 2013р. по 25 травня 2019р. (помісячно). Для того, щоб побудувати прогнозатор на базі розробленого ансамблю нейро-фаззі систем, була проведена попередня обробка даних у вигляді, як в таблиці 4.2.

Таблиця 4.2 – Фрагмент вибірки споживання електроенергії по Україні за період з жовтня 2018р. по травень 2019р.

	Жовтень 2018	Листопад 2018	Грудень 2018	Січень 2019	Лютий 2019	Березень 2019	Квітень 2019	Травень 2019
$x_1(k)$	558275	543247	541478	582639	583798	579065	578932	575576
$x_2(k)$	565640	558275	543247	541478	582639	579065	583798	578932
$x_3(k)$	550135	534579	573978	589912	594405	568605	573412	598185

де $x_1(k)$ – кількість споживаної електроенергії на наступний місяць,

$x_2(k)$ – кількість споживаної електроенергії за поточний місяць,

$x_3(k)$ – це сезонна компонента, кількість споживаної електроенергії дванадцять місяців назад.

Дані по споживанню електроенергії були пронормовані в діапазон $[0, 1]$, потім були подані на входи блоків ансамблю нечітких нейро-фаззі мереж. Спочатку мережа була запущена в режимі навчання. Режим навчання був організований таким чином: на вхід мережі було подано вхідний вектор. При цьому вхідний вектор формувався з попередніх значень зі зрушенням в 2 тижні, тобто початковим значенням було не перше значення, а п'ятнадцяти. Кількість таких значень збігалася з кількістю значень функцій належності в ансамблі нейро-фаззі систем. У даній роботі, це значення було прийнято рівним трьом.




Рисунок 4.3 – Графічне відображення даних по споживанню електроенергії

При цьому були отримані такі результати:




Рисунок 4.4 – Результати роботи в режимі навчання мережі

Результативна помилка склала 4,43%. Ряд значень споживання електроенергії має нестационарну природу, тому система зуміла мінімізувати помилку, обробивши 120 точок.

Далі система була запущена в режим прогнозування. Слід зазначити, що перевірку результатів прогнозування було вирішено виконати таким чином: система повертала деякий результуючий вектор, значення якого, так само, як і значення вхідного вектора, перебували в діапазоні $[0, 1]$, далі значення цього вихідного вектора за допомогою квадратичного критерію помилки порівнювалися з істинними значеннями. Тобто тепер в якості історії використовувалися значення, які спрогнозувала сама мережа. При цьому кількість прогнозованих точок було обмежено до 14. Результати прогнозування:




Рисунок 4.5 – Результати прогнозування часового ряду споживання електроенергії




Рисунок 4.6 – Графік зміни помилки прогнозування
на тимчасовому ряді споживання електроенергії

У цьому випадку помилка склала 5,37%. При цьому варто відзначити, що сумарна помилка на різних часових відрізках змінювалась в межах 3-7%. Також варто відзначити, що на початку експерименту перерахунок центрів після надходження кожного нового значення не проводився, і помилка досягала 20%. При перерахунку значень центрів функція швидко виходила з області локального екстремуму, що сприяло різкому зменшенню результуючої помилки.

Спроби збільшення кількості значень для прогнозування привели до збільшення помилки. Наприклад, для 60 точок помилка прогнозування склала 27,31%.

Графіки на рисунках 4.7 і 4.8 показують, що алгоритму потрібен певний час для підстроювання своїх параметрів при старті його «з нуля», так як початкові параметри задаються випадковим чином. Також при різких змінах тренда часового ряду, алгоритм поводить себе нестабільно певний час. Це пов'язано з тим, що для вхідних даних використовуються історія самого ряду, тому алгоритм «пам'ятає» старі дані і не миттєво змінює свої вільні змінні. Також це пов'язано з тим, що на

вхід подається лише історія ряду без додаткової інформації про можливу зміну властивостей ряду. Такою інформацією, наприклад, може бути дата для часового ряду про споживання електроенергії, що дозволить врахувати сезонну компоненту.




Рисунок 4.7 – Прогноз на 60 спостережень

Варто відзначити, що дана система не проводить аналіз прихованих залежностей в вибірці, як наприклад, сезонність, споживання електроенергії в святкові дні. Також варто відзначити, що навіть за умови регулювання параметрів на кожній ітерації процедури прогнозування не завжди давала бажані результати.

Аналізуючи результати, отримані під час прогнозування, можна відзначити, що ряд має можливість прогнозувати на невеликий крок (близько 15-25 кроків), після чого прогнозована функція згладжується.




Рисунок 4.8 – Результати апроксимації часового ряду споживання електроенергії




Рисунок 4.9 – Графік зміни похибки апроксимації часового ряду споживання електроенергії

Використовуючи реальні дані про споживання електроенергії, було проведено тестування здатності ансамблю нейро-фаззі систем до вирішення задачі прогнозування. Отримана результуюча точність прогнозу дозволяє з високою ймовірністю визначати рівні споживання електроенергії. Однак, варто зазначити, що на даному етапі дана нейро-фаззі система поки не здатна демонструвати високу точність прогнозу на великих часових відрізках, що було показано при експериментальних дослідженнях. Причиною цього є нестационарність властивостей часового ряду і наявність залежностей, які не були враховані в математичній моделі розробленого ансамблю нейро-фаззі систем. Для поліпшення якості довгострокового прогнозу необхідно враховувати приховані закономірності в аналізованій вибірці.

ВИСНОВКИ

В атестаційній роботі магістра розглядається задача гібридного навчання еволюційної нейро-фаззі мережі, заснованої на об'єднанні різних архетипів навчання (оптимізація, «нейрони в точках даних»). розглянутий підхід забезпечує рішення задач апроксимації, інтерполяції, прогнозування, ідентифікації, інтелектуального управління системами, в яких інформація надходить на опрацювання послідовно в on-line режимі. Дослідження показали, що розглянута модель ансамблю еволюційних нейро-фаззі мереж є достатньо конкурентоспроможною в порівнянні з іншими алгоритмами та системами для прогнозування нестационарних часових рядів. Зокрема, можливості прогнозатора дозволяють його успішне використання для вирішення завдань прогнозування в умовах короткого часового ряду та послідовного надходження спостережень на опрацювання. В роботі отримані наступні результати:

- введені чисельно прості і швидкодіючі алгоритми навчання, що дозволяють в реальному часі синтезувати оптимальний відгук мережі;
- запропонований алгоритм навчання ансамблю еволюційних нейро-фаззі систем з дзвонуватими функціями належності, забезпечує високу швидкість і якість навчання;
- було проведено імітаційне моделювання на даних, згенерованих за допомогою диференціального рівняння. Варто відзначити, що побудована нейро-фаззі система показала дуже високу точність, як на етапі навчання, так і на етапі прогнозування. Цей факт безпосередньо пов'язаний з тим, що ряд, що генерується рівнянням, має стаціонарні властивості, які дозволяють системі швидко налаштувати синаптичні ваги і центри функцій приналежності;
- використовуючи реальні дані про споживання електроенергії, було проведено тестування здатності нечіткої нейронної мережі до вирішення задачі прогнозування. Отримана результуюча точність прогнозу дозволяє з високою ймовірністю визначати рівні споживання електроенергії. Однак, варто зазначити, що на даному етапі дана нейро-фаззі система поки не здатна демонструвати високу

точність прогнозу на великих часових відрізках, що було показано при експериментальних дослідженнях. Причиною цього є нестационарність властивостей часового ряду і наявність залежностей, які не були враховані в математичній моделі розробленої нейро-фаззі системи. Для поліпшення якості довгострокового прогнозу необхідно враховувати приховані закономірності в аналізованій вибірці;

– доведено, що еволюціонує нейро-фаззі система є ефективним прогнозатором, який просто реалізувати на практиці.

ПЕРЕЛІК ПОСИЛАНЬ

1. Braun H. Neuronale Netze. Optimierung durch Lernen und Evolution. Berlin : Springer-Verlag, 1997. 279 p.
2. Dracopoulos D.C. Evolutionary Learning Algorithms for Neural Adaptive Control. Evolutionary Learning Algorithms for Neural Adaptive Control. Berlin : Springer-Verlag, 1997. 211 p.
3. Shepherd A.J. Second-Order Methods for Neural Networks. London : Springer-Verlag, 1997. 145 p.
4. Haykin S. Neural Networks. A Comprehensive Foundation. Upper Saddle River, NJ : Prentice Hall, Inc., 1999. 842 p.
5. Angelov P. Evolving Rule-based Models: A Tool for Design of Flexible Adaptive Systems. Heidelberg, New York : Springer-Verlag, 2002. 227 p.
6. Lughofer E. Evolving Fuzzy Systems – Methodologies, Advanced Concepts and Applications. Berlin, Heidelberg : Springer-Verlag, 2011. 456 p.
7. Осовский С. Нейронні мережі для обробки інформації. М.: Фінанси і статистика, 2002. 344 с.
8. Karaianis N.B., Venetsanopoulos A.N. Fast learning algorithm for neural networks // IEEE Trans. on Circuits and Systems. 1992. Vol. 39. p. 453-474.
9. Бодянський, Е.В., Воробйов С.А., Штефан А.А. Алгоритм адаптивної ідентифікації динамічних параметричних нестационарних об'єктів // Теорія і системи управління. 1999. №1. с. 19-23.
10. Кільдишев Г.С., Френкель А.А. Аналіз часових рядів і прогнозування.навч. М .: Статистика. 1973. 521 с.
11. Афанасьєв В.Н., Юзбашев М.М. Аналіз часових рядів і прогнозування. М .: Фінанси і статистика, 2001. сс. 220-223
12. Кендел М. Тимчасові ряди. М. "Фінанси і статистика", 1981. 540 с.
13. Гранічін О.Н. Введення в методи стохастичною оптимізації та оцінювання. СПб.: Літера, 2003. 250 с.

14. Vapnik V.N. Statistical Learning Theory. London: Wiley Interscience, 1998. 736 p.
15. Widrow B., Hoff Jr. Adaptive switching circuits. IRE Western Electric Show and Connection Record, 1960. pp. 96-104.
16. Trippi R.R., Lee J.K. Artificial Intelligence in Finance and Investing: State-of-the-Art Technologies for Securities Selection and Portfolio Management. Upper Saddle, NJ: Prentice Hall, 1996. 250 p.
17. Fausett L.V. Fundamentals of neural networks, architectures, algorithms and applications. Upper Saddle River, NJ: Prentice Hall, 1994. 461 p.
18. Cios K.J., Pedrycz W. Neuro-fuzzy algorithms // Oxford: IOP Publishing Ltd and Oxford University Press. Handbook of Neural Computation, 1997. pp. 271-285.
19. Nelles O. Nonlinear System Identification. Berlin: Springer, 2001. 785 p.
20. Вайн Я. Кореляція рядів динаміки. М.: Фінанси і статистика, 1992. 651 с.
21. Kohonen T. Learning vector quantization. Berlin: Springer, 1988. 105 p.
22. Kasabov N. Evolving Connectionist Systems. London: Springer - Verlag, 2003. 307 p.
23. Бодянський Є.В., Попов С.В. Прогнозуюча нейронна мережа та алгоритми її навчання // Радіoeлектроніка. Інформатика. Управління. 2000. № 1. сс. 60-64.
24. Suykens J.A.K., Gestel T.V., Brabanter J.D., Moor B.D., Vandewalle J. Least Squares Support Vector Machines. Singapore: World Scientific, 2002. 294 p.
25. Wang L.-X. Adaptive Fuzzy Systems and Control. Design and Stability Analysis // Upper Saddle, NJ: Prentice Hall, 1994. 256 p.
26. Jang J.-S., Sun C.-T., Mizutani E., Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Maching Intelligence // Upper Saddle River: Prentice Hall. 1997. 640 p.
27. Rutkowski L. Computational Intelligence. Methods and Tehniques. Berlin-Heidelberg, Springer-Verlag, 2008. 514 p.

28. Achtert E., Goldhofer S., Kriegel H.-P., Schubert E., Zimek A.. Evaluation of clusterings – metrics and visual support // In ICDE Conference. 2012. p. 1285–1288.
29. Muller E., Gnnemann S., Assent I., Seidl T. Evaluating clustering in subspace projections of high dimensional data // PVLDB. 2009. Vol 2(1). p.1270-1281.
30. Xu R., Wunsch D.C. Clustering // IEEE Press Series on Computational Intelligence. Hoboken, NJ : John Wiley & Sons, Inc., 2009. 370 p.
31. Jain A., Dubes R. Algorithms for Clustering Data // Prentice Hall. 1988.
32. Jain A., Murty M., Flynn P. Data clustering: A review // ACM Computing Surveys (CSUR). 1999. Vol 31(3). p.264–323.
33. Kaufman L., Rousseeuw P. Finding Groups in Data: An Introduction to Cluster Analysis // Wiley-Interscience. 2005.
34. Kriegel H.-P., Kroger P., Zimek A.. Clustering high-dimensional data: A survey on sub- space clustering, pattern-based clustering, and correlation clustering // ACM Transactions on Knowledge Discovery from Data (TKDD). 2009 Vol 3(1). p.1 – 58.
35. Gan G., Ma C., Wu J. Data Clustering: Theory, Algorithms, and Applications. SIAM, Society for Industrial and Applied Mathematics, 2007.
36. Schaeffer S. Graph clustering // Computer Science Review. 2007. Vol 1(1). p.27–64.
37. Madeira S., Oliveira A. Biclustering algorithms for biological data analysis: A survey // IEEE/ACM Transactions on Computational Biology and Bioinformatics. 2004. Vol 1(1). p.24–45.