

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет
Кафедра

Комп'ютерної інженерії та управління
Комп'ютерних інтелектуальних технологій та систем

КВАЛІФІКАЦІЙНА РОБОТА **Пояснювальна записка**

рівень вищої освіти

другий (магістерський)

Інтелектуальна система підтримки прийняття рішень
на основі нейронної мережі з імунним навчанням

Виконав:

студент 2 курсу, групи КІТм-20-1

Балим С.В.

Спеціальність 123 Комп'ютерна інженерія

Тип програми освітньо-професійна

Освітня програма Комп'ютерні
інтелектуальні технології

Керівник проф. Корабльов М.М.

Допускається до захисту

(підпис)

Зав. кафедри

(підпис)

проф. Руденко О.Г.

2021 р.

Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерної інженерії та управління
Кафедра _____ Комп'ютерних інтелектуальних технологій і систем
Рівень вищої освіти _____ другий (магістерський)
Спеціальність (напрямок) _____ 123 – Комп'ютерна інженерія
(код і назва)
Освітня програма _____ Комп'ютерні інтелектуальні технології
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

“ _____ ” _____ 20__ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові _____ Балиму Станіславу Володимировичу
(прізвище, ім'я, по батькові)

1. Тема роботи _____ Інтелектуальна система підтримки прийняття рішень на основі
нейронної мережі з імунним навчанням

затверджена наказом по університету від “ 08 ” листопада 2021 р. № 1666 Ст

2. Термін подання студентом роботи до екзаменаційної комісії _____ 10 грудня 2021 р.

3. Вхідні дані до роботи _____

1) нейромережеві та імунні моделі;

2) деякі вхідні та вихідні змінні є лінгвістичними або нечіткими;

3) використання методів штучних імунних систем повинно скорочувати час навчання НМ;

4) використання мови програмування та операційної системи.

4. Перелік питань, що потрібно опрацювати в роботі _____

1) аналіз предмету дослідження;

2) аналіз підходів до створення СППР у важко формалізованих задачах;

3) побудова нейромережевих моделей в СППР;

4) підвищення обчислювальної ефективності навчання багат шарового перцептрона;

5) експериментальні дослідження.

6) висновки.

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (слайдів) Демонстраційні матеріали. Плакати - 16 арк. ф. А4

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

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

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Видача та узгодження теми проєкту	08.11.2021	
2	Огляд стану проблеми та постановка задачі	09.11.2021 – 10.11.2021	
3	Аналіз літератури за напрямком магістерської роботи	10.11.2021 – 14.11.2021	
4	Вибір методів рішення для реалізації та їх обґрунтування.	16.11.2021 – 20.11.2021	
5	Експериментальні дослідження та аналіз отриманих результатів.	21.11.2021 – 28.11.2021	
6	Оформлення пояснювальної записки	29.11.2021 – 05.12.2021	
7	Підготовка графічного матеріалу	06.12.2021 – 10.12.2021	
8	Перевірка виконаного проєкту курівником	10.12.2021	
9	Захист проєкту	16.12.2021 – 17.12.2021	

Дата видачі завдання 08 листопада 2021 р.

Студент _____
(підпис)

Керівник роботи _____
(підпис)

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

РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 90 с., 11 рис., 1 табл., 2 дод., 27 джерел.

НЕЙРОННА МЕРЕЖА, ШТУЧНА ІМУННА СИСТЕМА, БАГАТОШАРОВИЙ ПЕРСЕПТРОН, АНТИГЕН, МУЛЬТИАНТИТІЛО, ЛОКАЛЬНА ОБЧИСЛЮВАЛЬНА МЕРЕЖА

Метою магістерської кваліфікаційної роботи є розробка інтелектуальної системи підтримки прийняття рішень (ІСППР) з використанням нейромережевої технології для побудови моделі прийняття рішень та імунного підходу для настроювання параметрів і структури нейронної мережі. Вона орієнтована на підвищення якості функціонування ІСППР шляхом створення моделі прийняття рішень та еволюції її структури і параметрів за умов невизначеності як зовнішнього середовища, так і властивостей об'єкта прийняття рішень.

Проведені експериментальні дослідження нейромережевої моделі з імунною настройкою для прийняття рішень по створенню та аналізу локальної комп'ютерної мережі (ЛКМ), які показали, що для навчання та прогнозування різних варіантів рішень при виборі тих чи інших параметрів ЛКМ доцільно використовувати нейронні мережі з імунним навчанням.

ABSTRACT

Explanatory note of attestation work: 90 pages, 11 figures, 1 tables, 2 appendix, 27 sources.

NEURAL NETWORK, ARTIFICIAL IMMUNE SYSTEM, MULTILAYER PERSEPTRON, ANTIGEN, MULTIANTIBODY, LOCAL COMPUTER NETWORK

The purpose of the master's certification work is to develop an intelligent decision support system (IDSS) using neural network technology to build a decision-making model and an immune approach to adjust the parameters and structure of the neural network model. It focuses on improving the quality of the IDSS by creating a decision-making model and the evolution of its structure and parameters under conditions of uncertainty of both the external environment and the properties of the object of decision-making. The purpose of the master's certification work is to develop an intelligent classifier based on neural networks for data analysis and classification.

Experimental studies of the neural network model with immune tuning for decision-making on the creation and analysis of a local area network (LAN), which showed that to learn and predict different solutions when choosing certain parameters of the LAN, it is advisable to use neural networks with immune learning.

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерної інженерії та управління _____

Кафедра _____ Комп'ютерних інтелектуальних технологій та систем _____

АНОТАЦІЯ
КВАЛІФІКАЦІЙНОЇ РОБОТИ
рівень вищої освіти другий (магістерський)

Інтелектуальна система підтримки прийняття рішень
на основі нейронної мережі з імунним навчанням

Виконав:

студент 2 курсу, групи КІТм-20-1

Балим С.В.

Спеціальність 123 Комп'ютерна інженерія

Тип програми освітньо-професійна

Освітня програма Комп'ютерні

інтелектуальні технології

Керівник проф. Корабльов М.М.

2021 р.

Актуальність теми дослідження. Одним із ключових напрямків розвитку інформатики є інтелектуальні комп'ютерні технології, використання яких для створення інтелектуальних систем підтримки прийняття рішень (ІСППР) знаходить широке застосування. Існує широке коло складних важко формалізованих завдань, вирішення яких без використання штучних нейронних мереж (ШНМ) неможливо або складно піддається реалізації. Методи і технології, що використовуються в ІСППР, мають певні обмеження, які обумовлені багатьма факторами.

Незважаючи на дослідження, які проводяться в цій області, важливим являється ще розв'язання задач по розробці методів, моделей та алгоритмів функціонування ІСППР, які б враховували інтеграцію різних інтелектуальних технологій і можливості їх реалізації в тій чи іншій практичній області. Тому створення нейромережових моделей з реалізацією в них різних технологій навчання, адаптованих до особливостей конкретного проблемного середовища, являється актуальною задачею.

Об'єктом дослідження є процеси побудови систем підтримки прийняття рішень у реальному часі.

Предметом дослідження є методи і моделі побудови інтелектуальних систем підтримки прийняття рішень на основі нейромережевого та імунного підходів.

Дослідження ґрунтуються на аналізі підходів до розв'язання погано формалізованих задач, які характеризуються певними наборами ознак, таких як неповнота вхідних даних, обчислювальна складність, неточність і неоднорідність тощо, які призводять до того, що вони не мають точного рішення. Для їх розв'язання необхідно застосовувати наближені методи, які засновані на використанні інтелектуальних технологій обробки інформації, а саме штучних нейронних мереж, нечіткої логіки, експертних систем, штучних імунних систем (ШИС), генетичних алгоритмів та їх гібридів.

Метою магістерської атестаційної роботи є розробка нейромережевої моделі інтелектуальної системи підтримки прийняття рішень, яка навчається

і адаптується на основі використання штучних імунних систем, що дозволяє підвищити ефективність прийняття рішень в умовах невизначеності.

У першому розділі проведено аналіз підходів до побудови ІСППР, згідно якого розглянуті проблеми побудови ІСППР в умовах невизначеності. Розглянуті методи розв'язання погано формалізованих задач в умовах невизначеності, а саме метод логічного висновку, метод експертного оцінювання, методи нечіткої логіки, нейромережевий підхід. При використанні вказаних підходів для розв'язання погано формалізованих задач однією з основних є задача формування бази знань, яка орієнтована на конкретну предметну область, наприклад для проектування комп'ютерної мережі, і не завжди може бути розв'язана. Вказано на доцільність використання нейромережевої технології для створення ІСППР.

Зроблена постановка задач дослідження, згідно якої передбачається розробка ІСППР, орієнтованої на проектування комп'ютерних мереж, на основі нейромережевих і еволюційних технологій, а саме штучних імунних систем, яка забезпечує адаптивність і гнучкість системи, дозволяє впроваджувати сучасні методи і засоби обробки інформації, розширює сферу застосування, дозволяє прогнозувати, аналізувати та оцінювати отримані проєктні рішення.

У другому розділі розглянуті питання вибору нейронної мережі для використання в задачі підтримки прийняття рішень. Розглянуті особливості формування моделей нейронних мереж (НМ). Зазначено, що особливо складними задачами є розробка методів формалізованого формування топології НМ, формування навчальних вибірок, які повинні бути представницькими, розробка ефективних алгоритмів навчання НМ. Все це разом забезпечує створення НМ із заданими властивостями.

При вирішенні конкретних завдань синтез НМ є складною задачею і визначається наступними критеріями: точність розв'язання, час розпізнавання і кількість помилок розпізнавання час навчання, тощо. При синтезі нейронної мережі необхідно вибрати: тип мережі та її архітектуру

(топологію), алгоритм навчання а також інші параметри, які впливають на значення критерію її ефективності. Результатом синтезу повинна бути сформована така нейронна мережа, яка має задані властивості і дозволяє розв'язувати поставлену задачу.

Зазначені основні проблеми синтезу НМ, яким є наступні:

- 1) не існує формальних методів вибору типу НМ;
- 2) недостатньо розроблені питання, які пов'язаних з автоматичною побудовою топології НМ, що не дозволяє створювати НМ мінімальної складності для багатьох практичних задач;
- 3) при навчанні НМ необхідне обґрунтування методу оптимізації, який обрано, що може призвести до великих помилок прогнозу.

Тому НМ, які створюються, не завжди відповідають вимогам, які ставляться перед розробниками.

Проведено аналіз питання вибору топології НМ, яка визначає складність її проектування. Складність топології НМ визначається як загальним числом нейронів мережі, так і кількістю зв'язків між ними. При виборі топології НМ ставиться завдання підібрати такі параметри мережі, щоб при мінімальній складності мережі помилка узагальнення залишалася на прийнятному рівні.

В роботі в якості моделі НМ, яка використовується для створення ІСППР, використовується багатошаровий персептрон, який найбільш широко застосовується на практиці. Для багатошарових нейронних мереж завдання мінімізація числа нейронів і числа шарів (завдання оптимізації топології) може бути поставлене або в плані зменшення надмірності числа нейронів, або шляхом введення обмежень на число нейронів. Метою даної роботи є розробка ефективного методу настройки і адаптації НМ, який враховує особливості конкретної задачі.

У третьому розділі розроблені моделі навчання та адаптації НМ. Розглянуто вплив алгоритму навчання на ефективність функціонування НМ, зокрема багатошарової НМ. Відомо, що навчання НМ ґрунтується на

мінімізації деякої функції, значення якої показує відхилення результатів від ідеально необхідних, що видає мережа на даній навчальній вибірці. Найбільш широко розповсюдженим алгоритмом навчання багат шарової НМ (БНМ) без зворотного зв'язку являється алгоритм зворотного поширення помилки Back Propagation (BP).

Розглянуті основні проблеми, які пов'язані з використанням алгоритму BP у процедурі навчання НМ. Негативними факторами, які мають вплив на алгоритм навчання BP, є такі:

1. Повільна збіжність алгоритму навчання.
2. Блокування мережі.
3. Проблема перенавчання НМ.
4. Проблема виходу з локального мінімуму.

Тому з метою підвищення ефективності навчання НМ доцільним є застосування еволюційних методів, зокрема імунного підходу. Ці методи дозволяють досліджувати цілком весь простір множини рішень і уникають можливості «застрягання» в області локального екстремуму. В роботі пропонується виконувати навчання та адаптацію нейронної мережі з використанням імунного підходу.

При використанні імунного підходу для навчання НМ основною ідеєю є представлення розв'язуваної задачі у вигляді антигену, а можливі її розв'язки – у вигляді антитіл. В якості антигенів розв'язуваної задачі може виступати навчальна вибірка про вхідні і вихідні змінні. В якості антитіл будемо використовувати вектори параметрів, що настроюються. В одному антитілі будемо кодувати всі параметри НМ.

Задачу навчання НМ можна розглядати як задачу мінімізації цільової функції. Для розв'язання задачі мінімізації цільової функції будемо використовувати модель кодування параметрів, які настроюються, у вигляді адаптивного структурованого мультиантитіла (рис. 3.2). При цьому мультиантитіло складається з двох частин, і кожна частина може оброблятися незалежно одна від одної. В першій частині мультиантитіла

закодовані всі коефіцієнти функцій активації, всі вагові коефіцієнти нейронів, а також всі значення зсувів. У другій частині мультиантитіла закодовані всі коефіцієнти, а також зміщення вихідного шару НМ.

Для побудови обчислювальної моделі оптимізації використовуються наступні принципи імунного підходу: клональний відбір та мережева взаємодія. Запропоновано імунний алгоритм навчання НМ, який виконує певну послідовність кроків.

Проведені експериментальні дослідження нейромережевої моделі з імунною настройкою для прийняття рішень по створенню та аналізу локальної комп'ютерної мережі (ЛКМ). Попередній аналіз ЛКМ дозволив визначити її основні вхідні та вихідні параметри. Задача синтезу ЛКМ була розбита умовно на три паралельні задачі, кожна з яких повинна вирішувати проблему по одному з трьох вихідних параметрів. Для кожної зі створюваних ЛКМ були організовані відповідні навчальні вибірки, які містили не менше 50 варіантів. Проведені дослідження показали, що доцільно використовувати багат шарові нейронні мережі персептронного типу з імунним навчанням для прогнозування різних варіантів рішень при виборі тих чи інших параметрів ЛКМ, при цьому спостерігається висока надійність і стійкість отриманих результатів.

Ключові слова: нейронна мережа, штучна імунна система, багат шаровий персептрон, антиген, мультиантитіло, локальна обчислювальна мережа

Балим С.В., Гніденко В.А. Система підтримки прийняття рішень на основі мультиагентного підходу // 25-й Міжнародний молодіжний форум «Радіоелектроніка та молодь у XXI столітті». Зб. Матеріалів форуму. Т. 5. – Харків: ХНУРЕ. 2021. С. 209-210.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ	14
ВСТУП	15
1 АНАЛІЗ ПІДХОДІВ ДО ПОБУДОВИ ІНТЕЛЕКТУАЛЬНИХ СИСТЕМ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ	17
1.1 Проблеми побудови ІСППР в умовах невизначеності.....	17
1.2 Підходи до розв’язання погано формалізованих задач.....	19
1.2.1 Характеристика погано формалізованих задач.....	19
1.2.2 Методи розв’язання задач в умовах невизначеності.....	21
1.2.3 Нейромережевий підхід до розв’язання погано формалізованих задач.....	26
1.2.4 Використання апарату нечіткої логіки в ІСППР	29
1.2.5 Проблеми побудови гібридних моделей	32
1.3 Постановка завдання дослідження.....	35
2.1 Особливості формування моделей нейронних мереж.....	38
2.2 Методи обробки інформації для формування навчальних вибірок.....	39
2.1 Вибір типу нейронної мережі	42
2.2 Проблеми формування топології нейронної мережі	50
3.1 Вплив алгоритму навчання на ефективність функціонування нейронної мережі	57
3.2 Навчання та адаптація нейронної мережі з використанням імуного підходу	65
3.3 Експериментальні дослідження нейромережевої моделі з імуною настройкою для прийняття рішень.....	70
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ	77
ДОДАТОК А.....	80
ДОДАТОК Б	88

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ
І ТЕРМІНІВ

ІСППР – інтелектуальна система підтримки прийняття рішень

ШНМ – штучна нейронна мережа

ШІС – штучна імунна система

ЛОМ – локальна обчислювальна мережа

ОПР – особа, що приймає рішення

БНМ – багатошарова нейронна мережа

НМ – нейронна мережа

ОС – операційна система

СШІ – системи штучного інтелекту

СЗЗ – системи засновані на знаннях

СУ – система управління

ЕС – експертна система

ВР – Back Propagation

ВСТУП

Сьогодні одним з ключових напрямків розвитку інформатики є інтелектуальні комп'ютерні технології, використання яких для створення інтелектуальних систем підтримки прийняття рішень (ІСППР) знаходить широке застосування. Існує широке коло складних важко формалізованих завдань, таких як автоматизоване проектування, робототехніка, управління, інформаційний моніторинг, діагностика тощо, вирішення яких без використання штучних нейронних мереж (ШНМ) неможливо або складно піддається реалізації. Крім того, в реальних умовах такі завдання характеризуються певними наборами ознак, таких як неповнота вхідних даних, обчислювальна складність, неточність і неоднорідність тощо, які призводять до того, що вони не мають точного рішення. Тому для їх вирішення необхідно застосовувати наближені методи, які засновані на використанні інтелектуальних технологій обробки інформації, а саме штучних нейронних мереж, нечіткої логіки, експертних систем, штучних імунних систем (ШІС), генетичних алгоритмів та їх гібридів.

Методи і технології, що використовуються в ІСППР, мають певні обмеження, які обумовлені багатьма факторами, основними з яких є невизначеність умов, необхідність обробки неповної і неточної вхідної інформації, складність інтерпретації результатів, проблеми навчання і настроювання побудованих моделей до задачі, що розв'язується, трудомісткість обчислень, які погано відображають реальні процеси і об'єкти надходження даних для обробки з різних джерел тощо.

Незважаючи на дослідження, які проводяться в цій області, важливим являється ще розв'язання задач по розробці методів, моделей та алгоритмів функціонування ІСППР, які б враховували інтеграцію різних інтелектуальних технологій і можливості їх реалізації в тій чи іншій

практичній області. Таким чином, створення нейромережових моделей з реалізацією в них різних технологій навчання, адаптованих до особливостей конкретного проблемного середовища, являється актуальною задачею.

Використання нейромережових технологій дає можливість отримати якісно новий рівень вивчення процесів в різних за призначенням системах та об'єктах. Нейронні мережі не використовують правила виведення, вони навчаються це робити на початкових вибірках для вирішення різних завдань з необхідною точністю.

Метою магістерської кваліфікаційної роботи є розробка гібридних методів і моделей інтелектуальної обробки інформації в СППР на основі використання ШНМ, навчання яких виконується за допомогою ШС. Це дозволить розширити клас задач, які розв'язуються за допомогою ІСППР, та підвищити ефективність процесів інтелектуальної обробки інформації.

1 АНАЛІЗ ПІДХОДІВ ДО ПОБУДОВИ ІНТЕЛЕКТУАЛЬНИХ СИСТЕМ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ

1.1 Проблеми побудови ІСППР в умовах невизначеності

В магістерській кваліфікаційній роботі розглядається створення інтелектуальних систем підтримки прийняття рішень (ІСППР), які широко використовуються для розв'язання погано формалізованих задач, якими є задачі класифікації, кластеризації, діагностики, управління, прогнозування, автоматизація проектування тощо в умовах невизначеності. Основними рисами таких задач є такі:

1. Неможливість отримати точне рішення, так як внаслідок високої обчислювальної складності реалізації алгоритму їх розв'язання, навіть на комп'ютерах з високою швидкістю, він не може бути виконаний за необхідний час [1, 11].

2. Вхідні дані про розв'язувану задачу та знання про її предметну область як правило є неповними, неоднозначними, суперечливими та мають суб'єктивний характер. Тому для розв'язання таких задач можуть бути застосовані наближені методи, які використовують спеціально розроблені методики, нечітку логіку, емпіричні дані, експертне оцінювання, еволюційні підходи, нейромережеві технології і таке інше.

Однією з основних проблем при розв'язанні таких задач, наприклад, в управлінні, проектуванні та аналізі різних систем тощо, є проблема побудови математичної моделі, яка буде адекватною досліджуваному об'єкту або предметній області. Крім того, методи побудови таких моделей визначаються характером завдань, які вирішуються, що впливає на достовірність опису об'єктів і процесів, які в них відбуваються. Виходячи з цього побудову тієї чи іншої моделі можна здійснювати тільки після детального аналізу конкретного завдання. При цьому для однієї і тієї ж задачі можливе

створення різних видів моделей [3].

Розглянемо це питання на прикладі розробки ІСППР при проектуванні та аналізі комп'ютерної мережі. Вирішення цього завдання вимагає ефективної обробки інформації, яка відображає в базах знань досвід і знання експертів, і дає можливість прогнозувати варіанти рішень, а також проводити їх аналіз та оцінку. Це дозволить особі, що приймає рішення (ОПР), більш обґрунтовано вибирати один із запропонованих варіантів рішень.

Слід зазначити, що проектування комп'ютерних мереж має специфіку баз знань. Вона охоплює різноманітні знання про об'єкт і його предметну область, знання про завдання проектування і знання про можливі обмеження, а також знання про ступінь його невизначеності. Для обробки таких знань при проектуванні комп'ютерних мереж допускається можливість їх математичного опису з використанням рівнянь або алгоритмів з урахуванням обмежень. Наприклад, для опису функціонування комп'ютерної мережі може бути використана теорія масового обслуговування як широко відомий математичний інструмент.

Знання про комп'ютерну мережу, що проектується, як правило є неповними і багатозначними і потребують урахування великої кількості його параметрів таких як топологія мережі, мережеві технології, що використовуються, протоколи обміну, методи доступу до середовища передачі даних, кількість абонентів мережі, мережеве обладнання, мережеві і клієнтське програмне забезпечення тощо. Крім того, при побудові моделі комп'ютерної мережі необхідно враховувати достовірність вихідних даних за умов невизначеності її функціонування, вплив параметрів мережі на її характеристики, де і як буде використовуватися комп'ютерна мережа, що розробляється, обсяг і повнота інформації про мережу, а також схеми руху інформаційних потоків в мережі [2, 5, 6, 7].

Ступінь невизначеності розробки комп'ютерної мережі визначається як складністю побудови самої моделі мережі, так і відсутністю чіткого уявлення про можливі рішення та їх взаємозв'язок, а також можливою якістю

евристик, які можуть бути використані при розробці, та іншими чинниками. Слід зазначити, що чим більше ступінь невизначеності отримання можливих рішень і критеріїв. За допомогою яких оцінюються ці рішення, тим важливішою є експертна оцінка, яка отримана від фахівця, яку він зробив на основі своїх знань, досвіду та інтуїції.

Таким чином, задача розробки і аналізу комп'ютерної мережі являє собою задачу, яка є погано формалізованою і потребує для її розв'язання використання інтегрованого підходу, який поєднує різні математичні та логічні методи дослідження, використовує нові методи подання знань, інтуїцію та досвід ОПР, а також дозволяє прогнозувати і оцінювати різні варіанти отриманих рішень.

В кваліфікаційній роботі передбачається розробка ІСППР, орієнтованої на проектування комп'ютерних мереж, на основі нейромережових і еволюційних технологій, яка забезпечує адаптивність і гнучкість системи, дозволяє впроваджувати сучасні методи і засоби обробки інформації, розширює сферу застосування, дозволяє прогнозувати, аналізувати та оцінювати отримані проектні рішення. Трансформація процесу розглянутого процесу в область обґрунтування і формалізації рішень дозволяє в цілому підвищити інтелектуальність і якість функціонування ІСППР.

1.2 Підходи до розв'язання погано формалізованих задач

1.2.1 Характеристика погано формалізованих задач

Розв'язання погано формалізованої задачі в умовах невизначеності можна розглядати як розв'язання наступної задачі: знайти найкраще рішення з мінімальними витратами. Це пов'язано з вибором з наявної множини рішень необхідного варіанту за умов, коли в наявності є інформація про стан зовнішнього середовища, критерії і правила пошуку та особливості ОПР. Процедура пошуку і отримання необхідного результату може бути

представлена послідовністю виконання наступних етапів [4]:

- 1) збирання та структуризація знань про об'єкт або предметну область, що досліджується;
- 2) побудова математичних моделей об'єктів або процесів управління, які повинні бути адекватними;
- 3) пошук і прогнозування можливих варіантів рішень;
- 4) проведення аналізу і оцінка отриманих рішень;
- 5) вибір необхідного рішення.
- 5) вибір рішення.

Задачі управління в залежності від ступеня невизначеності можна поділені на такі [11]:

- задачі, для яких можливе отримання об'єктивної оцінки результатів рішення або виконання порівняльної оцінки декількох рішень;
- задачі, для яких неможливе отримання об'єктивної оцінки результатів рішення, тоді її можна замінити експертною оцінкою, отриманої від фахівців досліджуваної предметної області.

Перший тип задач характеризується присутністю в них як кількісних, так і якісних залежностей між компонентами системи, при цьому якісних залежностей більше, ніж кількісних. Тому такі задачі відносяться до слабкоструктурованих і погано формалізованих. Другий тип задач відноситься до неструктурованих, в яких відсутні описи кількісних залежностей між компонентами системи, але разом з тим можливий лиш якісний опис системи. Тому в таких задачах необхідно використовувати експертні оцінки [5, 11].

Задача проектування комп'ютерних мереж належить до погано формалізованих, яка характеризується такими ознаками [7]:

- неточність, неповнота, неоднозначність в суперечливість вхідних даних і знань про об'єкт дослідження або предметну область;
- параметри об'єкта або предметної області можуть бути представлені як в якісній, так і в числовій формі;

- простр рішень має висока розмірність;
- розвиток об'єкту або предметної області має високу динамічність;
- цільова функція не завжди може бути точно сформульована і формалізована в визначених термінах.

Через недостатній рівень формалізації об'єкту або предметної області та великі обчислювальні витрати на їх реалізацію практично неможливо будувати для них формальні теорії і застосовувати відомі математичні методи та моделі. Крім того, необхідно враховувати досвід і інтуїцію експертів, які є суб'єктивними [11]. Слід зазначити, що такі задачі відносяться до класу NP-повних задач, вирішувати які неможливо класичними математичними методами. Тому при вирішенні погано формалізованих потрібно враховувати як якісні залежності, так і кількісні дані, а також досвід і інтуїцію експертів (фахівців).

1.2.2 Методи розв'язання задач в умовах невизначеності

Використання методів класичного штучного інтелекту для рішення складних завдань базувалося на застосуванні символічного підходу, який ґрунтувався на формальних логічних системах, які виконували операції над символами, і не застосовували моделювання людського інтелекту як в цілому, так і окремих його складових. Особливість розвитку формальних логічних систем була в тому, що вони імітували людське мислення, пов'язане тільки з розробкою інформації, а не процесом її обробки в цілому. Застосування символічного підходу в той час було обумовлено такими причинами:

- на основі заданої системи аксіом можна отримати необхідний результат;
- вважається адекватним природному процесу формалізації, який призводить до формальних міркувань;
- процедура міркувань доступна як для аналізу, так і для перевірки, не

залежить від проблемної області і будується на основі загальних правил;

- формальні міркування просто реалізуються на комп'ютері і можуть використовуватися для обчислень для отримання необхідних результатів.

В таких системах база знань є головним елементом. Існують інтелектуальні системи, які засновані на знаннях (СЗЗ) [9], в яких в базі знань використовується логічний висновок (продукційні правила). Ефективність їх використання в різних предметних областях залежить від якості закладених в них знань, важливим при цьому є придбання та подання знань в СЗЗ.

Можна використовувати різні методи вилучення знань у експертів для придбання та подання знань, таких як інтерв'ювання експертів, посередництво інженерів-когнітологів. Вони дозволяють отримати і представити експертні знання у зручному вигляді, зберігати отримані знання в компактному виді та перевіряти правила виведення. Але мають місце проблеми, які пов'язані з їх використанням [8-10, 11, 12-15]:

- багато часу необхідно для виявлення правил у експерта;
- може мати місце відсутність повноти і несуперечності бази знань, що створюється, а також можливий логічний висновок при наявності неповної бази [24]).

Для подолання цих недоліків необхідна розробка нових методів, моделей і мов представлення знань, підтримка інженерів-когнітологів при застосуванні нетрадиційних логік, моделювання невизначеності шляхом використання нечітких змінних в судженнях експертів тощо. База знань, яка представлена у вигляді продукції, може використовуватися як основа організації взаємодії баз даних для пошуку варіантів рішень. При цьому, формування продукційних правил в базі знань може здійснюватися на основі таблиць рішень.

Основними перевагами продукційних систем є такі:

- уявлення правил є просте і легке для розуміння;
- модифікації знань виконується легко;
- самостійні фрагменти знань, що виражають правил, є незалежними;

– можливість пояснення результатів виведення завдяки прозорості бази знань;

– існує велика кількість розроблених правил прямого і зворотного виводу.

Метод логічного висновку, який заснований на продукціях, можна легко використати для розв’язання простих і однорідних за властивостями задач. Але це може призвести до зменшення ефективності розв’язання задач, які можуть бути складними і різнорідними.

Основним засобом подання і представлення знань є числення предикатів першого порядку. Йому властиві такі якості:

- модульності знань;
- представлення знань в універсальному для формалізма вигляді;
- виведення, що засноване на методі резолюції, універсальний механізм

Слід зазначити, що резолюційному підходу властивий недолік, який пов’язаний з неможливістю протиріч в базі знань.

В теперішній час розроблено велику кількість методів представлення знань і створено велику кількість СЗЗ – експертних систем (ЕС) [9, 10, 13-16]. За способом автоматизованного отримання рішення погано формалізованих завдань ЕС класифікуються на дедуктивні та індуктивні.

Дедуктивний підхід характеризується однозначністю і достовірністю в рамках теорії, що використовується. Він дозволяє отримати інформацію із знань, що зберігаються в базі, а також знань, отриманих від експертів, які представлені у вигляді правил. Індуктивний підхід дозволяє вивести нову інформацію (правила), узагальнюючи або вивчаючи відому інформацію, яка отримана від експертів. Як правило, вона представлена або у вигляді прикладів, або у вигляді навчальної вибірки.

Індуктивний підхід відрізняється від дедуктивного підходу тим, що дедукція призводить до висновків про дійсність за умови, коли бази знань несуперечливі. При застосуванні індуктивних методів виведення отримують висновки, які підтверджують інформацію, за допомогою якої проводилося

навчання. Разом з тим, вони не повинні обов'язково бути вірними в реальній дійсності. Так задача отримання функціональної залежності характеристик об'єкта, що досліджується, від його параметрів на основі заданих прикладів є складною і може бути некоректною. Тому індуктивний метод є неоднозначним і потребує перевірки отриманих висновків з використанням тестових вибірок.

В теперішній час практично не використовується розробка і використання ЕС, що пов'язано з обмеженнями, які властиві технологіям розв'язання погано формалізованих завдань за допомогою ЕС:

1. За допомогою технології ЕС можна вирішувати обмежене число практичних завдань, рішення яких може бути сформульовано експертом набором продукційних правил [13]. Як правило, експерту складно формалізувати всі необхідні знання.

2. Процес отримання знань є дорогою, неформальною і тривалою процедурою, яка може не привести до бажаного результату [9].

3. В процесі функціонування ЕС слабо розроблені технології адаптації та автоматизації поповнення бази знань. Крім того, неможливе навчання ЕС, а база знань у багатьох випадках є набором правил конкретного експерта.

4. В ЕС ускладнена обробка неповних і неточних даних у зв'язку з символічним поданням знань.

5. При пошкодженні баз знань ЕС стає не надійною системою.

6. Коли виникають непередбачувані ситуації, ЕС найчастіше зазнає невдачі. Разом з тим, вона адекватно реагує тільки на ситуації, які передбачені розробником [3].

Підсумовуючи, можна зазначити, що основними недоліками розглянутих способів подання знань та ЕС, які побудованих на їх основі, є проблеми з отриманням знань від експертів та їх вузька спрямованість. Крім того, збільшується список ознак при розширенні предметної області та ускладнюється опис об'єкта і його поведінки, що потребує значних інформаційних ресурсів і значних витрат часу для функціонального

забезпечення і реорганізації бази знань.

Можна ввести класифікацію для обмеження списку ознак об'єкта, використовуючи яку можна отримати можливість визначати характеристики об'єктів, знаючи загальні властивості класу, до якого він відноситься. Використовуючи класифікацію замість набору продукцій, можна отримати цілісні враження про експертні знання і є звичною формою подання знань для ОПР. Широко використовуються прості методи класифікації, які засновані на пошуку можливих рішень [16, 17]. Але при цьому класифікація позбавляє об'єкт його ознак і індивідуальних властивостей.

Опис складних об'єктів на основі їх жорсткої класифікації зробив Л. Заде [5], який сформулював принцип несумісності, згідно якого зменшується можливість точного опису об'єкта при зростанні складності системи, а релевантність і точність інформації є несумісними та взаємно виключаючими характеристиками. Він ввів поняття нечіткої множини і нечіткої логіки, згідно з якими кожному елементу ставиться у відповідність міра належності даної нечіткої множини. Для вхідних нечітких множин міру належності до них може оцінювати людина на основі свого досвіду і своїх суб'єктивних уявлень.

Такий підхід є зручним при формалізації знань, але експерт може часто мати труднощі в оцінюванні функцій належності. Разом з тим цей підхід дає можливість створювати вихідні нечіткі множини, використовуючи вхідні системи автоматичного розпізнавання.

Разом з тим, міру належності можна отримати з роботи автоматичного пристрою, який здійснює класифікацію або кластеризацію, а не на основі суб'єктивної оцінки, аналогічній мірі Л. Заде. В цьому випадку в якості міри належності можна використати міру подібності об'єктів, в якості якої в рамках метричної теорії використовуються певні відстані (метрики) на множині об'єктів, наприклад, квадратичні, спеціальні, методи потенційних функцій тощо.

Використовуючи такі функції належності замість суб'єктивних оцінок

Л. Заде, можна пом'якшити класифікацію і кластеризацію об'єктів та визначити їх схожість за аналогією. Для фреймових, процедурних та інших способів опису об'єктів у вигляді семантичних мереж можливі способи подання знань можуть визначатися подібністю об'єктів, що схоже на міркування за аналогією. Але таке подання знань про об'єкти є складною проблемою. Якщо використовувати експертні оцінки, різні метрики тощо, то міра належності буде скалярною величиною, і тоді втрачається різноманіття властивостей об'єкта і його просторового уявлення.

Досягнення компромісу між збереження малих обсягів інформації і докладним описом об'єктів в них потребує іншої системи уявлення знань. При цьому важливо забезпечити єдність і сутність структури «ім'я – властивість» [16] при пошуку такого компромісу. Тобто, щоб швидко знайти властивості об'єкта при використанні імені, яким він описується, необхідно перейти на більш високий рівень опису, обмежуючись обсягами інформації, яка аналізується. Такого компромісу може досягти, використовуючи для подання та обробки знань штучні нейронні мережі.

1.2.3 Нейромережевий підхід до розв'язання погано формалізованих задач

В кінці ХХ-го сторіччя став розвиватися інший напрямок штучного інтелекту, який пов'язаний використання штучних нейронних мережах (ШНМ), що імітують людське мислення. Застосування ШНМ на тепер є ефективним засобом розв'язання погано формалізованих задач на основі індуктивного підходу. Розроблено велику кількість нейронних мереж (НМ), які використовуються для аналізу сигналів, класифікації, кластеризації, розпізнавання зображень, в управлінні виробництвом і робототехніці тощо. Широке застосування ШНМ в різних предметних областях пояснюється наступними перевагами [11]:

- можливістю отримання рішення задачі за умов, коли відповідні

математичні моделі або продукційні правила, що визначають алгоритм рішення, відсутні, шляхом заміни математичної моделі структурою НМ, відповідним обсягом інформації, який зосереджено в навчальній вибірці, та алгоритмом навчання мережі;

- можливістю адаптуватися при змінах в умовах функціонування, які не передбачені ситуаціями,;

- універсальністю рішень, що базується на збіжності алгоритму навчання для багатосарових НМ, яка дозволяє розв'язувати задачу апроксимації функцій;

- реалізацією довільних нелінійних залежностей в умовах відповідного настроювання функцій активації нейронів в різних прихованих шарах багатосарової НМ;

- можливістю введення неповних і нечітких вхідних даних;

- паралельністю обробки різнотипних даних;

можливістю обробляти з високою ефективністю різнотипні дані великої розмірності.

На основі проведених досліджень можна відзначити, що моделі ШНМ є більш точними і надійними для розв'язання задач класифікації, кластеризації та апроксимації функцій, ніж методи, що засновані на знаннях, а також методи, що засновані на деревах рішень. НМ можна розглядати як один з методів факторного аналізу і нелінійної регресії. Разом з тим, нейронна мережа може генерувати як статично достовірне, так і правдоподібне рішення задачі, використовуючи індуктивний вивід, а також може використовуватися при недостатній кількості емпіричних даних, які неохідні при статичних дослідженнях.

Для розв'язання погано формалізованих задач дуже ефективним [20] є використання нейромережевого підходу, оскільки експерт може структурувати проблему лиш до рівня «чорного ящика», при цьому можна визначати тільки необхідні вхідні і вихідні дані системи, що досліджується, а також підготувати необхідну навчальну вибірку. Після того як нейронна

мережа навчена і протестована, вона може генерувати варіанти рішень на основі нових вхідних даних, яких немає в навчальній вибірці [20-22].

Моделі систем, що засновані на знаннях, мають більш абстрактний рівень і вимагають використання спеціальних процедур отримання знань за участю когнітолога. При цьому експерт повинен вербалізувати свої знання і досвід про структури системи, що досліджується, а також про окремі елементи і закономірності їх функціонування. З цього погляду нейромережевий підхід є більш ефективним.

При використанні нейромережевих технологій для вирішення прикладних завдань однією з основних задач є задача формування бази знань, яка орієнтована на конкретну предметну область. При цьому вибір типу нейромережевої моделі та її топології можуть бути зробленими користувачем з набору відомих і стандартних. Разом з тим ця модель може не відповідати розв'язуваній задачі. Тому необхідно створювати нейронні модулі, які навчені на вирішення конкретного завдання.

При проектуванні комп'ютерної мережі можуть бути поставлені задачі вибору топології мережі, мережевої і клієнтської операційних систем, фізичного середовища обміну даних, тощо. Використовуючи нейронні модулі можна будувати складні модульні системи, які зберігають її властивості, що вирішує при поданні та обробки знань проблему єдності структури «ім'я - властивість».

При використанні нейромережевої технології важливим є її інтеграція з іншими інформаційними технологіями, що дає можливість створення гібридних моделей на основі принципів синергізму. Це дозволяє об'єднати переваги НМ, символічних підходів, нечітких множин, еволюційних обчислень та інших технологій і врахувати їх недоліки. Важливим є створення систем, що мають більш високу ефективністю в порівнянні з тим, коли при їх створенні використанні тільки одна технологія. Тому необхідно вести активні дослідження для створення гібридних моделей [26, 27].

1.2.4 Використання апарату нечіткої логіки в ІСППР

При наявності системної невизначеності, яка пов'язана з неточними, нечіткими і розпливчастими властивостями процесів, або, наприклад, за наявності ситуаційної, інформаційної і стратегічної невизначеностей, для яких неможливо коректно застосувати існуючі методи, можна користуватися підходами формального представлення якісних експертних оцінок для опису неточних, невизначених і ненадійних даних. Дослідженнями встановлено, що у мисленні людини фігурують не числа, а образи і слова, тому відповіді експертів при експертному опитуванні, тобто експертні оцінки, є якісними, що являють собою різні об'єкти нечислової природи, такі як ранжирування, градації якісних ознак, результати парних порівнянь, розбивки, нечіткі переваги, тощо.

Тоді якісні поняття представляються у вигляді інтервальних чисел або об'єктів багатозначних логік. В цьому випадку використовуються такі найбільш поширені підходи як нечітка логіка, яка ґрунтується на нечітких множинах, апарат інтервальних чисел, логіка антонімів тощо. Слід зазначити, що нечітка логіка та логіка антонімів, неперервнозначні чи багатозначні логіки оперують приблизними міркуваннями. Тобто, вони розширені від використання класичної Булевої логіки до обробки понять істинності між «повністю істинний» до «повністю хибний».

У задачах, що використовують інтервальні числа, коефіцієнти та невідомі постають як замкнені інтервали можливих значень, наприклад, $\tilde{c}_i = [c_i^l, c_i^r]$ та $\tilde{x}_i = [x_i^l, x_i^r]$. Такі задачі можна розв'язувати методом імовірнісного аналізу, коли інтервальне число розглядається як випадкова величина з рівномірним розподілом; або найчастіше вирішують «безпосередньо», користуючись теорією інтервальних чисел. Тоді інтервальну задачу на основі методу детермінації зводять до двох аналогічних задач, що визначають верхню та нижню границі вектора невідомих. Метод ґрунтується на теорії порівняння інтервальних чисел,

згідно якої порівняння таких чисел розглядається як порівняння їх відповідних границь – верхньої та нижньої.

Пропонується використання апарату нечіткої логіки та теорії нечітких множин для оперування як кількісними і якісними поняттями в реальних задачах, які розв'язуються з використанням ІСППР. Цей апарат є найкращим способом застосування для класу задач вибору варіантів і розподілу ресурсів, які можуть розглядатися.

Слід зазначити, що згідно публікацій нечітка логіка Л. Заде як за ступенем розробленості, так і за кількістю застосувань немає рівних у світі серед неперервнозначних логік. Л. Заде запропонував нечітку логіку і теорію нечітких множин, яка припускає, що вона оперує наближеними поняттями, що робить її подібною людським міркуванням. Функціонал істинності в нечіткій логіці може приймати значення з відрізка $[0,1]$.

Нехай X – область визначення змінної x . При цьому нечітка множина \tilde{A} належить області X і визначається функцією належності $\mu_{\tilde{A}} : X \rightarrow [0, 1]$. Значення функції належності $\mu_{\tilde{A}}(x)$ являє собою значення належності величини x нечіткій множині \tilde{A} , яка у загальному випадку може бути графічно представлена на рис. 1.1.




Рис. 1.1 – Графічне представлення нечіткої множини \tilde{A}

Нечітка множина \tilde{A} є звичайною множиною з $x \in X$, для якої $\mu_{\tilde{A}}(x) > 0$ в інтервалі $[a_l, a_r]$ і є носієм нечіткої множини \tilde{A} . Нечітка множина \tilde{A} є пустою, якщо $\forall x \in X \quad \mu_{\tilde{A}}(x) = 0$, а величину $\mu_{\tilde{A}}(a) = \sup_{x \in X} \mu_{\tilde{A}}(x)$ називають висотою нечіткої множини \tilde{A} . Нечітку множину \tilde{A} називають нормальною, якщо її висота дорівнює 1, тобто $\sup_{x \in X} \mu_{\tilde{A}}(x) = 1$, та називають субнормальною за умови $\sup_{x \in X} \mu_{\tilde{A}}(x) < 1$. Нечітку множину \tilde{A} називають унімодальною, якщо $\mu_{\tilde{A}}(x) = 1$ лише для одного $x \in X$. Елементи множини $x \in X$, для яких $\mu_{\tilde{A}}(x) = 0,5$ називають характерними точками переходу нечіткої множини \tilde{A} .

Нечіткі множини можуть описуватися ФН трикутного виду (рис. 1.2) та дзвоноподібного виду (рис. 1.3).




Рис. 1.2 – Графік функції належності трикутного виду




Рис. 1.3 – Графік функції належності дзвоноподібного виду

Але найбільш поширене застосування має трикутна симетрична ФН, графік якої в частному випадку може представляти собою рівнобедрений трикутник. Таке застосування трикутних симетричних ФН зобов'язане легкості їх сприйняття та простоті їх практичного застосування у обчислювальних алгоритмах при розв'язанні задач прийняття рішень.

$$\mu_{\tilde{A}}(x) = \begin{cases} (x - a_l)/(a - a_l), & a_l \leq x \leq a, \\ (x - a_r)/(a - a_r), & a \leq x \leq a_r, \\ 0, & \text{інакше.} \end{cases} \quad (1.1)$$

Трійка параметрів ФН $\tilde{A} = (a_l; a; a_r)$ має таке призначення: параметр a визначає максимально можливий ступінь належності: $\mu_{\tilde{A}}(a) = 1$, параметри a_l, a_r представляють собою ліву і праву границі нечіткої множини. Так, для точного значення числа a можна записати, що $\tilde{A} = (a; a; a)$.

Таким чином, використання теорії нечітких множин і нечіткої логіки являється ефективним засобом інтелектуальної обробки інформації.

1.2.5 Проблеми побудови гібридних моделей

Проаналізувавши такі інформаційні технології як технології нейронних мереж (НМ), нечітких множин і нечіткої логіки (НЛ), еволюційних алгоритмів (ЕА) слід зазначити, що вони добре розв'язують задачі, які пов'язані з обробкою неточної, неповної і недостовірної інформації. Використання нейронних мереж дозволяє узагальнювати різні дані, які надходять з різних джерел, а також навчатися і прогнозувати рішення. Використання еволюційних алгоритмів, які мають високі адаптаційні властивості, дозволяє у багатьох випадках знайти краще рішення. Використання апарату нечітких множин і нечіткої логіки дозволяє оперувати неточними, нечіткими і недостовірними даними.

Слід зазначити, що відомі методи досліджень систем і методи штучного інтелекту (ШІ) побудовані класичними засобами і не володіють багатьма можливостями. Для обробки достовірних даних доцільно використовувати класичні методи досліджень, а методи ШІ – для представлення знань в тому чи іншому середовищі. Методи ШІ дозволяють породжувати нові знання в умовах невизначеності та дефіциту знань, що розширює можливості інтелектуальних систем обробки інформації.

В залежності від особливостей розв'язуваних задач особою, що приймає рішення, залежить вибір технології обробки вхідної інформації. На вибір також впливає від числа кількісних і якісних параметрів, які описують задачу, а також рівень опрацьованості завдання. Важливим при цьому є визначеність умов, в яких застосовується кожна з розглянутих технологій, а також можливість розробки методів та алгоритмів, які дозволяють їх адаптувати до розв'язання конкретних задач в проблемній області. Тут найкращим рішенням може бути рішення, яке отримане за допомогою використання еволюційних підходів на всіх етапах пошуку оптимального рішення, наприклад, імунних алгоритмів. Це дозволяє в залежності від розв'язуваної задачі перейти від моделей уявлення і використання знань, в яких жорстк зв'язк, до моделей, в яких динамічно змінюється структур.

Наприклад, основою об'єднання в єдину систему нечітких систем і нейромережових технологій є функціональна еквівалентність між роботою нейронних мереж і висновком в нечітких системах.

Основні задачі, які найчастіше мають розв'язувати гібридні моделі, зводяться до наступних: задачі оптимізації; розпізнавання, класифікації багатокритеріального вибору; прогнозування; логічного висновку тощо. Спільне використання окремих компонент гібридних моделей при розв'язанні загальної задачі дозволяє посилити їх переваги та компенсувати їх недоліки, створюючи тим самим синергетичний ефект, а також вирішувати ряд проблем, присутніх в компонентах і пов'язаних з їх недоліками.

При створенні гібридних моделей слід брати до уваги такі важливі

фактори [26]:

- призначення системи;
- підходи до пошуку та аналізу альтернативних варіантів рішень;
- особливості їх реалізації.

Призначення систем визначається задачами, які вирішуються, наведеними вище. Підходи до пошуку і аналізу рішень залежать від типу вхідної інформації, що задана, яка може бути представлена в базах знань, базах даних, експертних базах даних тощо. Для визначення особливостей методів реалізації гібридних моделей виділити такі архітектури:

1. Комплексна архітектура, що складається з моделей, які взаємодіють між собою і виконують «свої» функції.

2. Архітектура, яка об'єднує моделі на окремих стадіях реалізації основних алгоритмів з урахуванням рівнів методів.

При побудові гібридних моделей першого типу слід досліджувати недоліки кожної з технологій і визначити шляхи усунення цих недоліків, враховуючи те, що внутрішня структура моделей буде незмінною. При побудові моделей другого типу необхідне більш глибоке дослідження алгоритмів функціонування кожної з них, щоб на основі більш прогресивних технологій визначити способи реалізації окремих функцій.

Слід зазначити, що більш дослідженими є моделі другого типу. Гібридизація нечітких систем з нейромережевими технологіями розглянута в [26], де наведені приклади нечітких систем нейромережових систем, які реалізують нечіткій висновок за допомогою нейронної мережі ANFIS (Adaptive Neuro-Fuzzy Inference System), а також приклади нейромережових нечітких мереж, в якій окремі нейрони є нечіткими.

До структурних ознак можна віднесемо такі:

- кількість шарів нейронної мережі;
- вид активаційної функції;
- тип нейронів;
- метод поширення інформації в нейронних мережах;

- алгоритм навчання;
- правила нечіткого виводу;
- спосіб фазифікації і дефазифікації;
- метод оцінки та інтерпретації результатів роботи мережі;
- метод реалізації операцій нечіткої логіки,
- вид еволюційних операторів, що використовуються для мінімізації цільової функції і т.п.

Використання вищезазначених ознак дозволяє при побудові гібридних моделей забезпечити в багатьох випадках налаштування та адаптацію до проблемно-предметного середовища нейрон-нечітких моделей.

Для вирішення погано формалізованих задач пропонується використовувати нейромережевий підхід в якості основного, Ефективність застосування якого може бути підвищена наступним чином:

- налаштування і навчання нейромережевої моделі на вирішувану задачу;
- використання базових гібридних моделей, які зв'язується з іншими інформаційними технологіями;
- використання вбудовуваних в структуру ієрархічних нейронних мереж знань. Які враховують особливості предметної області.

1.3 Постановка завдання дослідження

Структурна схема пропонованої ІСППР приведена на рис. 1.4. Її основою є база знань, в якій зберігаються знання про всі внутрішні зв'язки системи, загальні знання, які необхідні для розв'язання всіх задач прийняття рішень, всі прикладні знання, які описують предметну область, комплекси алгоритмів, правила на процес прийняття рішень і їх обмеження тощо. При цьому база знань формується, використовуючи інформацію з навчальної вибірки.

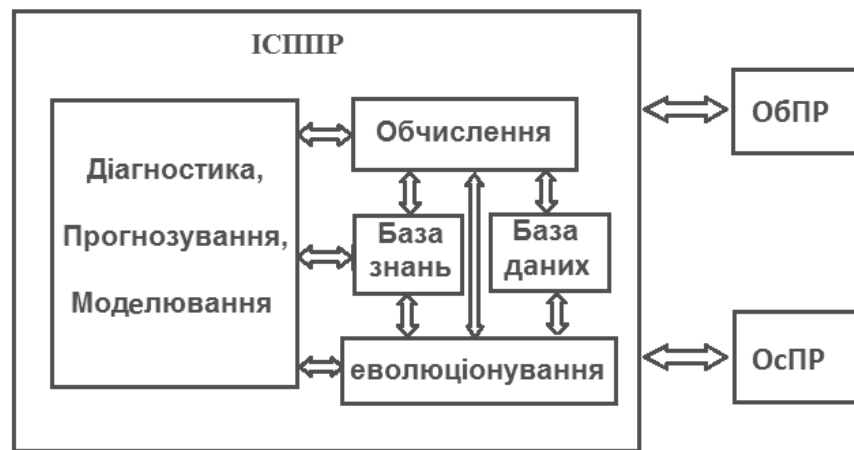


Рисунок 1.4 – Структурна схема ІСППР

Система повинна підтримувати двосторонній і безперервний зв'язок з ОПР. Робочу пам'ять системи, тобто її базу даних, утворюють оперативні дані про, а також дані, які необхідні для характеристики впливу на ОПР з боку системи. Важливим блоком ІСППР є блок обчислення, який забезпечує ідентифікацію ситуації, діалог з ОПР, логічний висновок рішень, взаємодію з базами даних і знань, пояснення і обґрунтування цих рішень. Він може використовувати традиційні засоби алгоритмізації програмування та моделювання.

Для адаптації до середовища функціонування та для додання системі здатності розвиватися в часі до складу ІСППР введений блок еволюціонування. За його допомогою можна коригувати як структуру, так і параметри нейронної мережі в залежності від зміни властивостей досліджуваного об'єкта та характеристик навколишнього середовища.

ІСППР повинна виконувати стандартні функції з прогнозування, технічної діагностики, документування, моделювання та відображення інформації. В ІСППР повинен здійснюватися моніторинг її параметрів і виявлення як можна ранніше несприятливих тенденцій і відхилень в її стані. В ІСППР здійснюється збір, зберігання і обробку оперативної інформації про її стан і стан ОПР а також про процеси, що в ній відбуваються. При відхиленні поточних значень контрольованих параметрів від встановлених

або робочих значень ця інформація необхідна для прийняття оперативних рішень.

Для досягнення поставленої мети в магістерській кваліфікаційній роботі розв'язуються наступні задачі:

1. Дослідження методів і алгоритмів прийняття рішень, орієнтованих на підвищення ефективності використання нейромережових і еволюційних методів і технологій в ІСППР.

2. Дослідження методів і алгоритмів побудови нейромережових моделей прийняття рішень з використанням нейронних модулів, які орієнтовані на врахування специфіки предметної області.

3. Дослідження методів і алгоритмів побудови гібридних моделей нейронних мереж і з заданими характеристиками, які навчаються на основі штучних імунних систем в залежності від специфіки їх застосування та умов пошуку рішення в рамках ІСППР з можливістю їх адаптації.

4. Проведення експериментальних досліджень розробленої нейромережової моделі прийняття рішень з імунним навчанням на практичних прикладах.

Для проведення теоретичних та прикладних досліджень використовувалися метод, теорії прийняття рішень, сучасного системного аналізу, нейроінформатики, теорії штучних імунних систем, об'єктно-орієнтованого програмування.

Результатом магістерської кваліфікаційної роботи є розробка інструментальних засобів, які підвищують ефективність процесів обробки інформації в ІСППР а також дозволяють їх використовувати в різних проблемних областях. Пропоновані методи і моделі можуть бути застосовані для розв'язання конкретних задач дослідження спеціалізованих комп'ютерних систем інтелектуальної обробки даних, а також для вибору компонентів комп'ютерних систем і мереж.

2 ВИБІР НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ВИКОРИСТАННЯ В ЗАДАЧІ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ

2.1 Особливості формування моделей нейронних мереж

В моделях нейронних мереж, на відміну від методів подання і накопичення знань, які застосовуються у звичайних системах, що засновані на знаннях, головними носіями знань є наперед навчені НМ на розв'язання певної задачі, з яких можна сформувати нейронні мережі ієрархічного типу. Це дозволяє розв'язувати складні задачі природним чином, які можна декомпозувати на більш прості, що розв'язуються окремими НМ. Кожна НМ може бути при цьому застосована багато раз як складовий елемент більш складної нейронної мережі.

Слід зазначити, що при використанні нейромережових моделей в ІСППР можна позбавитися вирішення проблеми немонотонності виведення, яка має місце в традиційних системах, заснованих на знаннях СЗЗ, коли необхідно враховувати інформацію, яка надійшла від ОБПР, або необхідно розширити простір параметрів, що досліджуються. Ці проблеми можна вирішити шляхом донавчання або перенавчання нейронних мереж, які складають структуру основної НМ.

Слід зазначити, що попередні настроювання окремих нейронних мереж і основної складної НМ на задачу, що розв'язується, є нетривіальною задачею (рис. 2.1). Для того, щоб підвищити ефективність функціонування нейромережової ІСППР, необхідно розробити набір методів і алгоритмів, які дозволять спростити процедуру підготовки НМ для розв'язання конкретних прикладних задач.

Проведений попередньо аналіз методів налаштування НМ на задачу, що розв'язується, показує, що особливо складними задачами є розробка методів формалізованого формування топології НМ, формування навчальних

вибірок, які повинні бути представницькими, розробка ефективних алгоритмів навчання НМ. Все все разом забезпечує створення НМ із заданими властивостями.

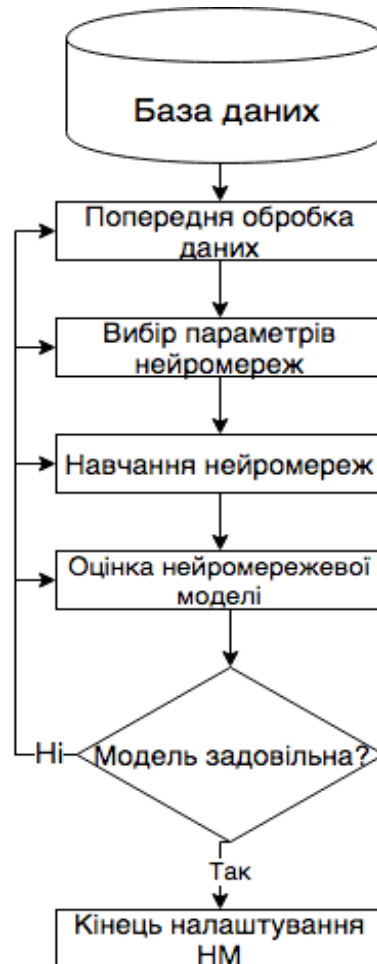


Рисунок 2.1 – Схема технології налаштування НМ на задачу, що вирішується

2.2 Методи обробки інформації для формування навчальних вибірок

Для формування і поповнення бази знань ІСППР необхідно їх знаходження і виявлення, перетворення у таке внутрішнє представлення, яке дозволяє їх перенесення в базу знань. Основні джерела інформації, які можна застосувати для формування баз знань, наведені на рис. 2.2. При цьому можуть використовуватися різні алгоритми обробки даних і знань, що можуть надходити з різних джерел і бути представленими в різних шкалах: лінгвістичних, числових, найменувань, інтервальних, порядку тощо.

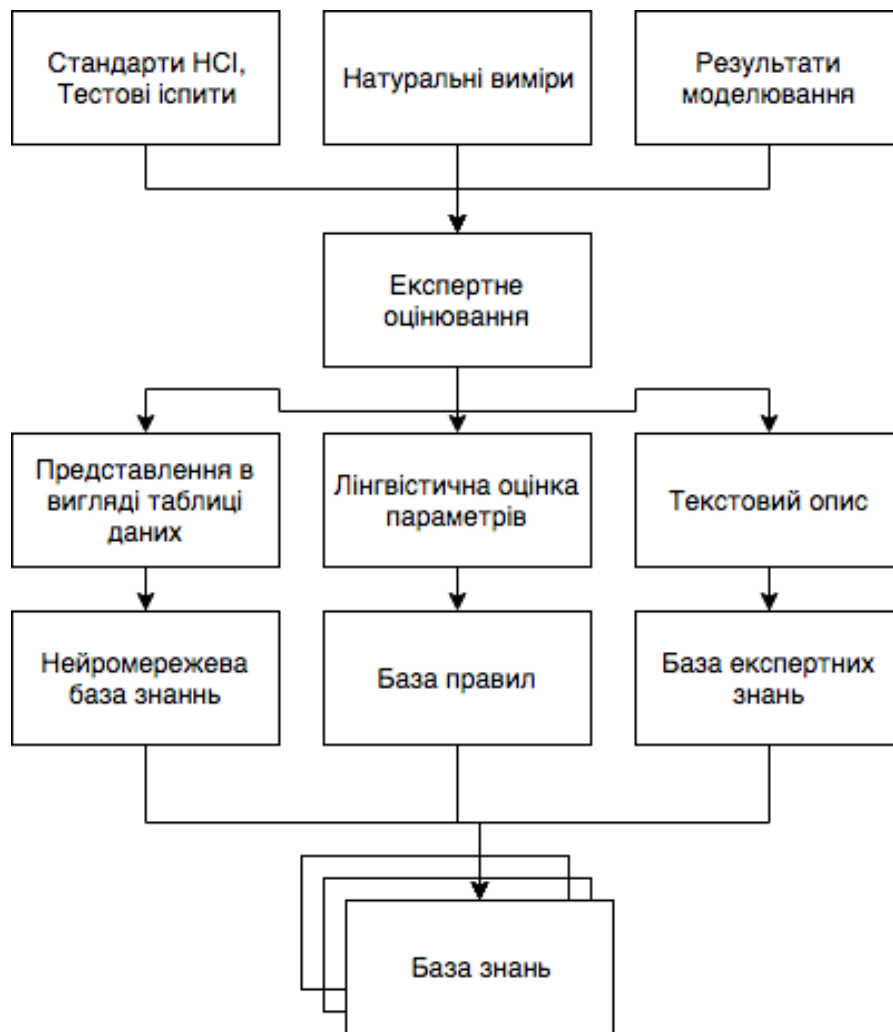


Рисунок 2.2 – Формування баз знань в ЕСПР

Формування баз знань може здійснюватися шляхом об'єднання багатьох інформаційних потоків, а саме:

- експериментальна інформація, яка отримується з натурального експерименту, або при моделюванні системи;
- фундаментальні знання про предметну область, що досліджується, які можуть бути представлені у форматі різних жорстких структур, таких, як закони, математичні залежності, стандарти, схеми, тощо;
- експертна інформація про кількісні та якісні характеристики конкретних об'єктів, що досліджуються в даній предметній області;
- експертна інформація мета-рівня, яка може визначати правила застосування фундаментальних знань в експертних висновках.

Як результат об'єктивної інтерпретації емпіричної інформації

формуються експертні знання (результати натурних експериментів або результати моделювання), які відображають різні приклади розв'язання реальних задач в даній предметній області та відіграють важливу роль при поданні та використанні експертних знань.

Розглянемо тепер питання вибору способів обробки і кодування інформації, які можуть надходити з різних джерел з метою формування навчальних вибірок. Методика обробки емпіричної інформації в системах, що засновані на знаннях, яка виконується за допомогою експертів, зводиться до наступних дій:

1) виділення множини характерних фрагментів емпіричної інформації, що отримана (наприклад, у вигляді натурних випробувань, у вигляді статичних характеристик результатів моделювання, або у вигляді зважених оцінок кількох експертів);

2) визначення множини інформативних параметрів, яка дозволяє виключити етапи кодування не суттєвих параметрів а також їх селекції при машинному навчанні;

3) вибір шкали, використання якої дозволить здійснити кодування вибраних параметрів;

4) кодування параметрів для формування бази знань, що дозволить створити вхідний навчальний набір прикладів.

Етапи 3 і 4 тісно пов'язані між собою і можуть розглядатися як одна процедура. Функціональна схема обробки емпіричної інформації, отриманої за допомогою експертів, представлена на рис. 2.3.

Основні проблеми, які пов'язані із застосуванням розглянутої методики, полягають в наступному:

– необхідність мати в наявності висококваліфікованих експертів, які здатні виробляти достовірні висновки;

– необхідні довготривалі додаткові дослідження, щоб оперувати лінгвістичними термами, які адекватно описують реальні об'єкти;

– в деяких випадках необхідно враховувати взаємозв'язки між

параметрами, тому що є можливість побудови неоднозначних логіко-лінгвістичних моделей.

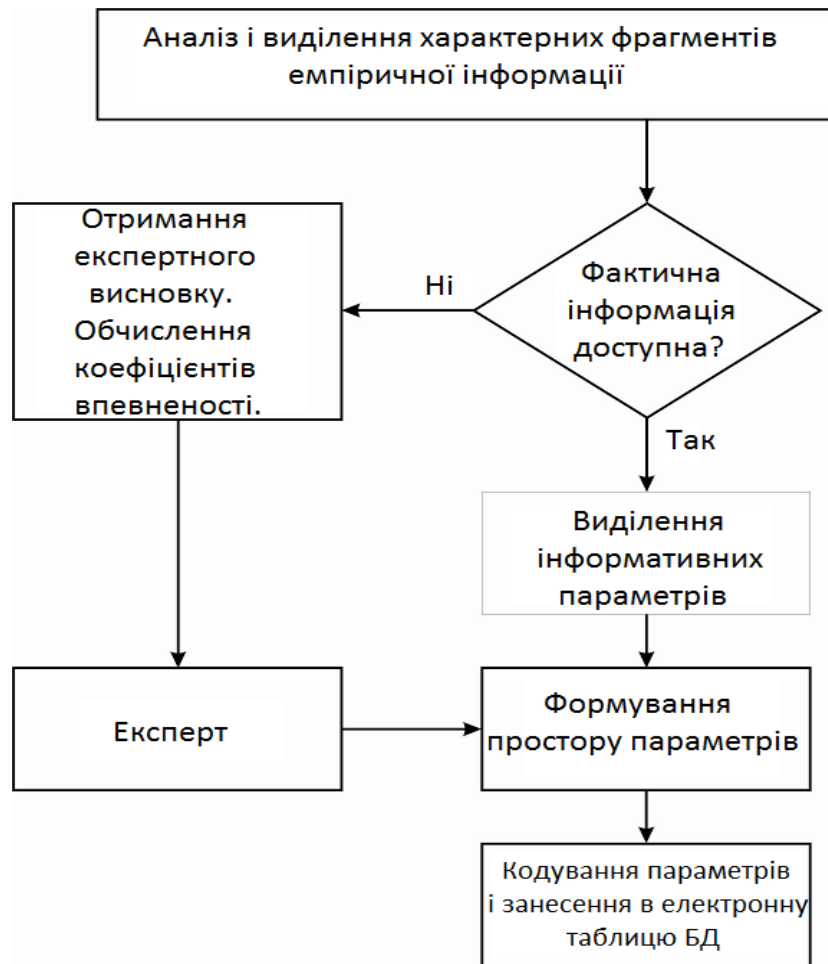


Рисунок 2.3 – Послідовність обробки емпіричної інформації

Все це вимагає урахування множини експертних описів та обліку багатьох додаткових чинників. При обробці емпіричної інформації допомога експерту може бути надана шляхом виділення інформативних параметрів, використовуючи для цього при формуванні баз даних спеціальні механізми відбору таких параметрів.

2.1 Вибір типу нейронної мережі

При вирішенні конкретних завдань синтез нейронної мережі є

складною задачею і визначається наступними критеріями: точність розв'язання, час розпізнавання і кількість помилок розпізнавання час навчання, тощо. При синтезі нейронної мережі необхідно вибрати: тип мережі та її архітектуру (топологію), алгоритм навчання а також інші параметри, які впливають на значення критерію її ефективності. Результатом синтезу повинна бути сформована така нейронна мережа, яка має задані властивості і дозволяє розв'язувати поставлену задачу.

Основними проблемами синтезу НМ є наступні:

1) не існує формальних методів вибору типу НМ;
 2) недостатньо розроблені питання, які пов'язаних з автоматичною побудовою топології НМ, що не дозволяє створювати НМ мінімальної складності для багатьох практичних задач;

3) при навчанні НМ необхідне обґрунтування методу оптимізації, який обрано, що може призвести до великих помилок прогнозу.

Тому НМ, які створюються, не завжди відповідають вимогам, які ставляться перед розробниками. Метою даної роботи є розробка ефективного методу настройки і адаптації НМ, який враховує особливості конкретної задачі.

Штучна нейронна мережа є мережею з кінцевим числом шарів, які складаються з однакових елементів, що називаються нейронами. Вони є аналогами природних нейронів, які мають різні типи зв'язків як між собою, так і між їх шарами.

Шар мережі складається з множини нейронів, які при наявності в мережі тільки послідовних зв'язків отримують вхідні сигнали в один і той же момент часу. При цьому перетворення нейроном вхідного сигналу в вихідний відбувається за кінцевий проміжок часу Δt , цей час перетворення є однаковим для всіх нейронів. Тоді перший шар НМ, який називається вхідним, налічує множину нейронів, які отримують вхідний сигнал в момент часу t_0 , другий шар налічує множину нейронів, які отримують вхідний

сигнал в момент $t_0 + \Delta t$.

Слід зазначити, що між нейронами різних шарів в багатошаровій нейронній мережі (БНМ) можуть бути зв'язку різних типів (рис. 2.4). У загальному випадку вихідний сигнал нейрона j -го шару є вхідним сигналом нейрону $(j+S)$ -го шару. При цьому можливі наступні типи зв'язків між нейронами:

- послідовні ($S = 1$);
- перехресні ($S > 1$);
- латеральні ($S = 0$);
- зворотні ($S < 1$).

У НМ з прямим послідовним зв'язком вихідний сигнал нейронів деякого шару є вхідним сигналом нейронів наступного за ним шару. Перехресні (або зв'язку через шар) встановлюються між нейронами деякого шару і наступних шарів (але не наступного шару). Для латеральних НМ характерне встановлення зв'язків між нейронами одного і того ж шару, Зворотні зв'язки встановлюються між нейронами деякого шару і попередніх йому шарів.

Одношаровими і багатошаровими нейронними мережами з послідовними зв'язками (в разі багатошарових НМ і НМ з перехресним зв'язками) являються одношарові і багатошарові перцептрони, НМ з латеральними зв'язками являються мережі Кохонена, НМ зі зворотними зв'язками являються мережі Хопфілда, Хеммінга, машина Больцмана [20-22].

Якщо в багатошаровій нейронній мережі є послідовні, зворотні, перехресні та латеральні зв'язки, то тоді вироджується поняття шару нейрона, тому що дуже складно і неможливо визначити ті нейрони, які отримують сигнал в один і той же момент.

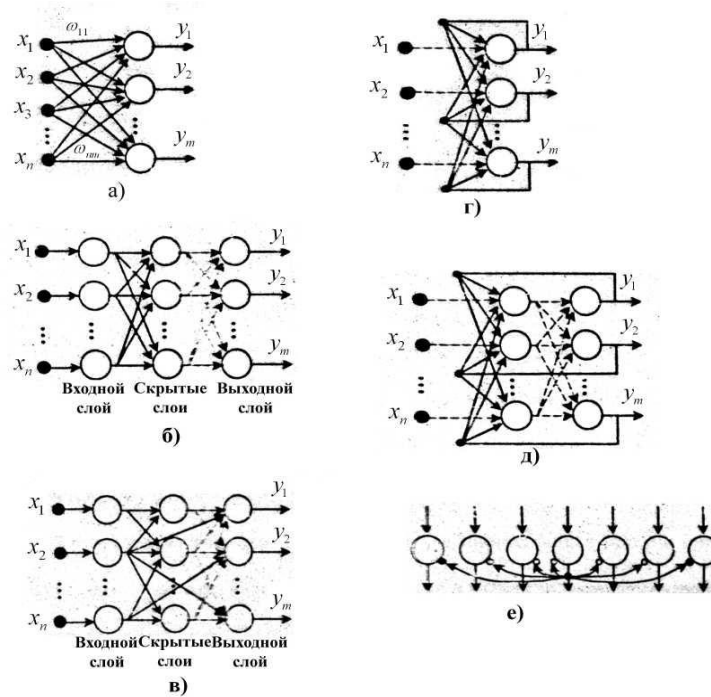


Рисунок 2.4 – Основні види зв'язків між нейронами різних шарів в НМ:

- а) одношарова мережа з прямим зв'язком;
- б) багатошарова мережа з прямим зв'язком;
- в) багатошарова мережа з перехресним зв'язком;
- г) багатошарова рекуррентна мережа (зі зворотним зв'язком);
- д) багатошарова рекуррентна мережа;
- е) мережу з латеральними зв'язками.

Слід зазначити, що на практиці крім основних типів зв'язків, розглянутих вище, використовуються також шаруваті і пірамідальні НМ, для яких характерна наявність різних типів нейронів і функцій активації.

Оскільки на сьогодні відсутні формалізовані методи вибору типу НМ, то необхідно використовувати накопичений досвід роботи розробників НМ з різними типами НМ. Як правило, сьогодні НМ використовуються в основному для розв'язання задач класифікації і розпізнавання, коли застосовується основний критерій оцінки НМ – мінімальна помилка узагальнення при заданій складності НМ, яка є заданим невід'ємним дійсним числом.

Загальне число зв'язків між усіма нейронами НМ визначає складність

в роботі НМ i , в свою чергу, визначає обчислювальну складність мережі як кількість операцій РС, яка необхідна для перетворення вхідного сигналу в вихідний. З урахуванням проведеного аналізу різних типів НМ і розв'язуваних ними задач в даній роботі можна вибрати наступні НМ: нейронні мережі без зворотних зв'язків, в яких є тільки послідовні, перехресні або латеральні зв'язки.

Ці типи мереж охоплюють широкий клас НМ, що дає можливість створювати комбіновані ефективні НМ, а також інтегрувати їх з іншими технологіями інтелектуальної обробки інформації.

Розглянемо основні характеристики НМ з послідовними зв'язками, які є найбільш важливими для використання в СППР.

1. Повнозв'язні послідовні нейронні мережі.

При наявності послідовних зв'язків у НМ вихідний сигнал поточного шару є вхідним сигналом наступного шару. При цьому можуть бути повними послідовні зв'язки між нейронами, коли кожен нейрон j -го шару мережі пов'язаний з усіма нейронами $(j + 1)$ -го шару. Математична модель j -го нейрона в шарі можна описати так:

$$y_{jl} = f_{jl} \left(w_{0jl} + \sum_{l=1}^{L_{l-1}} w_{ijl} y_{jl-1} \right) \quad (2.1)$$

де y_{jl} – вихідний сигнал j -го нейрона j -го шару;

f_{jl} – функція активації;

w_{0jl} – порогове значення;

L_l – кількість нейронів шару l ;

w_{ijl} – ваговий коефіцієнт;

y_{jl} – вихідний сигнал j -го нейрона $(l - 1)$ -го шару і одночасно вхідний сигнал для j -го нейрона l -го шару;

Вираз (2.1) можна використовувати для знаходження виходів всіх нейронів всіх шарів НМ; тоді $y_{i0} = x_i$, де x_i – i - компонента вхідного вектора. У випадку, коли всі нейрони мають одну і ту ж функцію активації,

то $f_{jl}(x) = f(x)$ для $\forall i, j = 1, 2, \dots, L$. Це говорить про те, що НМ - однорідна. В подальшому будемо розглядати тільки однорідні НМ. Зазначимо, що функції активації, які застосовуються в НМ, можуть бути різними: лінійними, граничними, монотонними, обмеженими, і т.д. [20].

Для однорідної тришарової НМ, в якій перший шар – вхідний, що сприймає вхідний вектор X з компонентами $x_j, j=1, 2, \dots, n$, де n – число компонент вектора, другий шар – схований шар L_1 , а третій шар – вихідний шар L_2 , математична модель для k -ого нейрона має вигляд:

$$y_k = f \left(w_{0k_2} + \sum_{i=1}^{L_2} w_{ki_2} \cdot f \left(w_{0i_1} + \sum_{j=1}^{L_1} w_{ji_1} x_j \right) \right), \quad (2.2)$$

де y_k – k -я компонента вихідного вектора;

w_{0i_1} – порогове значення i -го нейрона першого шару;

w_{0k_2} – порогове значення i -го нейрона другого шару;

w_{ji_1} – i -й ваговий коефіцієнт j -го нейрона першого шару;

w_{ij_2} – i -й ваговий коефіцієнт j -го нейрона другого шару;

f – функція активації;

L_1, L_2 – кількість нейронів в прихованому і вихідному шарі відповідно.

2. Модель нейронної мережі з перехресними зв'язками.

Модель НМ з перехресними зв'язками має зв'язки нейронів шару j з нейронами попередніх шарів. Тоді для моделі з повними перехресними зв'язками маємо наступний опис:

$$y_{jl} = f \left(w_{0jl} + \sum_{h=1}^{j-1} \sum_{i=1}^{L_1} w_{hji} y_{ih} \right), \quad (2.3)$$

де $w_{h\ j}$ – ваговий коефіцієнт між i -м нейроном h -го шару.

В (2.3) від попереднього шару послідовні зв'язки розглядаються як окремий випадок перехресних. Виконуючи обнулення деяких вагових коефіцієнтів w в (2.3), може бути отриманий варіант НМ з неповними перехресними зв'язками.

3. Нейронна мережа з латеральними зв'язками.

Нейронною мережею з латеральними зв'язками називається мережа, якщо будь-який k -й нейрон ($k = 1, \dots, L_j$) j -го шару (L_j - число нейронів в j -му шарі) приймає сигнал в якості вхідних від всіх нейронів j -го шару. Може бути випадок, коли нейрон включає самого себе, що еквівалентно наявності петлі на графі НС.

Вихід j -го нейрона в l -му шарі обраховується за формулою:

$$y_{jl} = f \left(w_{0jl} + \sum_{i=1} w_{0ji} y_{il-1} + \sum_{k=1} w_{0kj} y_{kl} \right), \quad (2.4)$$

де w – ваговий коефіцієнт латеральних зв'язків.

Для НМ з неповними латеральними зв'язками характерно, що вагові коефіцієнти в (2.4) дорівнюють нулю.

Таким чином, в залежності від виду міжнейронних зв'язків та функцій активації, які застосовуються, в практичних задачах можуть використовуватися різні математичні моделі нейронів.

Узагальнюючи, можна зазначити, що скалярний вихід нейрона Y і його n - вимірний вхід X пов'язані співвідношеннями [20-22]:

$$y = (net(X, W)), \quad net(X, W) = \sum_{i=1}^n w_i u_i(X), \quad (2.5)$$

де функція $net(X, W)$ – дискримінантна функція; кожна компонента якої $u_i(X)$ є функцією вхідного вектора X ;

$f(net)$ - функція активації.

Дискримінантна функція є скалярним добутком n - мірного вектора вагових коефіцієнтів на вектор U , значення якого впливає на властивості нейрона.

Дискримінантна функція $net(X, W)$ може бути відрізком багатовимірного ряду Тейлора ступеня l . Якщо ступінь ряду Тейлора $l = 1$, то відповідний нейрон називається нейроном першого порядку. В інших випадках мають місце нейрони вищих порядків. Тоді коефіцієнти розкладання відрізка багатовимірного ряду Тейлора можуть утворювати вектор вагових коефіцієнтів W , який впливає на дискримінантну функцію нейрона першого порядку і має вигляд:

$$net_1(X, W) = w_0 + \sum_{j=1}^n w_j x_j, \quad (2.6)$$

де $W = (w_0, w_1, \dots, w_n)$ – вектор вагових коефіцієнтів нейрона;

$U = (1, x_1, x_2, \dots, x_n)^T$ – розширений вектор входу нейрона;

x_j – j -ая компоненту n - мірного вхідного вектора X .

Для нейрона другого порядку дискримінантна функція описується виразом:

$$net_2(X, W) = w_0 + \sum_{j=1}^n w_j x_j + \sum_{j=1}^n \sum_{k=1}^j w_{jk} x_j x_k, \quad (2.7)$$

де $w_0, w_j, j = \overline{1, n}$, $w_{jk}, j = \overline{1, n}, k = \overline{1, j}$ – компоненти вектора U , для якого розширений вхідний вектор описується виразом:

$$U = (1, x_1, \dots, x_n, x_1^2, x_2 x_1, \dots, x_n^2)^T. \quad (2.8)$$

Зазначимо, що компоненти вектора U можуть бути більш складними за виразом функціями, ніж функції, що подані в (2.9). Вони створюють відрізок ряду Тейлора, який дозволяє утворювати різні НМ з різними математичними властивостями [20-22].

2.2 Проблеми формування топології нейронної мережі

Вибір топології НМ є найбільш важливою проблемою її синтезу, яка визначає складність проектування НМ. Відомо, що складність топології НМ визначається як загальним числом нейронів мережі, так і кількістю зв'язків між ними. Наприклад, оптимальна топологія для багатошарового перцептрона є така топологія, яка при заданій помилці узагальнення забезпечує як найменше число нейронів в кожному шарі, так і найменше число шарів НМ. Разом з тим, точне відновлення шуканої функції відображення $F: R \rightarrow Y$, де R - вхідний вектор НМ, Y – вихідний, НМ з малим числом нейронів буде недостатньо. Але НМ з великим числом нейронів дуже точно узагальнює приклади навчальної вибірки, тобто має місце ефект перенавчання, що знижує можливості прогнозування за її допомогою.

Для обчислення характеристики складності НМ введемо такі визначення. Під складністю S нейронної мережі як правило розуміють число, рівне сумарній кількості обчислювальних операцій, яке необхідне для обчислення вихідного вектора Y по відомому вхідному вектору R . Це число залежить від топології мережі, тобто від числа нейронів, прихованих шарів і зв'язків між ними.

При виборі топології НМ ставиться завдання підібрати такі параметри мережі, щоб при мінімальній складності мережі помилка узагальнення $E_{\text{обш}}$ залишалася на прийнятному рівні. Слід зазначити, що для найбільш використовуваних на практиці багатошарових нейронних мереж завдання мінімізація числа нейронів і числа шарів (завдання оптимізації топології)

може бути поставлене або в плані зменшення надмірності числа нейронів, або шляхом введення обмежень на число нейронів [20].

Разом з тим широко розглядаються два евристичних підходи до вибору топології НМ: скорочення нейронів мережі (деструктивний підхід), і поступове нарощування НМ (конструктивний підхід), починаючи з деякої мінімальної топології. Можуть також використовуватися статичні підходи або методи еволюційного пошуку.

При використанні статичних методів розв'язуються задачі зв'язку між собою таких параметрів мережі, як складність НМ, помилка навчання E_0 (training error), кількість прикладів в навчальній вибірці, помилка узагальнення $E_{\text{общ}}$ (generalization error), тощо. Метою статичного підходу є визначення взаємозв'язку між параметрами НМ з використанням статичних методів. Складність організації одношарового перцептрона $E_{\text{общ}}$, що визначається у [30], обмежена: $0\left(\frac{1}{h}\right) + 0\left(\frac{h}{N}\right) \log N$, де h – число нейронів внутрішнього шару перцептрона, N – число прикладів у навчальній вибірці. Щоб визначити достатність розміру НМ, необхідно порівняти оцінку константи Ліпшиця для функцій, що реалізують НС, і оцінку константи Ліпшиця, яка обчислена з апроксимуючої функції за заданою навчальною вибіркою.

Запропоновано метод, що оцінює $E_{\text{общ}}$, а також розроблено метод оцінки статичних характеристик вибірки, а саме інтегральних атрибутів, які обчислюються за навчальною вибіркою і дозволяють оцінювати характеристики апроксимуючої функції.

Недоліки підходу:

- 1) для кожної топології НС повинна будуватися модель залежності $E_{\text{общ}}$ від статичних характеристик вибірки;
- 2) методика побудови навчальної вибірки, згідно якої будується регресійна модель та оцінюється помилку $E_{\text{общ}}$, відсутня.

Разом з тим, статичний підхід представляється перспективним,

незважаючи на вказані недоліки, так як обчислювальна складність алгоритму формування топології НМ набагато менше, ніж в існуючих методах.

Якщо використовувати деструктивний підхід, то відбувається або погіршення вагових коефіцієнтів для різних шарів НМ, або видалення зв'язків між нейронами. Погіршення ваг є підмножиною методів регуляризації і може запобігати значному зростанню вагових коефіцієнтів. У функцію оцінки вводиться штрафний доданок (додатковий елемент), який певним чином дозволяє зменшуватися ваги. Як правило, штрафний доданок є сумою квадратів ваг, яка помножена на константу ослаблення [45]:

$$E = \frac{1}{P} \sum_{i=1}^P (d_i - y_i)^2 + \frac{\eta}{2} \sum_{i,j} w_{ij}^2(t), \quad (2.9)$$

де величина $\eta < 1$ вибирається експертом.

Штрафний член при зменшенні ваг змушує великі ваги до зменшення абсолютної величини:

$$w_{ij}(t+1) = (1 - \eta)w_{ij}(t), \quad (2.10)$$

де t – поточна інтеграція.

При введенні штрафу для виключення ваг [145] маємо:

$$E = \frac{1}{P} \sum_{i=1}^P (d_i - y_i)^2 + \frac{\eta}{2} \sum_{i,j} \frac{w_{ij}^2}{1 + w_{ij}^2}, \quad (2.11)$$

Згідно формули (2.23) малі вагові коефіцієнти в результаті підрахунку зменшуються швидше, ніж великі, а відповідні їм зв'язки між нейронами видаляються.

Недоліком деструктивного підходу є те, що використовуючи метод

зменшення, ускладнюється вибір константи η , що при вирішенні конкретної задачі потребує проведення великої кількості експериментів на НМ для визначення її конкретної величини.

При використанні конструктивного підходу основна ідея полягає в тому, що шляхом поступового додавання нейронів в початкову структуру структура НМ нарощується до тих пір, поки не будуть правильно розпізнаватися всі приклади навчальної вибірки («переможець забирає все» при використанні методу інтерпретації, при цьому експерт задає максимальну величину перевищення сигналу нейрона-переможця над усіма іншими сигналами нейронів вхідного шару). Згідно цього методу повинно бути задане максимальне число прихованих шарів і нейронів у цих шарах, а також параметри навчання.

Ідея алгоритму автоматичної побудови НМ полягає в послідовному додаванні нейронів в такий спосіб, щоб величина $E_{\text{общ}}$ зменшувалася на кожному кроці інтерпретації кожного разу, коли черговий нейрон, який доданий і навчений, то його вагові коефіцієнти зв'язків з іншими нейронами мережі стають непотрібними в наступних ітераціях.

Тоді кожен новий нейрон при подібному способі побудови буде зменшувати хоча б одну помилку попереднього нейрона, що може гарантувати збіжність алгоритму навчання. Основним недоліком такого підходу є можливість побудови такої топології НМ, яка може розділяти множини даних тільки два класи.

При використанні метода динамічного додавання вузлів у НМ не накладається ніяких істотних обмежень на спосіб її побудови, тобто, як додавати нові шари і нейрони в НМ, як вони повинні бути з'єднані з існуючими шарами і нейронами. Слід зазначити, що при додаванні нових шарів і нейронів при виконанні процедури навчання НМ обчислюється швидкодія зміни помилки, і при зменшенні швидкості зміни помилки настає нижче заданого порогу, то тоді в прихований шар додається новий нейрон. Але при цьому можуть виникати проблеми обчислювальної ефективності, які

пов'язані з необхідністю перенавчання НМ.

Метод каскадної кореляції, який запропонований Фальманом, використовує дві основні ідеї:

1) каскадна архітектура НМ, згідно якої в кожному шарі знаходиться тільки по одному нейрону, що є варіантом такої НМ, в якій нові нейрони додаються послідовно і потім після настройки не змінюються;

2) автоматичний вибір і настройка нового нейрона. Згідно цього метода до кожного нейрона приписується за певними правилами номер шару, яке є деяким числом. Нейрон, що доданий, з'єднуються зі всіма нейронами, які мають номер шару, менший на одиницю, ніж номер шару, у який додається нейрон.

З метою поліпшення роботи алгоритму можна використовувати декілька прийомів:

1) формувати пул, який представляє набір нейронів–кандидатів, які мають різні активаційні функції. При цьому вибирається такий нейрон, який забезпечує менше значення помилки $E_{\text{общ}}$;

2) так як ваги нейронів, що додаються для побудови топології НМ на попередньому кроці, не змінюються, то вони можуть бути збережені і використані на наступних кроках.

Переваги методів каскадної корекції, дослідження і модифікації яких проведені в роботах [40-41]. Перевагою методу є можливість використання в одній мережі різних типів нейронів із різною функцією активації а також автоматична побудова топології мережі. Недоліком методу є те, що він працює тільки з НМ, що мають каскадну структуру.

Використання еволюційних методів для формування топології мережі основане на застосуванні імунних або генетичних алгоритмів [33-37]. При цьому множина можливих топологій побудови НМ має ряд властивостей:

- множина допустимих топологій НМ не є числовою;
- недетермінованність процесу знаходження помилки $E_{\text{общ}}$, що може призвести до багатозначності та зашумленості функцій, які характеризують

оптимальність архітектури НМ;

- залежність між топологією і помилкою $E_{\text{общ}}$ як правило не може бути визначена у явному виді, оскільки вона визначається через рішення оптимізаційної задачі навчання НМ.

Таким чином, наведений вище аналіз підходів для формування топології і адаптації параметрів і структури НМ показав, що, для цих цілей необхідно застосовувати еволюційний підхід, а саме імунний або генетичний підхід.

Розглянемо основні вимоги, яким необхідно відповідати, щоб побудувати нейромережеву модель СППР.

1. *Тип модулів.* Інструментальні засоби, які використовуються для реалізації функцій, що виконуються, для аналізу і класифікації вихідних даних. Вони повинні мати у своєму розпорядженні необхідний набір алгоритмів для реалізації відповідного правила, які враховують як неоднорідність, так і нелінійність залежностей вхідних даних. Якщо заздалегідь відома кількість класів, то слід застосовувати НМ типу багатошарового персептронну, яку навчати за допомогою алгоритму з учителем. Якщо заздалегідь невідома кількість класів, то слід використовувати один з алгоритмів кластеризації, наприклад, мережу Кохонена, яка є самоорганізованою. При наявності малих навчальних вибірок також доцільно використовувати мережу Кохонена. При переважанні різних НЕ-факторів у вхідній інформації доцільно використовувати різні гібридні моделі, наприклад, нечіткі нейронні мережі.

2. *Модульна архітектура НМ.* Якщо розробляти складну багатомодульну НМ, то в створювану архітектуру нової мережі слід передбачити можливість включення інших модулів, які вже раніше навчені, або групи нових модулів, які треба навчити за допомогою спеціальних алгоритмів навчання таких мереж.

3. *Оптимізація.* Важливим при цьому є забезпечення можливості оптимізації архітектури НМ, а саме вибір типу нейронів, вибір функцій

активації, вибір кількості шарів НМ і нейронів у кожному шарі, аналіз можливості досягнення згідно зробленого вибору глобального (або допустимого) мінімуму функції помилок, а також оцінки важливості кожного компонента НМ з точки зору стійкості побудованої схеми. Розв'язання цих задач можливе при застосуванні еволюційних підходів і алгоритмів.

4. *Координація процесів навчання в НМ.* Для кожної створюваної НМ необхідно передбачити три основні функції: функція навчання (Teach), функція тестування (Test) і функції виконання (Run). Слід зазначити, що більш ефективно навчання НМ можна отримати при паралельному виконанні процедур Teach, Test і Run з урахуванням функцій, що ними виконуються. Для реалізації цього можна застосувати клієнт-серверну технологію навчання і роботи нейронних мереж, а в якості механізму координації їх взаємодії використати черговість і послідовність виконання зазначених для них функцій.

3 РОЗРОБКА МОДЕЛІ НАВЧАННЯ ТА АДАПТАЦІЇ НЕЙРОННОЇ МЕРЕЖІ

3.1 Вплив алгоритму навчання на ефективність функціонування нейронної мережі

Відомо, що навчання НМ ґрунтується на мінімізації деякої функції, значення якої показує відхилення результатів від ідеально необхідних, що видає мережа на даній навчальній вибірці. Тому необхідно обрати відповідну оцінку, в якості якої можна взяти середню квадратичну помилку, що буде помилкою навчання E_0 або MSE (Mean Squared Error). Вона визначається як середня сума квадратів різниць між бажаною величиною виходу d_i і реально отриманою величиною значення y_i на виході мережі для кожного прикладу i :

$$E_0 = \frac{1}{P} \sum_{i=1}^P (d_i - y_i)^2, \quad (3.1)$$

де P – кількість прикладів у навчальній вибірці.

В тих випадках, коли вихідні сигнали мережі повинні із однаковою і заданою для всіх сигналів точністю ε збігатися з відомими векторами, використовується оцінка E_0 , де точність ε може визначатися як рівень надійності [21].

Для оцінки рівня надійності навчання можна використати модифікацію формули (3.1):

$$E = \frac{1}{P} \sum_{i=1}^P \left(\frac{d_i - y_i}{\varepsilon} \right)^2, \quad (3.2)$$

де точність ε може мати різний діапазон зміни для способів інтерпретації, що використовуються: $0 < \varepsilon \leq 1$ – для знакової інтерпретації; $0 < \varepsilon \leq 2$ – для правила «переможець забирає все»; $0 < \varepsilon \leq 2 / (n-1)$ – для порядкової інтерпретації, де n – цезорозмірність вектора вхідних сигналів [22].

З метою забезпечення надійної роботи мережі вводиться рівень надійності. Критерій надійності можна сформулювати так: робота мережі вважається надійною, якщо при зміні вихідних сигналів мережі на величину, меншу як ε , інтерпретація відповідей мережі не буде змінюватися. Для забезпечення прискореного навчання мережі можна використати цей факт, а саме, при обчисленні оцінки за формулою (3.2) доцільно використовувати тільки такі вихідні сигнали, які відповідають множині правильних відповідей, інтерпретація яких при зміні їх значень на величину, меншу похибки ε , не змінюється.

Можна узагальнити оцінку E_0 , якщо використовувати підсумовування квадратів різниць $(d_i - y_i)^2$ р відповідними ваговими коефіцієнтами:

$$E = \frac{1}{P} \sum_{i=1}^P K_i (d_i - y_i)^2, \quad (3.3)$$

де K_i – ваговий коефіцієнт i -го прикладу в навчальній вибірці.

Для виділення найбільш важливих прикладів з навчальної вибірки можна використати оцінку (3.3), встановлюючи для цього значення відповідних вагових коефіцієнтів. Зазначимо, що цю оцінку можна використовувати у тому разі, коли необхідно врівноважити різні групи прикладів в навчальній вибірці.

Для цього необхідно призначати вагові коефіцієнти K_i так, щоб сумарна вага навчальних прикладів в навчальній вибірці для кожного класу не залежала від класу (наприклад, можна встановити для будь-якого прикладу ваговий коефіцієнт $K_i = 1/m$, де i – номер класу, m – число прикладів в

класі). При формуванні навчальної вибірки у разі нечіткої експертної оцінки окремих варіантів прикладів доцільно було б збільшити вагу окремих варіантів, щоб вони більше могли впливати на процес навчання мережі.

Вище було зазначено, що задача навчання нейронної мережі є задачею пошуку мінімуму функції помилки на множині вагових коефіцієнтів зв'язків між нейронами. Ця множина зазвичай задається матрицею W , тоді для розв'язання задачі пошуку мінімуму функції можуть бути використані стандартні методи теорії оптимізації.

Розглянемо алгоритм зворотного поширення помилки (Back Propagation - BP) і способи урахування його недоліків. Найбільш широко розповсюдженим алгоритмом навчання багатошарової НМ (БНМ) без зворотного зв'язку (рис. 3.1) являється алгоритм зворотного поширення помилки Back Propagation (BP).




Рисунок 3.1 – Структурна організація багатошарової нейронної мережі

Вважається, що розробкою цього алгоритму займалися Руммельхарт і Хінтонн [20], але незалежно від них раніше російські вчені Горбань А.Н. і Охонін В.А. розробили алгоритм двоїстого поширення сигналів, який дуже близький до алгоритму BP.

Розглянемо БНМ, в якій всі компоненти вхідного вектора подаються на кожен нейрон першого шару. Всі виходи прихованого шару m подають в

наступний шар і так далі, тобто нейронна мережа вважається повнозв'язаною. При навчанні нейронної мережі ставиться завдання мінімізації помилки, яку можна знайти різними методами, наприклад за допомогою метода найменших квадратів:

$$E(W) = \frac{1}{2} \sum_{j=1}^P (y_j - d_j)^2, \quad (3.4)$$

де y_j – значення j -го виходу нейронної мережі;

d_j – бажане значення j -го виходу;

p – число нейронів у вихідному шарі.

З використанням алгоритму ВР у стандартному варіанті навчання НМ може проводитися за допомогою градієнтної процедури пошуку локального екстремуму функціоналу оптимізації, який на практиці буває завжди багатоекстремальним. В цьому випадку зміна вагових коефіцієнтів на кожній ітерації обчислюється за формулою:

$$\Delta w_{ij} = -h \frac{\partial E}{\partial w_{ij}}, \quad (3.5)$$

де h – параметр, який визначає швидкість навчання НМ;

i, j – індекси, які пов'язують нейрони сусідніх шарів НМ.

Знайдемо похідну помилки навчання:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial S_j} \frac{\partial S_j}{\partial w_{ij}}, \quad (3.6)$$

де y_j – значення виходу j -го нейрона НМ;

S_j – зважена сума вхідних сигналів нейронів НМ.

При цьому в (3.6) множник $\frac{\partial S_j}{\partial w_{ij}} = x_i$, де x_i – значення i -го входу нейрона НМ.

Визначимо перший множник формули (3.5):

$$\frac{\partial E}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \frac{dy_k}{dS_k} \frac{\partial S_k}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \frac{dy_k}{dS_k} w_{jk}^{(n+1)}, \quad (3.7)$$

де k – число нейронів в $(n+1)$ шарі НМ.

Введемо допоміжну змінну $\delta_j^{(n)} = \frac{\partial E}{\partial y_j} \frac{dy_j}{dS_j}$. Тоді для визначення $\delta_j^{(n)}$ n -го шару можна використати рекурсивну формулу, якщо відомо $\delta_j^{(n+1)}$ наступного $(n+1)$ шару:

$$\delta_j^{(n)} = \left[\sum_k \delta_j^{(n+1)} w_{jk}^{(n+1)} \right] \frac{dy_j}{dS_j}, \quad (3.8)$$

Для знаходження $\delta_j^{(n)}$ для останнього слоя НМ не виникає труднощів, оскільки апріорі відомий вектор тих значень, які повинна видавати мережа при заданому вхідному векторі

$$\delta_j^{(n)} = (y_i^n - d_i) \frac{dy_i}{dS_i}. \quad (3.9)$$

Тоді отримаємо наступний вираз:

$$\Delta w_{ij}^{(n)} = -h \delta_j^{(n)} x_i^n. \quad (3.10)$$

Таким чином, можна сформулювати наступну послідовність повного алгоритму навчання з використанням ВР.

Крок 1. З навчальної вибірки подати на вхід нейронної мережі черговий вхідний вектор і визначити значення виходів нейронів у вихідному шарі.

Крок 2. Для вихідного шару НМ розрахувати δ^n за формулою (3.9) і $\Delta w_{ij}^{(n)}$ по формулі (3.10).

Крок 3. Для решти слоїв НМ розрахувати δ^n і $\Delta w_{ij}^{(n)}$ за відповідно за формулами (3.8) і (3.10).

Крок 4. Скорегувати всі ваги НМ:

$$w_{ij}^{(n)}(t) = w_{ij}^{(n)}(t-1) + \Delta w_{ij}^{(n)}(t), \quad (3.10)$$

де t – номер поточної ітерації.

Крок 5. Якщо помилка виявилася істотною, то необхідно повернутися до кроку 1, в іншому випадку – кінець.

Розглянемо основні проблеми, які пов'язані з використанням алгоритму ВР у процедурі навчання НМ, а також шляхи їх вирішення з метою підвищення якості та швидкості навчання. Розглянемо також методи підвищення ефективності алгоритму навчання ВР.

Негативними факторами, які мають вплив на алгоритму навчання ВР, є такі:

1. Повільна збіжність алгоритму навчання.

Якщо функціонування БНМ описується за допомогою диференціальних рівнянь, то строго доведена збіжність алгоритму ВР для нескінченно малих кроків змінювання вагових коефіцієнтів. Але при цьому нескінченно малі кроки змінювання призводять до нескінченно великого часу навчання. Тож при кінцевих кроках змінювання збіжність алгоритму ВР не гарантовано. Для підвищення швидкості збіжності алгоритму ВР можна

емпірично встановити коефіцієнт h [20], який можна не змінювати під час процедури навчання.

2. Блокування мережі.

Слід зазначити, що алгоритм ВР не являється ефективним у випадку, коли за різними вагами похідні змінних сильно відрізняються. Цими випадками є ситуації, коли для деяких нейронів значення функцій виходу близькі по модулю до одиниці, або коли модуль деяких ваг набагато більше одиниці. У цьому випадку на кожному кроці навчання для надання процесу корекції ваг деякої інерційності, що при переміщенні по поверхні цільової функції згладжує різкі скачки, як правило, в формулу (3.9) можна також емпірично ввести деякий коефіцієнт інерційності π , який на попередній ітерації дозволяє корегувати приріст ваги:

$$\Delta w_{ij}^{(n)}(t) = -h\delta_j^{(n)}x_i^n + \pi\Delta w_{ij}^{(n)}(t-1). \quad (3.11)$$

Значення коефіцієнтів корекції h і π визначається в ході розв'язання кожної конкретної задачі і залишається постійним протягом всієї процедури навчання, але це значно зменшує адаптивні можливості НМ. В теперішній час розробляють окремі алгоритми управління коефіцієнтами корекції h і π за поточним значенням помилки, але в цілому проблема поки що залишається не розв'язаною. Можна використовувати алгоритм автоматичного підстроювання цих коефіцієнтами під час процедури навчання, застосовуючи теорію нечітких множин і нечіткої логіки, тестування яких показало їх високу ефективність.

3. Проблема перенавчання НМ.

Слід зазначити, що висока точність, яка отримується на навчальній вибірці, на тестовій вибірці може привести до ненадійних результатів навчання. Чим краще мережа адаптована до навчальної вибірки і до конкретних умов, тим менше вона здатна до екстраполяції та узагальнення.

Це є наслідком перенавчання мережі, коли вона моделює не функцію, а шум, який присутній у навчальній вибірці.

Для вирішення цієї проблеми необхідно використовувати підтвердуючі вибірки, тобто використати частину прикладів бази даних, що не входять до навчальної та тестової вибірок. Недоліком застосування цього прийому є суттєве зменшення числа прикладів, які можна було б взяти в якості навчальної вибірки, що впливає як на зменшення навчальної вибірки, так і на можливе зниження якості роботи мережі. Крім того, виникає проблема оптимального розбиття вхідних даних на навчальну і тестову вибірки. Різні способи розбиття бази даних можуть дати різні оцінки навіть при випадковій вибірці.

Для вирішення розглянутої проблеми можна використати спеціальний метод зупинки алгоритму навчання, який дозволяє зменшити час навчання і покращити якість навчання НМ.

4. Проблема виходу з локального мінімуму.

Функція оптимізації в БНМ, яка представляється у вигляді (3.1), є багатоекстремальною і нелінійною за визначенням з наступних причин [20-22]:

- 1) має місце дуже складний розподіл множини варіантів представлення об'єкта в багатовимірному просторі ознак;
- 2) висока розмірність простору об'єкта, що досліджується.

У стандартному варіанті градієнтні методи пошуку екстремуму, які використовує алгоритм ВР, не завжди можуть виявити глобальний мінімум або вийти з локального мінімуму. Для підвищення ймовірності знаходження глобального мінімуму і збільшення стійкості алгоритму можна використати один із способів, який дозволяє розширити розмірність простору вагових коефіцієнтів за рахуна основі збільшення кількості прихованих шарів та кількості нейронів в прихованих шарах.

Але цей шлях суттєвого ускладнює НМ, яка використовується. Тому необхідний пошук альтернативних варіантів застосування

недетермінованих методів пошуку глобального екстремуму, до яких можна віднести, наприклад, випадковий пошук, еволюційні методи (генетичний та імунний підходи), метод імітації відпалу, тощо [33-37].

Ці методи дозволяють досліджувати цілком весь простір множини рішень і уникають можливості «застрявання» в області локального екстремуму. Тому необхідне дослідження властивостей цих методів в задачі навчання НМ з метою підвищення ефективності їх застосування. Зокрема, доцільним є застосування еволюційних методів, зокрема імунного підходу до навчання НМ.

3.2 Навчання та адаптація нейронної мережі з використанням імунного підходу

Методи навчання НМ, які існують на сьогодні, є трудомісткими. Крім того, в них відсутня можливість модифікації параметрів і структури НМ. Для надання такої можливості навчання НМ пропонується виконувати з використанням штучних імунних систем [20-22]. Задачу навчання НМ можна розглядати як задачу мінімізації цільової функції, в векторі параметрів НМ в якій використовуються параметри $w_{n,m}$, $w_{o,m}$, $v_{m,k}$, $v_{o,k}$ и λ_m , $n = \overline{1, N}$, $m = \overline{1, M}$, $k = \overline{1, K}$.

$$\Phi(P) = \sqrt{\frac{1}{n \cdot m} \sum_{i=1}^n \sum_{j=1}^m [F_i(x_j, P) - y_i]^2} = \min_P \quad (3.12)$$

При використанні імунного підходу для навчання НМ основною ідеєю є представлення розв'язуваної задачі у вигляді антигену, а можливі її розв'язки – у вигляді антитіл. В якості антигенів розв'язуваної задачі може виступати навчальна вибірка про вхідні x_n , $n = \overline{1, N}$ і вихідні y_k , $k = \overline{1, K}$ змінні. В якості антитіл будемо використовувати вектори параметрів, що

настроюються. В одному антитілі будемо кодувати всі параметри НМ: $w_{n,m}$, $w_{o,m}$, $v_{m,k}$, $v_{o,k}$ і λ_m , $n = \overline{1, N}$, $m = \overline{1, M}$, $k = \overline{1, K}$.

Для розв'язання задачі мінімізації цільової функції будемо використовувати модель кодування параметрів, які настроюються, у вигляді адаптивного структурованого мультиантитіла (рис. 3.2). При цьому мультиантитіло складається з двох частин, і кожна частина може оброблятися незалежно одна від одної.

$w_{1,1}, \dots, w_{1,M}, \dots, w_{N,1}, \dots, w_{N,M}; w_{0,1}, \dots, w_{0,M}; \lambda_1, \dots, \lambda_M$	$v_{1,1}$...	$v_{M,K}$	$v_{0,M}$
ab_0	ab_1	...	ab_M	ab_{M+1}
Частина 1	Частина 2			

Рисунок 3.2 – Структура адаптивного мультиантитіла

Популяцію мультиантитіл представимо у такий спосіб:

$$mAb = \{mAb_1, mAb_2, \dots, mAb_N\}$$

де $mAb_i = \{ab_0, ab_1, ab_2, \dots, ab_K\}$, $i = \overline{1, S}$ – i -те адаптивне мультиантитіло, розмір якого може змінюватися в ході виконання імунного алгоритму; S – розмір популяції мультиантитіл.

Кожне мультиантитіло характеризується повною множиною параметрів НМ, які настроюються. В першій частині мультиантитіла закодовані всі коефіцієнти функцій активації λ_m , всі вагові коефіцієнти нейронів $w_{n,m}$, а також всі значення зсувів $w_{o,m}$. У другій частині мультиантитіла закодовані всі коефіцієнти $v_{m,k}$, а також зміщення $v_{o,k}$ вихідного шару НМ.

Слід зазначити, що друга частина мультиантитіла є адаптивною, так як при навчанні змінюється загальна кількість коефіцієнтів і таким чином, крім оптимізації коефіцієнтів виконується ще і структурний синтез НМ. В цьому випадку відбувається зміна кількості нейронів в прихованому шарі НМ, а

також зв'язків між ними. Використання структурованого способу формування мультиантитіла за рахунок окремого застосування імунних операторів до кожної з його частин дозволяє підвищити ефективність імунного підходу до навчання НМ. Обчислення афінності між мультиантитілами виконується в цілому, оперуючи при цьому його обома складовими.

Для побудови обчислювальної моделі оптимізації використовуються наступні принципи імунного підходу: клональний відбір та мережева взаємодія. При використанні клонального відбору антитіло спочатку розпізнає антиген, потім клонується і отримані клони піддаються мутації. Якщо після мутації афінність клону покращилася, то відповідне антитіло замінюється цим клоном, тобто здійснюється клональний відбір. При застосуванні моделі імунної мережі до мультиантитіла всі антитіла взаємодіють не тільки з усіма антигенами, але і з усіма антитілами. Це призводить до забезпечення ефекту супресії і взаємної стимуляції, а це, в свою чергу, може призвести до зменшення кількості нейронів в проміжних шарах НМ.

Імунний алгоритм навчання здійснюється в режимі off-line і являє собою ітераційну процедуру послідовної ідентифікації моделі по навчальній вибірці. Антигени являють собою приклади навчальної вибірки, а кожне антитіло являє собою одне із можливих рішень. При цьому кількість антитіл в популяції повинно відповідати кількості прикладів у навчальній вибірці.

Імунний алгоритм навчання НМ виконує таку послідовність кроків:

1. Ініціалізація початкової популяції мультиантитіл, яка може виконуватися випадковим чином.

2. Обчислення афінності Aff_{mAb-Ag} кожного мультиантитіла mAb з антигеном Ag . Для цього необхідно підставити всі параметри, які закодовані в мультиантитілі, в НМ. На входи НМ слід подати вхідні змінні x_n і обчислити значення всіх вихідних змінних y_k . Афінність мультиантитіла

mAb з антигеном Ag обчислюється у такий спосіб:

$$Aff_{mAb-Ag} = (1 + d_{mAb-Ag})^{-1}, \quad (3.13)$$

де d_{mAb-Ag} – відстань Хеммінга між значеннями отриманих виходів НМ y_k , $k = \overline{1, K}$ і бажаними значеннями y_k^r для всіх антигенів популяції Ag :

$$d_{mAb-Ag} = \sum_{k=1}^K y_k, \quad \text{зде } y_k = \begin{cases} 1, & \text{если } y_k \neq y_k^r, \\ 0, & \text{если } y_k = y_k^r. \end{cases} \quad (3.14)$$

3. Клонування мультиантитіл, яке виконується пропорційно їх афінності з антигеном, і формування популяції клонів Cl . В якості параметрів оператора клонування береться кількість антитіл для клонування g та кратність клонування мультиантитіла N_{Cl} . Для клонування можна використати фіксоване значення параметра g . Кратність клонування мультиантитіла N_{Cl} в залежності від афінності можна регулювати в процесі роботи імунного алгоритму згідно виразу:

$$N_{Cl} = \alpha * N_{Cl_min} + (1 - \alpha) * N_{Cl_max}, \quad (3.15)$$

де $\alpha = \frac{Aff_{best} - Aff_{mAb-Ag}}{Aff_{best}}$; N_{Cl_min} і N_{Cl_max} – відповідно мінімальна та

максимальна кратність клонування мультиантитіла;

Aff_{best} – значення кращої афінності в поточному поколінні.

4. Мутація клонів, яка виконується обернено пропорційно афінності мультиантитіла з антигеном, і формування популяції клонів MC , що мутовані. При цьому мутація всіх обраних параметрів мультиантитіла mAb обробляється шляхом додавання до них Гаусівського шуму:

$$mAb_{i+1} = mAb_i + N(0, \sigma_i), \quad (3.16)$$

У формулі (3.16) змінювання середньоквадратичного відхилення випадкової величини σ_i можна виконувати, використовуючи співвідношення:

$$\sigma_{i+1} = \sigma_i \frac{Aff_{best} - Aff_{mAb-Ag}}{Aff_{best} - Aff_{worst}}, \quad (3.17)$$

де Aff_{worst} – найменше значення афінності мультиантитіла в поточному поколінні.

5. Обчислення афінності популяції клонів MC , що мутовані, згідно з (3.13). Якщо в результаті мутації афінність збільшилася, то заміна мутованими клонами відповідних мультиантитіл в популяції mAb .

6. Обчислення афінності між антитілами, які знаходяться всередині другої частини мультиантитіла. Виконання супресії антитіл, афінність яких стала більше заданого порога супресії δ_{net} . При цьому обчислення афінності може виконуватися відповідно до формули:

$$d_{ab_i-ab_j} = \|ab_i - ab_j\| = \sqrt{\sum_{m=0}^M (v_{m,i} - v_{m,j})^2}, \quad i, j = \overline{1, K}, \quad (3.18)$$

де $d_{ab_i-ab_j}$ – відстань між i -м та j -м антитілами другої частини мультиантитіла.

Шляхом видалення антитіл з афінністю, яка більше заданого порогу δ_{net} , реалізується супресія НМ, що дозволяє зменшити число нейронів і зв'язків між ними в прихованих шарах НМ і зменшити їх надмірність.

7. Перевірка критерію зупинки алгоритму. В якості критерія зупинки

імунного алгоритму можна використати або досягнення відповідного порогу афінності, або досягнення необхідної кількості поколінь роботи алгоритму.

Результатом роботи імунного алгоритму буде мультиантитіло, яке має кращу по популяції афінність. Таким чином, згідно цього мультиантитіла буде визначена як структура, так і налаштовані параметри НМ. При цьому кроки 1-5 імунного алгоритму відповідають принципу клонального відбору. На цих етапах імунний алгоритм працює одночасно з обома частинами мультиантитіла. Крок 6 відповідає імунному принципу мережевої взаємодії. Якщо на попередніх етапах мультиантитіло оброблялося як звичайне антитіло, то на цьому етапі робота імунного алгоритму виконується тільки з другою частиною мультиантитіла, яке складається з окремих антитіл.

При функціонуванні ІСППР можлива зміна як характеристик навколишнього середовища, так і властивостей ОБПР. За таких умов необхідно під ці зміни адаптувати модель, іншими словами, необхідно здійснювати її еволюцію. Для цього слід використовувати відповідні процедури навчання НМ на основі застосування імунного підходу, де на вхід як навчальна вибірка будуть подаватися реальні значення вхідних змінних моделі, яка функціонує в режимі on-line.

Застосування рівномірного розподілу нейромережевої обробки вхідних даних, який використовує динамічний перерозподіл наборів шарів нейронів НМ між обчислювачами в залежності від типу та обсягу оброблюваних даних, дозволяє значно зменшити час навчання і функціонування НМ, а також майже на порядок зменшити обчислювальну складність. Розглянутий підхід дозволяє у реальному часі коригувати як структуру, так і параметри нейромережевої моделі ІСППР.

3.3 Експериментальні дослідження нейромережевої моделі з імунною настройкою для прийняття рішень

Прикладом погано формалізованої задачі є задача створення та аналізу

локальної комп'ютерної мережі (ЛКМ). Для її розв'язання необхідне використання інтегрованого підходу, який дозволяє для дослідження складних систем адекватно поєднувати логічні та математичні методи обробки інформації, застосовуючи нові методи подання знань, а також використовувати інтуїцію і досвід ОсПР для прогнозу та оцінки альтернативних варіантів рішень.

Слід зазначити, що існує багато важливих питань, які перед реалізацією даної задачі необхідно розглянути, а саме питання валідності вихідних параметрів, яким повинна відповідати ЛКМ, а також початкові умови (вхідні параметри), які необхідно задати і врахувати безпосередньо перед процесом проектування.

Попередній аналіз ЛКМ дозволив визначити основні вхідні параметри, з яких найбільш суттєвими є такі:

- x_1 – вартість ЛКМ;
- x_2 – кількість і розташування користувачів ЛКМ;
- x_3 – простота встановлення і зміни конфігурації ЛКМ;
- x_4 – пропускна здатність ЛКМ;
- x_5 – надійність ЛКМ;
- x_6 – безпека ЛКМ;
- x_7 – можливість розширення ЛКМ.

Згідно вимог створення ЛКМ визначимо такі основні вихідні параметри:

- 1) операційна система (ОС) ЛКМ;
- 2) топологія ЛКМ;
- 3) технологія функціонування ЛКМ.

Варіанти вибору ОС ЛКМ:

- 1) Novell NetWare;
- 2) Microsoft Windows (NT, Vista, 7, 8, 10);

- 3) UNIX системи (Solaris, FreeBSD);
- 4) GNU / Linux системи;
- 5) IOS;
- 6) ZyNOS компанії ZyXEL.

Варіанти вибору топології ЛКМ:

- 1) зірка;
- 2) шина;
- 3) кільце;
- 4) дерево;
- 5) повнозв'язна;
- 6) чарункувата;
- 7) змішана.

Варіанти вибору технології функціонування ЛКМ:

- 1) Ethernet;
- 2) Token Ring;
- 3) FDDI.

Використання методу простого перебору варіантів для реалізація даної задачі непридатна, так як комбінаторна ємність варіантів перебору може становити кілька порядків. Крім того, більша частина комбінацій цих варіантів через високі матеріальні витрати ніколи не буде реалізована. Тому реалізація моделі ІСППР була виконана з використанням нейронних мереж, які еволюціонують.

Задача синтезу ЛКМ була розбита умовно на три паралельні задачі, кожна з яких повинна вирішувати проблему по одному з трьох вихідних параметрів. Зазначимо, що кожен з вихідних параметрів може залежити від значень не всіх 7-х вхідних параметрів, а тільки від кількох із них. Для кожної з трьох розв'язуваних задач була створена окрема нейронна мережа, яка враховувала певну кількість вхідних і вихідних параметрів, наприклад, для вибору ОС – це відповідно 7 і 6.

Кількість прихованих шарів НМ обрано один, який може містити 15 і

більше нейронів. Структура створеної НМ, згідно якої визначається ОС ЛКМ, наведена на рис. 3.3.




Рисунок 3.3 – Структура нейронної мережі для визначення ОС ЛКМ

Для кожної зі створюваних ЛКМ були організовані відповідні навчальні вибірки, які містили не менше 50 варіантів. Випадковим чином визначалися початкові значення всіх вагів нейронної мережі, які були задані в діапазоні від -0,5 до +0,5. На виході НМ для кожного варіанту навчальної вибірки була установлена комбінація з нулів і однієї одиниці. Так, наприклад, якщо необхідно було виконати вибір ОС, то НМ мала на виході 6 нейронів, а варіант «0001000» відповідав отриманому рішенням «GNU / Linux системи».

Відповідно до своєї навчальної вибірки після створення нейронних мереж для кожної задачі кожна з них навчалася за допомогою ШС, досягаючи заданої точності навчання. Кількість епох навчання НМ залежала не тільки від кількості варіантів у навчальній вибірці та значень виходу мережі, а й від кількості варіантів у навчальній вибірці.

Перевірка про досягнення мережею межі навчання показала, що отриманий результат на окремому етапі дає помилку для кожного з варіантів вибірки, тому що при збільшенні числа варіантів вибірки мережа навчається

довше. Подача на вхід НМ варіанта з набору вхідних змінних після закінчення процесу навчання формує результат з трьох вихідних параметрів.

Таким чином, проведені дослідження показали, що доцільно використовувати багат шарові нейронні мережі персептронного типу з імунним навчанням для прогнозування різних варіантів рішень при виборі тих чи інших параметрів ЛКМ, при цьому спостерігається висока надійність і стійкість отриманих результатів.

ВИСНОВКИ

Метою магістерської кваліфікаційної роботи є розробка інтелектуальної системи підтримки прийняття рішень з використанням нейромережевої технології та імунного підходу, яка орієнтована на підвищення якості її функціонування шляхом створення моделі прийняття рішень та еволюції її структури і параметрів за умов невизначеності як зовнішнього середовища, так і властивостей об'єкта прийняття рішень.

Ефективність розв'язання цієї задачі обумовлена обґрунтованим вибором моделі прийняття рішень у вигляді багат шарової нейронної мережі, а також використанням методу для її навчання і еволюції на основі застосування імунного підходу. Навчання та еволюція нейромережевої моделі прийняття рішень розглядається як задача її адаптації як до зміни зовнішнього середовища, так і до зміни властивостей об'єкта прийняття рішень. Реалізація цієї задачі складається з розробки алгоритмів адаптації як параметрів нейромережевої моделі, так і її структури, тобто числа нейронів в прихованих шарах та їх зв'язків між собою. З цією метою були використані імунні моделі клонального відбору та імунної мережі.

В ході виконання магістерської кваліфікаційної роботи були розглянуті і вирішені наступні питання:

1. Проведено аналіз існуючих підходів до побудови інтелектуальних систем підтримки прийняття рішень. Розглянуто проблеми побудови ІСППР в умовах невизначеності та проаналізовані основні підходи до розв'язання погано формалізованих задач.

2. Проведено аналіз використання нейромережевого підходу та апарату нечіткої логіки до розв'язання погано формалізованих задач, які мають певні переваги і недоліки. Вказано, що вони добре розв'язують задачі, які пов'язані з обробкою неточної, неповної і недостовірної інформації, але вони не володіють багатьма можливостями. Тому для розв'язання поставленої задачі

пропонується побудова гібридних моделей, які враховують кращі особливості нейронних мереж, нечітких множин і нечіткої логіки та еволюційних алгоритмів.

3. Розглянуті особливості формування моделей нейронних мереж для ІСППР, методи обробки інформації для формування навчальних вибірок, а також питання вибору типу і формування топології нейронної мережі.

4. Розроблена модель і алгоритм навчання та адаптації нейронної мережі на основі штучних імунних систем. З цією метою використовується модель кодування параметрів, які настроюються, у вигляді адаптивного структурованого мультиантитіла, яке складається з двох частин, кожна з яких може оброблятися незалежно одна від одної.

5. Проведені експериментальні дослідження нейромережевої моделі з імунною настройкою для прийняття рішень по створенню та аналізу локальної комп'ютерної мережі.

Проведені дослідження показали, що для навчання та прогнозування різних варіантів рішень при виборі тих чи інших параметрів ЛКМ доцільно використовувати НМ з імунним навчанням.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Комарцова Л.Г. Использование нейросетевых методов для решения задач проектирования вычислительных систем (монография). Научное издание.-М.: Из-во МГТУ им. Н.Э. Баумана. -2000.
2. Ларичев О.И. Теория и методы принятия решений. - М.: Логос. - 2002.
3. Гаврилова Т.А., Хорошевский В.Р. Базы знаний интеллектуальных систем. -СПб.: Питер. -2000.
4. Байдык Т.Н. Нейронные сети и задачи искусственного интеллекта. - Киев.: Наукова Думка. -2001.
5. Заде Л. Понятие лингвистической переменной и его применение к принятию приближённых решений / Пер. с англ. -М.:Мир. -1976.
6. Галушкин А.И. Теория нейронных сетей. -Кн. 1. -М.: ИПРЖР. -2000.
7. Головкин В.А. Нейронные сети: обучение, организация, применение.- Кн.4. - М.: ИПРЖР.-2001.
8. Комарцова Л.Г. Нейросетевые технологии в задачах проектирования корпоративных сетей // Информационные технологии в проектировании и производстве. -Научно-техн. журнал.: ГУП "ВИМИ".-М.-2000.-№3.-С. 47-50.
9. Комарцова Л.Г. Исследование алгоритмов обучения многослойного персептрона // Нейрокомпьютеры. Разработка и применение. -М.: Радиотехника.-2002. -№ 12.-С. 15-21.
10. Сигеру Омату, Морзуки Холид, Рубея Юсов. Нейроуправление и его приложения. -Кн. 2. -М.: ИПРЖР. -2000.
11. Комарцова Л.Г., Максимов А.В. Нейрокомпьютеры. -М.: Из-во МГТУ им. Н.Э. Баумана. -2002. – 352 с.
12. Стадниченко С.Ю. Интеллектуальные системы поддержки принятия решения [Текст] / С.Ю. Стадниченко // Молодой ученый – 2010. – № 6. – С. 61-63.

13. Снитюк В.Е. Эволюционные технологии принятия решений в условиях неопределенности [Текст] / В.Е. Снитюк. – К.: «МП Леся», 2015. – 347 с.
14. Комарцова Л.Г. Исследование нейросетевых алгоритмов обучения в интеллектуальных эволюционных системах [Текст] / Л.Г. Комарцова, Ю.Н. Лавренков, О.В. Антипова // Материалы IV-й международной конференции OSTIS-2014, С. 233-238.
15. Korablev N. Immune Approach for Neuro-Fuzzy Systems Learning Using Multiantibody Model [Текст] / N. Korablev, I. Sorokina // ICARIS 2011, Springer Lecture Notes in Computer Science. – 2011. – Vol. 6825. – pp. 395–405.
16. Dasgupta D. Recent Advanced in Artificial Immune Systems: Models and Applications [Текст] / D. Dasgupta, S. Yu, F. Nino // Applied Soft Computing. Elsevier, 2011. – pp. 1574-1587.
17. Ala'M AZ, Heidari AA, Habib M, Faris H, Aljarah I, Hassonah MA. Salp chain-based optimization of support vector machines and feature weighting for medical diagnostic information systems. In Evolutionary machine learning techniques. Singapore: Springer; 2020, pp. 11–34.
18. Alexeyev A, Solianyк T. Decision-making support system for experts of penal law. In Data-centric business and applications. Switzerland: Springer; 2020, pp. 163–82.
19. Alloghani M, Al-Jumeily D, Hussain A, Mustafina J, Baker T, Aljaaf AJ. Implementation of machine learning and data mining to improve cybersecurity and limit vulnerabilities to cyber attacks. In Nature-inspired computation in data mining and machine learning. Springer; 2020. pp. 47–76.
20. Díaz J.J.S. Artificial intelligence in cardiovascular medicine: Applications in the diagnosis of infarction and prognosis of heart failure. In Artificial intelligence in precision health. Spain: Elsevier; 2020, pp. 313–28.
21. S. Behmel, M. Damour, R. Ludwig, M.J. Rodriguez. Intelligent decision-support system to plan, manage and optimize water quality monitoring

programs: design of a conceptual framework // Journal of Environmental Planning and Management. Volume 64, 2021 - Issue 4, pp. 703-733.

22. Xiaoqing Zhou, Zhiyong Zhou, Jianqiong Xiao, Jiaxiu Sun. Research and Application of an Intelligent Decision Support System // International Journal of Advanced Network, Monitoring and Controls. Volume 2, Issue 3, 2017, pp. 141-144.

23. He Changlin, Li Yufen. A Survey of Intelligent Decision Support System // 7th International Conference on Applied Science, Engineering and Technology (ICASET 2017). Advances in Engineering Research, volume 122, 2017.

24. F. Abu-Abed, A. Khabarov. Retracted: Intelligent decision support system for operators of the supply department of oil and gas extracting industry // Journal of Fundamental and Applied Sciences, Vol. 10, No. 6S (2018).

25. Min Hun Lee, Daniel P. Siewiorek, Asim Smailagic, Alexandre Bernardino, Sergi Bermúdez i Badia. Co-Design and Evaluation of an Intelligent Decision Support System for Stroke Rehabilitation Assessment // Proceedings of the ACM on Human-Computer Interaction Volume 4 Issue CSCW2, No.: 156, 2020, pp. 1–27.

26. Mykola Korablyov, Natalia Axak, Oleksandr Fomichov and Andrii Chuprina. Hybrid Neuro-Fuzzy Model with Immune Training for Recognition of Objects in an Image / Proceedings of the 9th International Conference "Information Control Systems & Technologies", Odessa, Ukraine, September 24–26, 2020. – pp. 267-281.

27. Кораблев Н.М., Фомичев А.А., Соловьев Д.Н., Чуприна А.А. Гибридные модели принятия решений с использованием иммунного подхода // Информационные управляющие системы и технологии. Проблемы и решения: монография. Под науч. ред. проф. Вычужанина Владимира. – Одесса: Экология, 2019. – С. 100-116.