

МАГІСТЕРСЬКА КВАЛІФІКАЦІЙНА РОБОТА

на тему:

«Методи оптимізації телекомунікаційних систем
на основі нейронних мереж»

Виконав: студент 2-го курсу,
групи TSM-23м
спеціальності 172 – Електронні
комунікації та радіотехніка
Чорний К.П.

Керівник: к.т.н., доцент каф. ІКСТ
Семенова О.О.
« 16 » 12 2024 р.

Опонент: к.т.н., доцент каф. ІРТС
Осадчук Я.О.
« 16 » 12 2024 р.

Допущено до захисту
Завідувач кафедри ІКСТ
д.т.н., проф. Кичак В.М.
« 16 » 12 2024 р.

Вінницький національний технічний університет
Факультет інформаційних електронних систем
Кафедра інфокомунікаційних систем і технологій
Рівень вищої освіти II-й (магістерський)

Галузь знань - 17- Електроніка, автоматизація та електронні комунікації
(шифр і назва)

Спеціальність - 172 - Електронні комунікації та радіотехніка
(шифр і назва)

Освітньо-професійна програма - Телекомунікаційні системи та мережі

ЗАТВЕРДЖУЮ

Завідувач кафедри ІКСТ

д.т.н., професор В.М. Кичак

"24" 09 2024 року

ЗАВДАННЯ НА МАГІСТЕРСЬКУ КВАЛІФІКАЦІЙНУ РОБОТУ СТУДЕНТУ

Чорному Костянтину Павловичу

(прізвище, ім'я, по батькові)

1. Тема роботи Методи оптимізації телекомунікаційних систем на основі нейронних мереж

керівник роботи Семенова Олено Олександрівна, канд. техн. наук, професор

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом вищого навчального закладу від "17" 09 2024 року № 310

2. Строк подання студентом роботи 09 грудня 2024 року

3. Вихідні дані до роботи кількість вузлів мережі - 5; залишкова енергія - 80%; навантаження в мережі - 30%; відстань - 80%; кількість циклів навчання - 1000

4. Зміст текстової частини: огляд та аналіз технології штучних нейронних мереж; планування телекомунікаційних систем за допомогою нейронних мереж; прогнозування у телекомунікаційних системах за допомогою нейронних мереж; оцінювання характеристик телекомунікаційних систем за допомогою нейронних мереж; економічна частина

5. Перелік ілюстративного матеріалу (з точним зазначенням обов'язкових креслень)

1) Інтелектуальні технології 2) Класифікація нейронних мереж. 3) Штучна нейронна мережа 4) Прогнозування напруженості поля 5) Розподіл частотних каналів у мережі 6) Прогнозування характеристик 7) Керування мережею 8) Маршрутизація в мережі 9) Розроблення мережі у програмі Matlab 10) Моделювання мережі у програмі Matlab

6. Консультанти розділів роботи


Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Спеціальна частина	Семенова О.О. доцент кафедри ІКСТ	24.09.2024	16.12.2024
Економічний розділ	Буреннікова Н. В. проф. каф. ЕПВМ	24.09.2024	16.12.2024

7. Дата видачі завдання 02 вересня 2024 року

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів магістерської кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
1.	Розробка технічного завдання	09.09.2024р.	
2.	Огляд відомостей про нейронні мережі	16.09.2024р.	
3.	Аналіз шляхів використання нейронних мереж при плануванні у телекомунікаціях	12.10.2024р.	
4.	Аналіз шляхів використання нейронних мереж при прогнозуванні у телекомунікаціях	30.10.2024р.	
5.	Аналіз шляхів використання нейронних мереж при виявленні аномалій у телекомунікаціях	11.11.2024р.	
6.	Аналіз економічної ефективності розробки	22.11.2024р.	
7.	Оформлення пояснювальної записки та ілюстративної частини	02.12.2024р.	
8.	Нормоконтроль МКР	06.12.2024р.	
9.	Попередній захист МКР, опонування МКР	14.12.2024р.	
10.	Захист МКР ЕК	18.12.2024р.	

Студент


 (підпис)

Чорний К.П.

Керівник роботи


 (підпис)

Семенова О.О.

АНОТАЦІЯ

УДК 621.335

Чорний К.П. Методи оптимізації телекомунікаційних систем на основі нейронних мереж. Магістерська кваліфікаційна робота зі спеціальності 172 – електронні комунікації та радіотехніка, освітня програма – телекомунікаційні системи та мережі. Вінниця: ВНТУ, 2024. 116 с.

На укр. мові. Бібліогр.: 36 назв; рис.: 25; табл. 15.

Робота присвячена дослідженню особливостей використання методів штучного інтелекту, зокрема штучних нейронних мереж для вирішення задач оптимізації телекомунікаційних систем.

Метою роботи є підвищення ефективності телекомунікаційних мереж шляхом розроблення нових методів їх планування.

Основними завданнями наукової роботи є огляд механізмів побудови та функціонування нейронних мереж; аналіз методів розв'язання деяких задач телекомунікаційних систем за допомогою нейронних мереж; розроблення та дослідження нейронних мереж.

Робота містить п'ять розділів. У першому розділі загальні відомості з теорії штучних нейронних мереж.

У другому розділі виконано аналіз можливостей використання нейронних мереж при плануванні телекомунікаційних систем.

У третьому розділі виконано аналіз можливостей використання нейронних мереж при прогнозуванні параметрів телекомунікаційних систем.

У четвертому розділі виконано аналіз можливостей використання нейронних мереж при оцінюванні характеристик телекомунікаційних систем.

У п'ятому розділі виконано економічне обґрунтування доцільності реалізації даної науково-дослідної роботи.

ANNOTATION

Chorny K.P. Methods of optimisation of telecommunication systems based on neural networks. Master's qualification work in speciality 172 - electronic communications and radio engineering, educational programme - telecommunication systems and networks. Vinnytsia: VNTU, 2024. 116 c.

In Ukrainian. Bibliography: 36 titles; Figures: 25; Table 15.

The work is devoted to the study of the peculiarities of using artificial intelligence methods, in particular artificial neural networks, to solve the problems of optimising telecommunication systems.

The aim of the work is to increase the efficiency of telecommunication networks by developing new methods of their planning.

The main tasks of the research work are to review the mechanisms of construction and functioning of neural networks; analyse methods for solving some problems of telecommunication systems using neural networks; develop and study neural networks.

The paper consists of five chapters. The first section provides general information on the theory of artificial neural networks.

The second section analyses the possibilities of using neural networks in planning telecommunication systems.

The third section analyses the possibilities of using neural networks in predicting the parameters of telecommunication systems.

The fourth section analyses the possibilities of using neural networks in assessing the characteristics of telecommunication systems.

Section 5 provides an economic justification for the feasibility of this research work.

ЗМІСТ

Вступ.....	4
1 ОГЛЯД ТА АНАЛІЗ ТЕХНОЛОГІЇ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ...	6
1.1 Призначення штучних нейронних мереж	6
1.2 Складові частини нейронної мережі	8
1.3 Принцип дії елементу нейронної мережі.....	9
1.4 Налаштування нейронної мережі	11
1.5 Алгоритм настроювання нейронних мереж.....	16
2 ПЛАНУВАННЯ ТЕЛЕКОМУНІКАЦІЙНИХ СИСТЕМ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ	23
2.1 Основні напрями застосування штучних нейронних мереж в телекомунікаційних системах	23
2.2 Використання нейронних мереж при плануванні мереж мобільного зв'язку.....	25
2.3 Використання нейронних мереж для розподілення каналів в коміркових мережах.....	28
3 ПРОГНОЗУВАННЯ У ТЕЛЕКОМУНІКАЦІЙНИХ СИСТЕМАХ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ	38
3.1 Задача прогнозування характеристик поширення сигналу.....	38
3.2 Задача виявлення сигналів.....	43
3.3 Задача керування мережею.....	47
4 ОЦІНЮВАННЯ ХАРАКТЕРИСТИК ТЕЛЕКОМУНІКАЦІЙНИХ СИСТЕМ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ.....	53
4.1 Виявлення аномалій у телекомунікаційних системах	53
4.2 Нейро-нечіткий підхід до маршрутизації.....	65
5 ЕКОНОМІЧНА ЧАСТИНА.....	78
5.1 Оцінювання наукового ефекту	78
5.2 Розрахунок витрат на здійснення науково-дослідної роботи	82
5.3 Оцінювання важливості та наукової значимості науково-дослідної роботи	94

5.4 Висновки по розділу.....	96
ВИСНОВКИ.....	97
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	99
ДОДАТКИ.....	104
Додаток А (обов'язковий) Ілюстративна частина.....	105
Додаток Б (обов'язковий) Протокол перевірки кваліфікаційної роботи на наявність текстових запозичень.....	116

ВСТУП

Актуальність теми. Оптимізація телекомунікаційних систем є критично важливою для забезпечення їх ефективності, надійності та відповідності сучасним вимогам. Існує декілька ключових причин необхідності такої оптимізації. Зокрема, сучасні технології, такі як мобільний інтернет, відео-стрімінг і IoT, спричиняють стрімке зростання обсягу даних. Оптимізація дозволяє системі справлятися з цим навантаженням і забезпечувати стабільну роботу. Окрім того, конкуренція на ринку телекомунікацій вимагає від операторів надання високоякісних послуг. Оптимізація допомагає зменшити затримки, підвищити швидкість передачі даних та покращити надійність зв'язку. Також оптимізація ресурсів, таких як пропускна здатність, енергія та обладнання, дозволяє знизити експлуатаційні витрати та підвищити загальну економічну ефективність. Оптимізовані системи можуть краще витримувати відмови та атаки, забезпечуючи більшу надійність і безпеку зв'язку. Також, в умовах швидко змінюваного технологічного середовища оптимізація дозволяє системам бути більш гнучкими і адаптуватися до нових технологій та вимог користувачів. Оптимізація дозволяє ефективно інтегрувати такі сучасні технології як 5G, IoT та штучний інтелект, котрі вимагають нових підходів до проектування та управління мережами. Нарешті, покращення якості послуг, зменшення затримок і підвищення швидкості передачі даних безпосередньо впливають на задоволеність користувачів і лояльність до оператора.

Таким чином, вирішення задач оптимізації телекомунікаційних систем є необхідним для забезпечення їхньої ефективності, конкурентоспроможності та відповідності вимогам сучасного суспільства.

Аналіз останніх досліджень. Виконані літературний огляд та аналіз підтвердили, що дослідженню особливостей оптимізації та підвищенню ефективності телекомунікаційних систем присвячені праці таких вітчизняних вчених як Климаша М.М., Захарченко С.М., Бешлей М.І., Одарченко Р.С., Лемешко О.В., Єременко О. С. та багатьох інших [1-13].

Мета та задачі дослідження. Метою даної магістерської дипломної роботи є оптимізація роботи телекомунікаційних систем.

Для досягнення мети необхідно розв'язати такі задачі:

- провести огляд механізмів побудови та функціонування нейронних мереж;
- виконати аналіз методів розв'язання деяких задач телекомунікаційних систем за допомогою нейронних мереж;
- розробити нейронну мережу для вирішення задачі маршрутизації.

Об'єктом дослідження є телекомунікаційні системи.

Предметом дослідження є методи оптимізації телекомунікаційних систем.

Методи дослідження. Для рішення поставлених завдань були використані методи теорії телетрафіку для опису принципів побудови телекомунікаційних систем, теорії інформації та передавання сигналів для опису роботи телекомунікаційних систем, методи м'яких обчислень для розроблення нейронних мереж, імітаційне моделювання для дослідження роботи пристрою.

Новизна одержаних результатів: У магістерській кваліфікаційній роботі шляхом використання теорії м'яких обчислень розроблено метод маршрутизації, побудований на математичному апараті нейронних мереж, використання якого дозволить підвищити ефективність функціонування телекомунікаційних систем.

Апробація результатів магістерської кваліфікаційної роботи. Основні ідеї роботи доповідались і обговорювались на LIII науково-технічній конференції підрозділів Вінницького національного технічного університету у 2024 році.

1 ОГЛЯД ТА АНАЛІЗ ТЕХНОЛОГІЙ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ

1.1 Призначення штучних нейронних мереж

Системи розпізнавання образів, оброблення сигналів, прогнозування та діагностування, а також робототехнічні та бортові системи використовують штучні нейронні мережі. Штучні нейронні мережі можуть розв'язувати складні завдання, які не залежать від несправності окремих нейронів [14].

Якщо біологічні нейронні мережі мають такі характеристики, штучні нейронні мережі можуть успішно виконувати нерегулярні завдання.

Нейрон природного мозку послужив моделлю для створення нейрона. Так, біологічний нейрон має тіло, де дендрити передають вхідні сигнали, і аксон, який передає вихідний сигнал нейрона іншим клітинам [15]. Синапс — це точка, де аксон і дендрит з'єднуються.

Функціонування нейрона можна представити так:

- нейрон одержує вектор вхідних сигналів від дендритів;
- у тілі нейрона оцінюється загальне значення вхідних сигналів. Однак входи нейрона не є однаковими. Так, кожен вхід має ваговий коефіцієнт, який оцінює цінність інформації, що потрапляє. Таким чином, нейрон не тільки підсумовує значення вхідних сигналів, але й обчислює скалярний добуток вектора вхідних сигналів і вектора вагових коефіцієнтів;
- нейрон генерує сигнал, інтенсивність якого залежить від скалярного добутку. Вихідний сигнал взагалі не формується, якщо він не перевищує визначеного порогу;
- вихідний сигнал проходить через аксон до дендритів інших нейронів.

Значення вагових параметрів і збудження нейронів визначають поведінку нейронної мережі. Збудження може бути лінійне, порогове та сигмоїдальне. У лінійних елементах сумарне зважене вхідне значення нейрона пропорційне його вихідному значенню. У порогових елементах вихідна дія встановлюється на одному з двох рівнів, залежно від того, менший або більший загальний

сигнал, який надходить до нейрона, ніж порогове значення. Вихідна дія сигмоїдальних елементів змінюється по мірі зміни входу безперервно, а не лінійно.

Нейронні мережі складаються з великої кількості досить простих компонентів, нейронів, а топологія їх з'єднань визначається типом мережі. Створення нейронної мережі для вирішення конкретного завдання передбачає визначення того, як нейрони будуть сполучатися один з одним, а також визначення вагових параметрів для зв'язків нейронів. Вплив одного елемента на інший залежить від його зв'язків. Вага з'єднання визначає силу впливу.

Отже, розпізнання образів, класифікація, прогнозування та оптимізація — це завдання, які добре виконують штучні нейронні мережі. Наведемо список потенційних промислових використання штучних нейронних мереж.

1) Телекомунікації та телебачення:

- а) адаптивне керування телекомунікаційною мережею;
- б) стиснення та відновлення зображення.

2) Адміністративне обслуговування:

- а) автоматичне зчитування документів;
- б) автоматичне розпізнання штрих-кодів.

3) Військова промисловість:

- а) оброблення звукових і радарних сигналів;
- б) оброблення інфрачервоних сигналів;
- в) автоматичне пілотування.

Наразі неможливо створити універсальні, потужні нейронні мережі через широкий круг завдань, які розв'язуються нейронними мережами. Це змушує розробляти спеціалізовані нейронні мережі, які працюють за різними алгоритмами.

Моделі штучних нейронних мереж можуть бути апаратними або програмними. Незважаючи на значні відмінності, різні типи нейронних мереж мають спільні характеристики.

1.2 Складові частини нейронної мережі

Основними складовими частинами нейронної мережі є (рис.1.1.):

- набір елементів перетворення (нейронів)
- набір активних станів
- вихідна функція для кожного елементу
- ієрархія з'єднання
- правило передачі активного зразку з одного елементу до іншого
- правило активації елементу сигналами та створення нового активного стану
- навчальне правило для модифікації значення ваги.

Перетворення і таких мережах полягає у правилі для вхідного шару через внутрішній шар до вихідного шару, або з вхідного шару прямо до вихідного, або у зворотному напрямку між окремими шарами (туди і назад).

Окремі шари складаються з числа елементів обробки. Кожен шар містить принаймні один елемент обробки. У більшості випадків, елементи одного шару є однотипними. Елемент обробки може бути з'єднаним з будь-якими елементами іншого шару (міжшарове з'єднання), або того ж шару (внутрішньшарове з'єднання). З'єднання елемента обробки j з елементом обробки i називається вагою W_{ij} , яка може бути змінною або постійною. Звичайно, значення ваги представляються дійсними числами (найчастіше, з інтервалу від -1 до $+1$). У більшості випадків, є додатковий шар, з елементом, який називається зміщенням. Цей елемент має постійне значення 1 і тільки вихід, входу він не має. За допомогою елемента зміщення можна забезпечити такий режим роботи, при якому певний елемент обробки буде завжди мати вхід, який не дорівнює нулю.

Зв'язки між нейронами одного шару можуть бути збуджуючими або гальмуючими, а зв'язки між шарами у більшості випадків є збуджуючими. Якщо активація поширюється з одного шару до наступного, то мережа є

мережею прямого поширення. У мережі зворотного поширення активація з наступних шарів передається до попередніх.




Рисунок 1.1 – Штучна нейронна мережа

1.3 Принцип дії елементу нейронної мережі

Елементи (нейрони) нейронної мережі працюють за постійною схемою. Перетворюється вхідний зразок i , що представляє собою вектори чисел $i_1, i_2, \dots, i_n$. Щодо ієрархії зв'язків, ваг зв'язків, то функція активації проводить кожен приклад через мережу до появи нового обчисленого значення активації на вихідних нейронах. Вихідні значення можна записати у вигляді числового вектору $O = (O_1, O_2, \dots, O_m)$ або об'єднати у зразок [16].

Спочатку, всі вхідні сигнали обробляються за допомогою вхідної функції. Через зв'язки одного нейрону проходять активації інших нейронів (наприклад, $O_1, O_2, \dots, O_n$). Активації повинні перемогти опір перенесення (вагу зв'язка між двома нейронами). Зазвичай, це звичайне підсумовування входу O_j перемноженого з відповідною вагою W_{ij} :

$$net_i = \sum_j o_j w_{ij}. \quad (1.1)$$

Ця формула є також відомою під назвою правило поширення (функція поширення), оскільки вона описує поширення сигналу через мережу.

Результатом цієї функції передається до так званої функції активації (функції передачі, функції порогового значення). Функція передачі визначає значення активації, яке повинен прийняти елемент обробки в залежності від дійсного вхідного значення.

Значення активації блоку перетворення визначається функцією $a_i(t)$. Найчастіше, вона ідентична нетто-входу ($a_i = net_i$). У загальному випадку, вона залежить від попередньої активації, ряду параметрів і приросту активації (ext_inp_i):

$$a_i(t+1) = F_i[net_i(t+1), ext_inp_i(t+1), a_i(t)]. \quad (1.2)$$

Разом з нетто входом активації, зовнішнім входом і попереднім значенням активації можуть бути визначені нове значення активації a_i нейрону i за допомогою функції активації F .

У якості функції активації застосовується лінійна, порогова або сигмоїдна функція.

Вихідна функція може утворюватися функцією активації. Вихідна функція визначає, який вихідний сигнал множини результатів варто використовувати далі:

$$o_i(t) = f_i[a_i(t)]. \quad (1.3)$$

За правилом, значення виходу встановлюється рівним внутрішньому значенню активації, але у деяких випадках ймовірність того, буде вихід рівним 0 або 1, залежить від значення активації.

Вихідна функція створює конкуренцію між елементами обробки одного шару. Так, наприклад, обирається вихідна функція “winner-take-all”. У цьому випадку тільки той елемент обробки шару передає інформацію далі, чия функція передачі досягає найвищого значення. Всі інші елементи обробки цього шару передають далі нуль. Найчастіше, обмежуються описом елементу обробки наступної функції активації:

$$a_i(t) = F_i[net_i(t)]. \quad (1.4)$$

Тут значення сигналу активації не залежить від попереднього значення і вихідний сигнал дорівнює сигналу активації.

Було розроблено багато типів нейронних мереж. Ці мережі відрізняються за багатьма ознаками, наприклад:

- кількість шарів
- тип навчання
- пряме або зворотне поширення
- прийом двійкових або постійних сигналів.

1.4 Налаштування нейронної мережі

Спочатку обчислюється нетто-вхід нейронів у шарі j :

$$net_j = \sum_i w_{ij} x_i. \quad (1.5)$$

Вихід нейронів у шарі j визначається за формулою:

$$o_j = f(net_j), \quad (1.6)$$

де $f(net)$ є функцією активації (у даному випадку сигмоїдальною).

Далі обчислюється вихід шару k , що відповідає виходу багатошарового перцептрона. Нетто-вхід нейронів у шарі k визначається за формулою:

$$net_k = \sum_j w_{jk} o_j. \quad (1.7)$$

Відповідний вихід складає:

$$o_k = f(net_k). \quad (1.8)$$

У методі зворотного поширення квадратична похибка E розраховується як функція похибки:

$$E = \frac{1}{2} \sum_k (t_k - o_k)^2. \quad (1.9)$$

Множник $\frac{1}{2}$ додається для спрощення подальших розрахунків. Для зменшення похибки зміна ваги Δw_{jk} вибирається пропорційною $-\frac{\partial E}{\partial w_{jk}}$.

Тобто

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}}. \quad (1.10)$$

Тут η представляє собою темп навчання як у навчальному алгоритмі перцептрона.

Частинну похідну $\frac{\partial E}{\partial w_{jk}}$ можна виразити через формулу:

$$\frac{\partial E}{\partial w_{jk}} = \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial w_{jk}}. \quad (1.11)$$

Похідну $\frac{\partial net_k}{\partial w_{jk}}$ можна виразити так:

$$\frac{\partial net_k}{\partial w_{jk}} = \frac{\partial}{\partial w_{jk}} \sum_j w_{jk} o_j. \quad (1.12)$$

Інакше

$$\frac{\partial net_k}{\partial w_{jk}} = \frac{\partial}{\partial w_{jk}} w_{jk} o_j = o_j. \quad (1.13)$$

Визначаємо δ_k як

$$\delta_k = -\frac{\partial E}{\partial net_k}. \quad (1.14)$$

Тоді отримуємо:

$$\Delta w_{jk} = \eta \delta_k o_j. \quad (1.15)$$

Для обчислення виразу $\delta_k = -\frac{\partial E}{\partial net_k}$ здійснюємо перетворення

$$\delta_k = -\frac{\partial E}{\partial net_k} = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial net_k}. \quad (1.16)$$

Виражаємо $\frac{\partial E}{\partial o_k}$ як:

$$\frac{\partial E}{\partial o_k} = \frac{\partial}{\partial o_k} \frac{1}{2} \sum_m (t_m - o_m)^2. \quad (1.17)$$

Інакше

$$\frac{\partial E}{\partial o_k} = \frac{\partial}{\partial o_k} \frac{1}{2} (t_k - o_k)^2 = -(t_k - o_k). \quad (1.18)$$

Другий множник

$$\frac{\partial o_k}{\partial net_k} = f'(net_k). \quad (1.19)$$

Оскільки функція активації є сигмоїдальною, отримуємо:

$$\frac{\partial o_k}{\partial net_k} = f'(net_k) = f(net_k)(1 - f(net_k)) = o_k(1 - o_k). \quad (1.20)$$

Виражаємо δ_k через формулу:

$$\delta_k = (t_k - o_k) o_k (1 - o_k). \quad (1.21)$$

Отримуємо значення зміни ваги:

$$\Delta w_{jk} = \eta (t_k - o_k) o_k (1 - o_k) o_j. \quad (1.22)$$

Зазначені формули є справедливими для ваг нейронів вихідного шару. Аналогічно, для ваг нейронів вхідного шару отримуємо:

$$\begin{aligned}\Delta w_{ij} &= -\eta \frac{\partial E}{\partial w_{ij}} = -\eta \frac{\partial E}{\partial net_j} \frac{\partial net_j}{\partial w_{ij}} = -\eta \frac{\partial E}{\partial net_j} o_i = \\ &= \eta \left(-\frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial net_j} \right) o_i = \eta \left(-\frac{\partial E}{\partial o_j} \right) f'(net_j) o_i = \eta \delta_j o_i\end{aligned}\quad (1.23)$$

$$\begin{aligned}-\frac{\partial E}{\partial o_j} &= -\sum_k \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial o_j} = \sum_k \left(-\frac{\partial E}{\partial net_k} \right) \frac{\partial}{\partial o_j} \sum_m w_{mk} o_m = \\ &= \sum_k \left(-\frac{\partial E}{\partial net_k} \right) w_{jk} = \sum_k \delta_k w_{jk}.\end{aligned}\quad (1.24)$$

Якщо є лише один внутрішній шар, то $O_i = X_i$.

$$\delta_j = f'(net_j) \sum_k \delta_k w_{jk} \quad (1.25)$$

$$f'(net_j) = f(net_j)(1 - f(net_j)) = o_j(1 - o_j) \quad (1.26)$$

$$\delta_j = o_j(1 - o_j) \sum_k \delta_k w_{jk} \quad (1.27)$$

$$\delta_k = (t_k - o_k) o_k (1 - o_k) \quad (1.28)$$

$$\Delta w_{jk} = \eta \delta_k o_j \quad (1.29)$$

$$\delta_j = o_j(1 - o_j) \sum_k \delta_k w_{jk} \quad (1.30)$$

$$\Delta w_{ij} = \eta \delta_j o_i \quad (1.31)$$

1.5 Алгоритм настроювання нейронних мереж

1.5.1 Алгоритм настроювання перцептрона.

Правило настроювання перцептрона можна представити у вигляді алгоритма настроювання корекції помилок одношарових мереж прямого поширення з лінійною пороговою функцією активації (рис.1.2).




Рисунок 1.2 – Одношарова мережа прямого поширення

Алгоритм настроювання перцептрона має такий вигляд

Крок 1. Обирається $\eta > 0$.

Крок 2. Ваги w_i встановлюються випадковим чином, поточна похибка E встановлюється рівною 0, $k := 1$.

Крок 3. Розпочинається навчання; $x := x^k$, $y := y^k$ і обчислюється вихідне значення $o = o(x)$:

$$o_i = \begin{cases} 1 & \text{при } \langle w_i, x \rangle > 0 \\ 0 & \text{при } \langle w_i, x \rangle < 0 \end{cases} \quad (1.32)$$

Крок 4. Ваги змінюються:

$$w_i := w_i + \eta(y_i - o_i)x, \quad i = \overline{1, m}. \quad (1.33)$$

Крок 5. Обчислюється циклова похибка додаванням до похибки E

$$E := E + \frac{1}{2} \|y - o\|^2. \quad (1.34)$$

Крок 6. Якщо $k < K$, тоді $k := k + 1$ і навчання продовжується, відбувається повернення до Кроку 3, інакше – перехід до Кроку 7.

Крок 7. Навчальний цикл завершений. Якщо $E = 0$, то навчання закінчується. Якщо $E > 0$, то E встановлюється рівним 0, $k := 1$ і розпочинається новий навчальний цикл, перехід до Кроку 3.

1.5.2 Дельта-алгоритм настроювання

Одношарова нейронна мережа має n входів і m лінійних виходів, тобто вихід i -го нейрона можна записати як

$$o_i = net_i = \langle w_i, x \rangle = w_{i1}x_1 + \dots + w_{in}x_n, \quad i = \overline{1, m}. \quad (1.35)$$

Припустимо, що ми маємо наступний навчальний набір:

$$\{(x^1, y^1), \dots, (x^K, y^K)\}, \quad (1.36)$$

де $x^k = (x_1^k, \dots, x_n^k)$, $y^k = (y_1^k, \dots, y_n^k)$, $k = \overline{1, K}$.

Основна ідея дельта-навчального правила полягає у визначенні міри роботи системи та у знаходженні способу оптимізувати цю роботу.

У даній мережі можна визначити роботу системи як:

$$E = \sum_{k=1}^K E_k = \frac{1}{2} \sum_{k=1}^K \|y^k - o^k\|^2. \quad (1.37)$$

Тоді

$$E = \frac{1}{2} \sum_{k=1}^K \sum_{i=1}^m (y_i^k - o_i^k)^2 = \frac{1}{2} \sum_{k=1}^K \sum_{i=1}^m (y_i^k - \langle w_i, x^k \rangle)^2, \quad (1.38)$$

де i відповідає виходам, k – парам вхід/вихід, y_i^k – меті певного виходу,

$o_i^k := \langle w_i, x^k \rangle$ – показує дійсний вихід елемента, E – загальна похибка.

Тобто, мета полягає у мінімізації даної функції.

Ми змінюємо ваги пропорційно до похідної від похибки до ваги.

Мінімізація функції квадратичної похибки здійснюється за допомогою наступної ітерації:

$$w_{ij} := w_{ij} - \eta \frac{\partial E_k}{\partial w_{ij}}. \quad (1.39)$$

Частинна похідна від функції похибки E_k за w_{ij} :

$$\frac{\partial E_k}{\partial w_{ij}} = \frac{\partial E_k}{\partial net_i} \frac{\partial net_i}{\partial w_{ij}} = -(y_i - o_i)x_j, \quad (1.40)$$

де $net_i = w_{i1}x_1 + \dots + w_{in}x_n$.

Тобто

$$w_{ij} := w_{ij} + \eta(y_i - o_i)x_j. \quad (1.41)$$

Міра похибки дельта на i -му нейроні визначається за формулою:

$$\delta_i = \frac{\partial E_k}{\partial net_i} = (y_i - o_i). \quad (1.42)$$

Для лінійних виходів дельта є різницею між необхідним і обчисленим значеннями виході на i -му нейроні.

Дельта-навчальне правило можна записати як

$$w_i := w_i + \eta(y_i - o_i)x. \quad (1.43)$$

Якщо є лише один вихід, формула приймає наступний вигляд:

$$w := w - \eta(y - o)x = w + \eta\delta x \quad (1.44)$$

Крок 1. Обираються $\eta > 0$ і $E_{\max} > 0$.

Крок 2. Ваги w_i встановлюються випадковим чином, поточна похибка E встановлюється рівною 0, $k := 1$.

Крок 3. Розпочинається навчання; $x := x^k$, $y := y^k$ і обчислюється вихідне значення $O = (o_1, \dots, o_m)^T$:

$$o_i = (\langle w_i, x \rangle) = w_i^T x. \quad (1.45)$$

Крок 4. Ваги змінюються:

$$w_{ij} := w_{ij} + \eta(y_i - o_i)x_j, \quad i = \overline{1, m}. \quad (1.46)$$

Крок 5. Обчислюється циклова похибка додаванням до похибки E

$$E := E + \frac{1}{2} \|y - o\|^2. \quad (1.47)$$

Крок 6. Якщо $k < K$, тоді $k := k + 1$ і навчання продовжується, відбувається повернення до Кроку 3, інакше – перехід до Кроку 7.

Крок 7. Навчальний цикл завершений. Якщо $E < E_{\max}$, то навчання закінчується. Якщо $E > E_{\max}$, то E встановлюється рівним 0, і розпочинається новий навчальний цикл, перехід до Кроку 3.

1.5.3 Алгоритм настроювання «Переможець отримує все»

Мережа Кохонена класифікує вхідні вектори на m категорій, відповідно до кластерів, визначених на навчальному наборі [18]:

$$\{x^1, \dots, x^K\}.$$

У навчальному алгоритмі набір з m вагових векторів розглядається як вектори змінних, які необхідно вивчити. Необхідною є нормалізація всіх вагових векторів.

Критерієм наближення ваг є вибір w_r , так що

$$\|x - w_r\| = \min_{i=1, \dots, m} \|x - w_i\|. \quad (1.48)$$

Індекс i показує номер “переможного” нейрона відповідно до вектора w_r , що є найближчою апроксимацією поточного входу x .

Використавши рівняння:

$$\begin{aligned} \|x - w_r\|^2 &= \langle x - w_i, x - w_i \rangle = \langle x, x \rangle - 2\langle w_i, x \rangle + \langle w_i, w_i \rangle = \\ &= \|x\|^2 - 2\langle w, x \rangle + \|w_i\|^2 = \|x\|^2 - 2\langle w_i, x \rangle + 1 \end{aligned} \quad (1.49)$$

можна зробити висновок, що пошук мінімуму з m відстаней відповідає знаходженню максимуму з m скалярних добутків:

$$\langle w_r, x \rangle = \max_{i=1, \dots, m} \langle w_i, x \rangle. \quad (1.50)$$

Враховуючи, що

$$\|w_i\| = 1, \quad \forall i \in \{1, \dots, m\}, \quad (1.51)$$

скалярний добуток $\langle w_i, x \rangle$ є проекцією x у напрямку w_i .

Після ідентифікації “переможного” нейрона, його вага змінюється так, що відстань $\|x - w_r\|$ зменшується у поточному навчальному кроці.

$$\begin{aligned}
\frac{d\|x-w\|^2}{dw} &= \frac{d\langle x-w, x-w \rangle}{dw} = \frac{d(\langle x, x \rangle - 2\langle w, x \rangle + \langle w, w \rangle)}{dw} = \\
&= \frac{d\langle x, x \rangle}{dw} - 2\frac{d\langle w, x \rangle}{dw} + \frac{d\langle w, w \rangle}{dw} = \\
&= 0 - 2\frac{d(w_1x_1 + \dots + w_nx_n)}{dw} + \frac{d(w_1^2 + \dots + w_n^2)}{dw} = \\
&= -2\left(\frac{\partial}{\partial w_1}[w_1x_1 + \dots + w_nx_n], \dots, \frac{\partial}{\partial w_n}[w_1x_1 + \dots + w_nx_n]\right)^T + \\
&\quad + \left(\frac{\partial}{\partial w_1}[w_1^2 + \dots + w_n^2], \dots, \frac{\partial}{\partial w_n}[w_1^2 + \dots + w_n^2]\right)^T = \\
&= -2(x_1, \dots, x_n)^T + 2(w_1, \dots, w_n)^T = -2(x-w). \tag{1.52}
\end{aligned}$$

Таким чином, отримуємо:

$$w_r := w_r + \eta(x - w_r). \tag{1.53}$$

Крок 1. $w_r := w_r + \eta(x - w_r)$, $o_r := 1$, (де r – “переможний” нейрон).

Крок 2. $w_r := \frac{w_r}{\|w_r\|}$ (нормалізація).

Крок 3. $w_i := w_i$, $o_i := 0$ $i \neq r$ (“переможені” не задіяні).

2 ПЛАНУВАННЯ ТЕЛЕКОМУНІКАЦІЙНИХ СИСТЕМ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ

2.1 Основні напрями застосування штучних нейронних мереж в телекомунікаційних системах

Нейрокомп'ютери є неефективними для вирішення так званих неформалізованих і погано формалізованих завдань; це означає, що вони повинні включати в свої алгоритми навчання на реальному експериментальному матеріалі. Такими завданнями в першу чергу є розпізнавання образів. Нейронні інформаційні технології постійно розвиваються [9]. Вони все частіше використовуються в завданнях з яскраво вираженим природним паралелізмом, таких як обробка сигналів, зображень і так далі.

Нейронні системи використовуються в чотирьох основних сферах телекомунікацій [3]:

- управління трафіком;
- комутація;
- маршрутизація;
- динамічний розподіл каналів.

Рішення майже будь-якої задачі в нейромережевому логічному базисі вимагає наявності наступних етапів.

- формування вхідних і дійсних вихідних сигналів НМ;
- формування бажаних вихідних сигналу НМ;
- формування сигналів помилки та функціонала оптимізації;
- формування структури НМ, адекватної практичної задачі;
- розроблення алгоритму налаштування НМ, еквівалентного процесу розв'язання задачі в нейромережевому логічному базисі;
- проведення досліджень процесу розв'язання задачі.

Так, нейронна мережа може керувати високошвидкісними комутаційними

мережами з пакетною передачею в асинхронному режимі. Логічним пристроєм є комутатор цієї мережі, який керує комутацією пакетів під час передачі даних, зображень і мови. Він отримує N сигналів на вхід і відтворює ці сигнали в будь-якому представленому порядку на виході.

Нейронні комп'ютери можуть імітувати сотні мільйонів зв'язків. Таким чином, можна створити комутатори з нейромережовим управлінням, які можуть підтримувати сотні каналів.

Постановка і рішення задачі маршрутизації в нейромережовому базисі мало відрізняються від постановки і рішення задачі розподілу каналів у системах мобільного зв'язку. зміна лише в структурі коміркової мережі та кількості комутованих вузлів [3].

На етапі проєктування таких систем можна використовувати алгоритм прогнозування напруженості поля нейромережі, подібний до алгоритму розподілу каналів у системах мобільного зв'язку.

Крім сфер використання нейронних мереж у телекомунікаційних системах, є перспективним використання алгоритмів нейронних мереж для завдань кодування та декодування даних. У цьому випадку використовується тришаровий перцептрон з однаковим кількістю елементів у вхідному та вихідному шарах і значно меншим кількістю елементів у прихованому шарі. Коли навчання проводиться таким чином, що на виході відтворюється той самий вектор, який подається на вхідний шар, перцептрон автоматично стискає інформацію. Це відбувається, коли зображення кожного вектора на елементах прихованого шару значно коротше, ніж довжина вектора, який подається на вхід. Таким чином, передача заздалегідь стислої інформації по лінії зв'язку зменшує кількість каналів, необхідних для цього. Це реалізується таким чином. На одному кінці лінії розташовують вхідний і прихований шари перцептрона. Короткі вектори, які є продуктами роботи прихованого шару, подаються в канал. Використовуючи копію прихованого шару та вихідного шару на іншому кінці лінії, можна відтворити початковий вектор на виході останнього шару.

Таким чином, область використання штучних НМ у телекомунікаційних системах постійно зростає. Поява на ринку недорогих багатофункціональних і спеціалізованих нейрочипів і нейрокомп'ютерів в даний час прискорить наступний етап розвитку телекомунікаційних систем: поява інтелектуальних телекомунікаційних систем.

2.2 Використання нейронних мереж при плануванні мереж мобільного зв'язку

Етап територіального планування є одним із основних етапів проектування мереж мобільного зв'язку (СМЗ). У цьому етапі вибирається конфігурація мережі, місця розміщення базових станцій (БС), розраховується можливість забезпечити покриття необхідної зони обслуговування відповідно до певної якості зв'язку та визначається місткість мережі, необхідна для обслуговування абонентського навантаження з із заданою інтенсивністю втрат. Характеристики стандартів СМЗ, параметри прийомо-передавального устаткування та антен, умови розповсюдження радіохвиль, середнє навантаження на одного абонента, необхідна напруженість поля корисного сигналу та допустиме значення вірогідності блокування викликів використовуються як технічні основи планування [12].

Таким чином, прогнозування напруженості поля в зоні обслуговування БС є частиною планування сучасних систем мобільного зв'язку. Дві стратегії прогнозування напруженості електричного поля є найпоширенішими. Незважаючи на те, що обидві моделі мають недоліки, перша базується на вимірюваних емпіричних формулах, а друга на аналітичних моделях, які використовують теорію дифракції [13].

Емпіричний метод прогнозування напруженості поля на основі нейронних мереж дозволяє усунути деякі недоліки. В цьому випадку НМ використовує наявні значення ряду точок для апроксимації функції. Ці точки в НМ є повчальними множинами. Приведена до дискретної форми і нормалізована інформація про покриття земної поверхні, робочу частоту,

висоту антен і інші характеристики подається крім відомих значень середньої напруженості електричного поля на вхід НМ. Параметри НМ регулюються таким чином, щоб мінімізувати погрішність значення формованого на виході НМ для будь-якої вхідної комбінації. У певній точці вихід мережі може бути визначений за допомогою нормалізованої напруженості поля, втрат на трасі та інших методів. Розповсюдження радіохвиль у вільному просторі значною мірою визначає динамічний діапазон напруженості поля. Можна обчислити аналітично внесок останнього та виключити його з процесу навчання, щоб підвищити точність апроксимації середнього значення напруженості поля. Наступні приклади демонструють результати використання НМ для прогнозування напруженості поля.

У першому випадку використовується широко відома формула Хата [14], яка показує емпіричну відображення втрат при розповсюдженні в міських районах:

$$L_p(\partial B) = 69,55 + 26,16 \log f(MГц) - 13,82 \log h_{BC}(м) - \\ - \{1,1 \log f(MГц) - 0,7\} h_M(м) + \{1,56 \log f(MГц) - 0,8\} + \\ + \{44,9 - 6,55 \log h_{BC}(м)\} \log d(км) \quad (2.1)$$

Діапазон частот становить $f = 150 \dots 1500 MГц$, висоти розташування базових станцій (БС) $h_{BC} = 30 \dots 200 м$, висоти розташування мобільних станцій $h_M = 1 \dots 10 м$, а дальність $d = 1 \dots 20 км$. Для апроксимації формули використовується нейронна мережа, що має чотири нейрони у вхідному шарі і десять нейронів в прихованому шарі. Вихід модельованої мережі визначає втрати сигналу при поширенні L_p .

Застосування НМ для прогнозування напруженості поля можна пояснити рис. 2.1.

Так, нормалізована середня помилка моделювання M визначається за формулою:

$$M = \frac{\frac{1}{N} \sum_{i=1}^N |L_{pi} - L_{pneti}|}{L_{p\max} - L_{p\min}}, \quad (2.2)$$

де L_{pneti} – втрати на трасі, які отримують з виходу НМ.

Після навчання протягом 1200 циклів на навчальній вибірці з 2160 точок середнє відхилення склало приблизно 0,18 %. Для точок тестування, які були обрані між навчальними точками в даному параметричному просторі, відхилення збільшилося до 0,24 %, при цьому $M_{\max} \leq 1,23$ %. Динамічний діапазон у цьому експерименті складає $L_{p\max} - L_{p\min} = 100$ дБ.

У моделі використовувалася НМ, що містить 11 нейронів у вхідному шарі та 8 нейронів у прихованому шарі, щоб апроксимувати нормалізовану напруженість поля E/E_0 на профілі траси.

Після навчання протягом 1200 циклів на навчальній вибірці з 2160 точок середнє відхилення склало приблизно 0,18 %. Для точок тестування, які були обрані між навчальними точками в даному параметричному просторі, відхилення збільшилося до 0,24 %, при цьому $M_{\max} \leq 1,23$ %. Динамічний діапазон у цьому експерименті складає $L_{p\max} - L_{p\min} = 100$ дБ.

У моделі використовувалася НМ, що містить 11 нейронів у вхідному шарі та 8 нейронів у прихованому шарі, щоб апроксимувати нормалізовану напруженість поля E/E_0 на профілі траси.

Після навчання протягом 1200 циклів на навчальній вибірці з 2160 точок середнє відхилення склало приблизно 0,18 %. Для точок тестування, які були обрані між навчальними точками в даному параметричному просторі, відхилення збільшилося до 0,24 %, при цьому $M_{\max} \leq 1,23$ %. Динамічний діапазон у цьому експерименті складає $L_{p\max} - L_{p\min} = 100$ дБ.

У моделі використовувалася НМ, що містить 11 нейронів у вхідному шарі та 8 нейронів у прихованому шарі, щоб апроксимувати нормалізовану напруженість поля E/E_0 на профілі траси.




Рисунок 2.1– Застосування НМ для прогнозування напруженості поля

Вибірка топографічних даних проводилася в десяти точках, що забезпечували вхідні дані для десяти елементів. Величина вибірки може бути різною. Дванадцять вхідних повідомлень стосуються неї. Після цього процесу вибірка адаптується до довжини профілю траси. Моделювали різні комбінації висот і кутів ділянок перешкод у модельному «клинні». Середнє відхилення було знайдено за допомогою формули (2.2) і після 20 000 циклів навчання склало 0,3%. У обох випадках було використано алгоритм зворотного розповсюдження для навчання. На практиці для навчання НМ можуть використовуватися як результати аналітичних розрахунків, так і результати поточних і попередніх вимірювань. Після завершення навчання тестові приклади мали максимальне відхилення 6%.

Таким чином, підтверджується можливість використання НМ для прогнозування напруженості поля на етапі планування сучасних систем рухомого зв'язку та в інших ситуаціях. Розглянуті нейромережеві моделі можуть удосконалюватися, щоб підвищити точність прогнозування. Так, можна більш повно враховувати всю наявну картографічну та земну інформацію.

2.3 Використання нейронних мереж для розподілення каналів в коміркових мережах

Етапи проектування СМЗ включають вирішення задачі призначення частоти та прогнозування напруженості поля. При вирішенні цієї проблеми частоти повинні визначатися в межах обмежень, визначених матрицею електромагнітної сумісності (ЕМС).

При цьому необхідно розглянути такі обмеження:

- обмеження через завади за сусіднім каналом;
- обмеження через завади, які обумовлюються сумісним розташуванням;
- обмеження по числу частотних діапазонів для кожної комірки.

Обмеження ЕМС в n -комірковій мережі можна описати за допомогою матриці $n \times n$, яку ще називають матрицею сумісності C . Отже, кожен недіагональний елемент c_{ij} матриці C відповідає відстані мінімального рознесення в частотній області між частотою i -тої комірки та частотою j -тої комірки. Обмеження через завади по сусідньому каналу записуються так $c_{ij} = 1$. Запис $c_{ij} = 2$ означає, що частоти, які є суміжними в частотній області не можуть надаватися суміжним комірками. Значення $c_{ij} = 0$ означає, що коміркам i та j дозволено використовувати одну і ту ж саму частоту. Кожен діагональний елемент c_{ij} означає відстань мінімального рознесення між двома частотами, присвоєними i -й комірці. В той же час, виконання вище наведених обмежень c_{ij} повинно завжди задовольняти обмеженню $c_{ij} \geq 1$.

Вимоги, що висуваються до частотного каналу кожної комірки n -коміркової мережі, можна описати за допомогою n -елементного вектора, який також називається вектором попиту D . Елемент d_i вектора D відповідає числу частот, які привласнюються i -й комірі. Позначаємо як f_{ik} k -у частоту, яка привласнюється i -й комірі, при цьому обмеження по ЕМС:

$$|f_{ik} - f_{jl}| \geq c_{ij} \quad (2.3)$$

для $i=1, \dots, n$, $j=1, \dots, n$, $k=1, \dots, d_i$, $l=1, \dots, d_j$, окрім $i=j$, $k=l$.

У якості прикладу, наведемо рішення задачі розподілу каналів для чотирьохкоміркової мережі (рис.2.2в). На рис. 2.2а подана матриця сумісності C і вектор попиту D . На рис. 2.2б зображена топологія мережі, що відповідає матриці сумісності C .

Задача розподілу каналів пов'язана з математичними завданнями з розфарбовування графів. Збільшення кількості базових станцій збільшує час, необхідний для знаходження рішення.

Теорія фарбування графів стверджує, що можна знайти нижню межу загального використаного частотного ресурсу, знайшовши так званий максимально повний підграф. Добре відомі алгоритми, спрямовані на задоволення всіх вимог з урахуванням заданих обмежень, одночасно мінімізуючи частотний ресурс. Рекомендується приймати рішення, якщо загальне число робочих частот близьке до певної нижньої межі. Якщо попит перевищує частотний ресурс, виділений мережі мобільного зв'язку, то розміри комірок слід зменшити, щоб мережа могла працювати локально з більшим рівнем повторного використання частот. Для початку розглянемо алгоритм рішення задачі розподілу частотних каналів, заснований на штучній матриці розподілу.




Рисунок 2.2 – Розподіл частотних каналів
для чотирьохкоміркової мережі

Хопфілд і Танк вперше запропонували модель НМ для вирішення комбінаторного завдання оптимізації. Рішення проблеми полягає в мінімізації функції енергії, яка була створена. Незважаючи на критику щодо стійкості та якості рішень таких моделей, відомо багато успішних застосувань НМ Хопфілда.

Кунц вперше запропонував модель НМ Хопфілда для вирішення проблеми розподілу каналів у комірковій мережі в 1991 році. Кунц встановив межу $C_{ij} = 2$, щоб обмежити мінімальну відстань між двома привласненими частотами та коміркою, не враховуючи обмеження через завади на сусідньому каналі. Але модель НМ Кунца має деякі недоліки. Зазвичай він використовує «повільну» функцію сигмоїдальної активації. Крім того, у використовуваній функції енергії не враховуються особливості задачі, яка має бути вирішена. Ці недоліки моделі Кунца перешкоджають її використанню в реальному житті для вирішення проблеми розподілу каналів у комірковій мережі.

Запропонована модель нейронної мережі використовує модифіковану функцію енергії та гістерезисну активаційну функцію. Усі ці обмеження

розглядаються, щоб визначити використану функцію енергії E . Відповідно, вона описує поточний стан НМ, що забезпечує значно швидшу збіжність рішення, ніж модель Кунца.

Задати зміни входу i -го нейрона можна за допомогою власних похідних обчислювальної функції енергії $E(V_1, \dots, V_n)$, яку також називають рівнянням енергії

$$\frac{dU_i}{dt} = \frac{\partial E(V_1, \dots, V_n)}{\partial V_i} \quad (2.4)$$

де U_i і V_i – вхід і вихід i -го нейрона відповідно,

n – число нейронів використовуваних для вирішення задачі.

На рис. 2.3б показано результати нейронів, які використовувалися для вирішення задачі розподілу каналів у чотирьохстільниковій мережі, і їх збіжність до рішення. Виходи нейронів представлені у вигляді матриці станів. Для вирішення цієї задачі потрібно мінімум 4×11 нейронів.

Це зрозуміло з матриці сумісності C та вектора попиту D , поданих на рис. 2.3а ($c_{ij} = 5$, $d_i = 3$, отже 4-комірка вимагає мінімум $11(1+5 \times 2)$ частот).

Перед моделюванням необхідно визначити число необхідних частот, а отже і число нейронів необхідне для вирішення задачі. Для задач великої розмірності m може бути визначено перемножуванням c_{ij} і максимального значення з вектора попиту. Якщо задача не вирішується за допомогою визначеного таким чином значення m , його необхідно збільшували до тих пір, поки рішення не буде знайдено.

V_{ij}		частота j										
		1	2	3	4	5	6	7	8	9	10	11
комірка i	1											
	2											
	3											
	4											

Рисунок 2.3 – Подання виходів 4×11 нейронів, використовуваних

для рішення задачі розподілу каналів у чотирьохкомірковій мережі

Вихід ij -го нейрона V_{ij} показує чи привласнюється j -та частота i -й комірці. Якщо вихід є ненульовим ($V_{ij}=1$), то це означає, що j -та частота надається i -й комірці. Якщо вихід є нульовим ($V_{ij}=0$), то це означає, що j -та частота не надається i -й комірці. На рис. 2.3, де подано рішення задачі, чорні квадрати позначають ненульовий вихід, а білі квадрати – нульовий.

Рівняння руху ij -го нейрона V_{ij} для n -коміркованої та m -частотної задачі задається так:

$$\frac{dU_{ij}}{dt} = -A \left(\sum_{q=1}^m V_{iq} - d_i \right) - B \left(\sum_{\substack{q=j-(c_n-1) \\ q \neq j \\ 1 \leq q \leq m}}^{j+(c_n-1)} V_{iq} + \sum_{\substack{p=1 \\ p \neq i}}^n \sum_{\substack{q=j-(c_{ip}-1) \\ 1 \leq q \leq m \\ c_{ip} > 0}}^{j+(c_{ip}-1)} V_{pq} \right) \quad (2.5)$$

Перший член виразу (2.5) A -член вказує, що d_i нейронів, котрі оброблюють стани виділених для i -ї комірки m частот, мають ненульовий вихід у випадку, коли відповідні частоти надаються i -й комірці. Другий член виразу (2.5) B -член означає, що ij -й нейрон немає ненульовий вихід у випадку, коли надання j - частоти i -й комірці порушує такі обмеження:

- у випадку, коли q -та частота у межах відстані C_{ij} від j -ої частоти привласнюється i -й комірці ($|j-q| < C_{ij}$), то j -та частота не має надаватися цій

комірці, тобто вираз $\sum_{\substack{q=j-(c_n-1) \\ q \neq j \\ 1 \leq q \leq m}}^{j+(c_n-1)} V_{iq}$ має ненульовий вихід, якщо привласнення j -ої

частоти i -й комірці порушить обмеження за числом частот для кожної комірки;

- якщо мають місце обмеження через завади по сусідньому каналу і через завади, обумовлені сумісним розташуванням, у випадку, коли q -та частота в межах відстані C_{ip} від j -ої частоти ($|j-q| < C_{ip}$) надається p -й комірці, то для $C_{ip} > 0$ та $p \neq i$ j -та частота не повинна надаватися i -й комірці. Тобто, вираз

$\sum_{\substack{p=1 \\ p \neq i}}^n \sum_{\substack{q=j-(c_{ip}-1) \\ 1 \leq q \leq m \\ c_{ip} > 0}}^{j+(c_{ip}-1)} V_{pq}$ має ненульовий вихід, у випадку надання j -ої частоти i -й

комірці порушується обмеження через завади по сусідньому каналу і обмеження через завади, обумовлені сумісним розташуванням.

Коефіцієнтами A та B є постійними ($A=B=1$).

Таким чином, для завдання розподілу каналів в комірковій мережі функція енергії задається так:

$$E = \frac{A}{2} \sum_{i=1}^n \left(\sum_{q=1}^m V_{iq} - d_i \right)^2 - B \sum_{i=1}^n \sum_{j=1}^m \left(\sum_{\substack{q=j-(c_n-1) \\ q \neq j \\ 1 \leq q \leq m}}^{j+(c_n-1)} V_{iq} + \sum_{\substack{p=1 \\ p \neq i}}^n \sum_{\substack{q=j-(c_{ip}-1) \\ 1 \leq q \leq m \\ c_{ip} > 0}}^{j+(c_{ip}-1)} V_{pq} \right) V_{ij} \quad (2.6)$$

Встановлено, що для використовуваної моделі НМ гарантується знаходження лише локального мінімуму. Для збільшення швидкості збіжності алгоритму та частоти знаходження глобального мінімуму додано наступні доповнення функції енергії.

І. Для того, щоб обмежити між двома значеннями A -член, модифікуємо його таким чином:

$$-Af \left(\sum_{q=1}^m V_{iq} - d_i \right), \quad (2.7)$$

де $f(x) = A_{\max}$ при $x > A_{\max}$; $f(x) = A_{\min}$ при $x < A_{\min}$; $f(x) = x$ в інших випадках.

Таким чином, $A_{\max}$ та $A_{\min}$ є відповідно верхньою і нижньою межею A -члена відповідно.

2. Якщо $(t \bmod T) < W$, тоді B -член рівняння енергії може набувати дві форми:

$$-B \left(\sum_{\substack{q=j-(c_n-1) \\ q \neq j \\ 1 \leq q \leq m}}^{j+(c_n-1)} V_{iq} + \sum_{\substack{p=1 \\ p \neq i}}^n \sum_{\substack{q=j-(c_{ip}-1) \\ 1 \leq q \leq m \\ c_{ip} > 0}}^{j+(c_{ip}-1)} V_{pq} \right) V_{ij}, \quad (2.8)$$

інакше

$$-B \left(\sum_{\substack{q=j-(c_n-1) \\ q \neq j \\ 1 \leq q \leq m}}^{j+(c_n-1)} V_{iq} + \sum_{\substack{p=1 \\ p \neq i}}^n \sum_{\substack{q=j-(c_{ip}-1) \\ 1 \leq q \leq m \\ c_{ip} > 0}}^{j+(c_{ip}-1)} V_{pq} \right), \quad (2.9)$$

де t – число ітераційних кроків,

T і W – постійні параметри.

3. Додаємо наступний вираз до рівняння руху:

$$+Ch \left(\sum_{q=1}^m V_{iq} - d_i \right) \cdot (1 - V_{ij}) \quad (2.10)$$

де $h(x)=1$ якщо $x < 0$ і $h(x)=0$ якщо $x \geq 0$.

На кожному ітераційному кроці вибирається значення C так, аби усунути ситуацію за якої два чи більше оброблювальних нейрона мають одні і ті ж самі стани. C -член означає, що ij -й оброблювальний нейрон має ненульовий вихід, якщо менш ніж d_i нейронів для i -ї комірки мають ненульовий вихід і $V_{ij} = 0$.

4. Вхід оброблювального нейрона обмежений двома значеннями:

$$U_{ij} = U_{\max}, \text{ при } U_{ij} > U_{\max}; \quad (2.11)$$

$$U_{ij} = U_{\min}, \text{ при } U_{ij} < U_{\min}, \quad (2.12)$$

де $U_{\max}$ і $U_{\min}$ – постійні верхня і нижня межі вхідного значення величини U_{ij} відповідно.

Алгоритм розподілу каналів в мережі мобільного зв'язку, що базується на використанні рівняння руху (3.5), функції енергії (3.6) та її доповнень, можна описаний наступним чином.

1 крок. Використовувані значення коефіцієнтів і параметрів $A, B, C, t, T, w, U_{\max}, U_{\min}, T_{\max}, UTL, LTR$ встановлюються емпіричним шляхом.

2 крок. Початкові значення входу $U_{ij}(t)$ рандомізуємо для $i=1, \dots, n$ та $j=1, \dots, m$ між 0 і $U_{\min}$. Потім початкові значення виходу $V_{ij}(t)$ для $i=1, \dots, n$ та $j=1, \dots, m$ призначаються рівними нулю.

3 крок. Обчислюємо зміну входу $\Delta U_{ij}(t)$ використовуючи рівняння (3.14) при $(t \bmod T) < w$

$$\begin{aligned} \Delta U_{ij}(t) = & -Af \left(\sum_{q=1}^m V_{iq} - d_i \right) - B \left(\sum_{\substack{q=j-(c_n-1) \\ q \neq j \\ 1 \leq q \leq m}}^{j+(c_n-1)} V_{iq}(t) + \sum_{\substack{p=1 \\ p \neq i}}^n \sum_{\substack{q=j-(c_{ip}-1) \\ 1 \leq q \leq m \\ c_{ip} > 0}}^{j+(c_{ip}-1)} V_{pq}(t) \right) V_{ij}(t) + \\ & + Ch \left(\sum_{q=1}^m V_{iq}(t) - d_i \right) \cdot (1 - V_{ij}(t)), \end{aligned} \quad (2.13)$$

інакше:

$$\begin{aligned} \Delta U_{ij}(t) = & -Af \left(\sum_{q=1}^m V_{iq} - d_i \right) - B \left(\sum_{\substack{q=j-(c_n-1) \\ q \neq j \\ 1 \leq q \leq m}}^{j+(c_n-1)} V_{iq}(t) + \sum_{\substack{p=1 \\ p \neq i}}^n \sum_{\substack{q=j-(c_{ip}-1) \\ 1 \leq q \leq m \\ c_{ip} > 0}}^{j+(c_{ip}-1)} V_{pq}(t) \right) + \\ & + Ch \left(\sum_{q=1}^m V_{iq}(t) - d_i \right) \cdot (1 - V_{ij}(t)), \end{aligned} \quad (2.14)$$

4 крок. Значення входу оновлюється

$$U_{ij}(t+1) = U_{ij}(t) + \Delta U_{ij}(t). \quad (2.15)$$

5 крок. Модифікуємо значення входу:

$$U_{ij}(t+1) = U_{\max}, \text{ якщо } U_{ij}(t+1) > U_{\max}; \quad (2.16)$$

$$U_{ij}(t+1) = U_{\min}, \text{ якщо } U_{ij}(t+1) < U_{\min} \quad (2.17)$$

6 крок. Оновлюємо вихід оброблювального нейрона $V_{ij}(t+1)$ використовуючи гістерезисну активаційну функцію,:

$$V_{ij}(t+1) = 1, \text{ якщо } V_{ij}(t+1) > UTR,$$

$$V_{ij}(t+1) = 0, \text{ якщо } V_{ij}(t+1) < LTR \quad (2.18)$$

у інших випадках не змінюється.

Тут UTR , LTR – верхня і нижня точки обходу відповідно.

7 крок. Перевіряється умови закінчення роботи алгоритму.

Якщо

$$\left(\sum_{q=1}^m V_{iq} - d_i \right) = 0 \text{ та } V_{ij}(t) = 1 \text{ та } \left(\sum_{\substack{q=j-(c_n-1) \\ q \neq j \\ 1 \leq q \leq m}}^{j+(c_n-1)} V_{iq} + \sum_{\substack{p=1 \\ p \neq i}}^n \sum_{\substack{q=j-(c_{ip}-1) \\ 1 \leq q \leq m \\ c_{ip} > 0}}^{j+(c_{ip}-1)} V_{pq} \right) = 0 \quad (2.19)$$

для $i=1, \dots, n$ та $\exists j \in \{1, \dots, m\}$ або $t = T_{\max}$, то алгоритм закінчує роботу. У інших випадках збільшуємо на одиницю значення t і повертаємося на крок 2.

Можна зафіксувати призначення частот для однієї або кількох комірок, які мають найбільше необхідних частот, щоб скоротити час збіжності під час вирішення великої кількості задач. Наприклад, як показано на рис. 3.2а, оскільки четверта комірка містить найбільший елемент у векторі попиту, логічно фіксувати привласнення частот цій комірці. Крім того, у випадках, коли мережа розширюється, фіксоване призначення частоти може бути апріорно задане, щоб запобігти збігам з частотами інших мереж.

Модифікація розглянутого алгоритму може бути спрямована на врахування великої кількості обмежень, які можна задати матрицею ЕМС [2].

3 ПРОГНОЗУВАННЯ У ТЕЛЕКОМУНІКАЦІЙНИХ СИСТЕМАХ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ

3.1 Задача прогнозування характеристик поширення сигналу

Розвиток мереж мобільного зв'язку вимагає пошуку найкращого способу прогнозування втрат електромагнітних хвиль, розрахунку бюджету радіоканалу та визначення дальності зв'язку. Втрати сигналу у вільному просторі, відбиття та ефект багатопробевого поширення, дифракція або ефект затінення, проникнення сигналу в приміщення та автомобілі, поширення сигналу над водою та через рослини, інтерференція та інші фактори. Найвідоміші напівемпіричні моделі, такі як Окамура-Хата, COST231-Hata, Уолфіш-Ікегамі, Кся-Бертоні, Альсбрука та Парсон [1], використовуються для визначення втрат сигналу при його поширенні в мобільних засобах зв'язку.

Для прогнозування втрат при поширенні радіохвиль також використовуються статистичні методи; ці методи класифікують зміну рівня прийнятого сигналу залежно від руху мобільної станції по відношенню до базової станції [2]. Штучні нейронні мережі успішно вирішують проблеми прогнозування в багатьох сферах. Наприклад, для прогнозування вартості валюти для визначення ціни продукту в промисловому виробництві [3].

Нейронні мережі можна класифікувати за різними ознаками, наприклад багатшаровості, затримки, зворотного зв'язку, самоорганізованості тощо. Нейронні мережі бувають різних видів, щоб вирішувати різні задачі. Нейронні мережі з часовою затримкою використовуються для вирішення задач, пов'язаних із відновленням форми часової функції, наприклад форми сигналу, а самоорганізовані нейронні мережі використовуються для вирішення задач, пов'язаних із розділенням даних за класами. Нейронна мережа з прямим поширенням сигналу, також відома як нейронна мережа з прямим поширенням сигналу, найкраще підходить для прогнозування, оскільки це багатшарова нейронна мережа, яка не має зворотних зв'язків і затримок, і має здатність

створювати функціональний зв'язок між початковими та прогнозованими даними [4].

Загальний вигляд нейронної мережі прямого поширення подано на рис.3.1, де у вхідному, прихованому і вихідному шарах розміщено по N , M і K нейронів відповідно, IW – це ваги для сигналу з вхідного шару, LW – це ваги для сигналу з прихованого шару, в той час як B – це ваговий коефіцієнт для одиничного сигналу, який дозволяє регулювати роботу нейрона з вхідними сигналами, X та Y – вхідний і вихідний вектори відповідно.




Рисунок 3.1 – Нейронна мережа прямого поширення

З достатньою кількістю нейронів прихованого шару дана нейронна мережа може точно відтворювати функції з кінцевим числом точок розриву.

На основі наведених моделей створені навчальні вибірки за допомогою мети навчання нейронної мережі. Нейронні мережі з прямим поширенням сигналу з різними прихованими шарами та нейронами були протестовані, щоб визначити найкращу конфігурацію. Обрана оптимальна тришарова нейронна мережа з 9 нейронами в першому шарі, 8 нейронами в другому шарі та 1 нейроном у третьому шарі, яка вносить мінімальну помилку в прогнозуванні

прогнозованих параметрів. Основним критерієм оцінки якості роботи нейронної мережі є помилка навчання нейронної мережі, яка представляє розбіжність між цільовим і вихідним значенням.

Значення помилки розраховано для кожного елемента вибірки. Дослідження роботи нейронної мережі було проведено на основі вибірки помилок. Були створені побічні графіки щільності ймовірності, обрана функція розподілу щільності ймовірності, яка відповідала отриманим вибіркам (рис. 4.2), і були оцінені параметри обраної функції розподілу.




Рисунок 3.2 – Статистична оцінка помилки прогнозування нейронної мережі при роботі з моделлю Окамура-Хата

Обираємо розподіл t розподіл, він подібний до розподілу Стюдента і

$$f(x) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sigma\sqrt{\nu\pi}\Gamma\left(\frac{\nu}{2}\right)} \left[\frac{\nu + \left(\frac{x-\mu}{\sigma}\right)^2}{\nu} \right]^{-\left(\frac{\nu+1}{2}\right)}, \quad (3.1)$$

де μ – параметр розташування,

σ – параметр масштабу,

ν – параметр форми.

Якщо змінна x має функцію розподілу t параметрами μ , σ і ν , то змінна $(x-\mu)/\sigma$ відповідає функції розподілу Стюдента зі ступенем свободи ν .

Була оцінена точність апроксимації розподілу помилки за допомогою t -розподілу. В табл.3.1 зведені параметри оцінки та їх значення.

Таблиця 3.1 – Оцінка параметрів функцій розподілу

Модель	Параметр	Значення
Альсбрука-Парсона	μ	-0,039315
	σ	0,514419
	ν	2,30768
Кся-Бертони	μ	-0,00754698
	σ	0,166953
	ν	3,6536
Окамура-Хата	μ	-0,00222371
	σ	0,243982
	ν	2,77659
Уолфиша-Икегами	μ	-0,0621849
	σ	1,55506
	ν	3,73478

У діапазоні від десятків децибел до сотень децибел розташовані моделі зображення. Середньоквадратичне відхилення — це значення порядку десятих або одиниць децибел, що становить приблизно відсоток від визначених величин, тоді як значення математичного очікування близькі до нуля та складають величини порядку сотих і тисячних децибел. Значення були отримані за допомогою вибірок, які містили 100 000 елементів. Нейронна мережа дала ідентичні результати для вибірок з кількістю елементів менше 100.

На практиці важливою характеристикою нейронної мережі є мінімальна кількість елементів, при яких вона працює ефективно. При тестуванні нейронної мережі, навченої за допомогою моделі Окамура-Хата в діапазоні вибірок від п'ятдесяти до двох тисяч елементів, відносна помилка склала не більше 1%. Для вибірок із 200 елементів і вище відносна помилка була значно нижчою, ніж для вибірок із 200 до 50 елементів. У реальному світі існує похибка вимірювання, яка вносить випадкову складову до результатів. На рис. 3.3 показано результати моделювання зашумленості вхідних значень навчальної вибірки за допомогою шуму з рівномірним законом розподілу.




Рисунок 3.3 – Дослідження функціонування нейронної мережі при зашумленості вхідних значень

Нейронна мережа демонструє найкращі результати під час тестування в умовах зашумленості, коли вхідні значення мають відношення сигналу до шуму між 400 і 100. Нейронна мережа демонструє низьке відношення сигналу до шуму під час тестування, коли відношення сигналу до шуму в навчальній вибірці значно зменшується до 10 значень.

Результати моделювання можна досить точно прогнозувати за допомогою методу прогнозування нейронних мереж. Нейронні мережі можуть створювати функціональні зв'язки навіть у разі неточності вимірювань. Завдання прогнозування рівня радіосигналу та частотно-територіального планування можна вирішити за допомогою нейромережевого методу.

3.2 Задача виявлення сигналів

Нейронна мережа Кохонена може бути використана для кластеризації, щоб виявити сигнал [13, 14].

Мережа Кохонена – це одношарова мережа, яка складається із нейронів типу WTA (Winner Takes All – переможець отримує все). Для розв'язання задачі виявлення сигналів мережа Кохонена працює у режимі самонавчання і містить вхідні вектори рівнів відліків прийнятого сигналу на відповідній частоті.

Даному випадку $a(t_1, f_1)$ – рівень відліку прийнятого сигналу у 1-й момент часу на частоті f_1 ; $a(t_2, f_1)$ – це рівень відліку прийнятого сигналу в 2-й момент часу на частоті f_1 ; $a(t_m, f_1)$ – це рівень відліку прийнятого сигналу у m-й момент часу на частоті f_1 ; $a(t_1, f_2)$ – це рівень відліку прийнятого сигналу у 1-й момент часу на частоті f_2 ; $a(t_2, f_2)$ – це рівень відліку прийнятого сигналу в 2-й момент часу на частоті f_2 ; $a(t_m, f_2)$ – це рівень відліку прийнятого сигналу в m-й момент часу на частоті f_2 тощо.

Нейронна мережа Кохонена повинна визначити, на яких частотах є сигнал первинного користувача, а на яких його немає, щоб виконати завдання виявлення сигналів. Робота алгоритму полягає у наступному. Усі частини m-мірного вхідного вектора пов'язані з кожним нейроном мережі. Число кластерів, які має виділити мережа, корелює з кількістю нейронів.

Кластер H_0 відповідає гіпотезі H_0 , згідно якої первинний користувач відсутній. Кластер H_1 відповідає гіпотезі H_1 згідно якої первинний користувач

працює зі спектром. Лінійні зважені суматори використовуються як нейронні мережі Кохонена:

$$y_j = t_j + \sum_{i=1}^m w_{ij} \cdot a_i, \quad (3.2)$$

де i – це номер входу;

j – це номер нейрона;

y_j – це вихід адаптивного суматора;

w_{ij} – це вага i -го входу j -го нейрона;

t_j – це поріг.

Кожний j -й нейрон можна описати за допомогою вектора ваг $w_{ij} = (w_{j1}, w_{j2}, \dots, w_{jm})$. Потім сигнал з виходів адаптивних суматорів поступає на функцію конкуренції, що функціонує за правилами "переможець отримує все".

Далі функція конкуренції реалізує вихід адаптивного суматора із максимальним значенням виходу $\max\{y_j\}$. Тобто, якщо 1 – номер суматора, то на виході формується вихідний сигнал $H_1=1$, а вихідний сигнал H_0 дорівнює нулю. Тобто, первинний користувач працює зі спектром.

Метод кластеризації майже завжди є ітеративним. Кластеризація даних включає такі етапи

1). Виділення окремих характеристик

Кластеризація ресурсів реалізовується за векторами ознак:

а) Координати розташування абонентської станції.

б) Запитувані ресурси:

- інтенсивність надходження пакетів від абонентської станції;
- затримка у черзі;
- відношення сигнал/завада;
- швидкість передачі даних;

в) Доступні ресурси:

- просторово-часові ресурси;

- частотно-часові ресурси.

2). Визначення метрики.

Наступний етап кластеризації – це вибір метрики, котра дозволить визначити близькість об'єктів. Класична евклідова метрика застосовується у більшості випадків.

3. Подання результатів.

Для здійснення оцінки якості кластеризації результати кластеризації необхідно представляти в зручному для оброблення вигляді. Можливі такі способи:

- представлення кластерів як центроїдів;
- представлення кластерів к набір характерних точок;
- представлення кластерів їхніми обмеженнями.

Два види кластеризації існують: чітка та нечітка [27-29]. У випадку чіткої кластеризації усі об'єкти в досліджуваній області належать до одного кластера з певними параметрами. Алгоритми, побудовані на математичному апараті мереж Кохонена, належать до методів чіткої кластеризації. У випадку нечіткої кластеризації кожен елемент досліджуваної області належить будь-якому кластеру з певною вірогідністю, яка виражається коефіцієнтом чіткості. Алгоритми k-середніх і Густафсона-Кесселя є двома алгоритмами нечіткої кластеризації, які переважно розглядаються в літературних джерелах.

Нейронна мережа Кохонена використовує режим самоорганізації для групування ресурсів. Таким чином у мережі не існує постійної структури.

Алгоритм має вигляд:

1. Дані попередньо обробляються за правилом:

$$x'_i = \frac{x_i - M_x}{\sigma_x}, \quad (3.3)$$

де x'_i – нормована і центрована ознака;

M_x – математичне сподівання;

σ_x – дисперсія.

2. Максимально допустима евклідова відстань між вагами нейрона-переможця та входами прикладу визначається як критична відстань $d_{кр}$. Нейрони відсутні в початковій структурі. Перший нейрон генерується з ваговими коефіцієнтами, рівними вхідним значенням, коли навчальна вибірка падається на входи мережі першого прикладу.

3. На вході мережі надходить новий випадково обраний приклад (наприклад, МС зі своїми характеристиками) для даної епохи навчання. Потім евклідові відстані від прикладу до центру кожного кластера обчислюються відповідно до співвідношення:

$$d_j = \sqrt{\sum_{i=1}^M (x_i - w_{ij})^2}, \quad (3.4)$$

де w_{ij} – вага i -ї ознаки j -го кластера.

Потім визначається нейрон-переможець найменшою d_{min} .

4. Якщо умова $d_{min} \leq d_{кр}$ виконується, то корекція вагових коефіцієнтів відповідного нейрона-переможця здійснюється на $t+1$ кроці згідно співвідношення:

$$w_{ij}(t+1) = w_{ij}(t) + v(x - w_{ij}(t)), \quad (3.5)$$

де v – це коефіцієнт швидкості навчання мережі.

В іншому випадку в структуру мережі додається новий нейрон, а вагові коефіцієнти рівні вхідним значенням наведеного прикладу.

5. Процес повторюється з пункту 3. Коли останні кластери не задіюються під час навчання, відповідні нейрони вилучаються з структури нейронної мережі Кохонена.

6. Обчислення завершуються, коли виконується одна з умов:

- вичерпана гранична кількість епох навчання;
- протягом останньої епохи навчання не відбулося значної зміни вагових коефіцієнтів у межах попередньо заданої точності;
- вичерпано заданий граничний час навчання.

Коефіцієнт швидкості навчання може бути або змінним, що поступово зменшується від епохи до епохи, або постійним у межах $(0,1]$.

3.3 Задача керування мережею

Удосконалення розумних методів управління мобільними мережами є важливим питанням [12].

Нейронні мережі є математичним інструментом, який ми обрали для дослідження, зокрема для прогнозування будь-якого результату. Здатність нейронної мережі до узагальнення та виявлення прихованих залежностей між вхідними та вихідними даними є основою її здатності до прогнозування. Після навчання мережа може прогнозувати майбутні значення послідовності на основі кількох попередніх значень і (або) факторів, які є зараз. Слід зазначити, що прогнозування можливо лише тоді, коли минулі зміни дійсно визначають майбутнє.

У більшості випадків обсяг обслуговуваного навантаження мереж є невизначеним. Основним завданням алгоритму маршрутизації даних є визначення найкращих шляхів передачі даних від джерела до одержувача.

Побудова короткострокової моделі прогнозу з двома нейронними мережами передуює процесу вибору маршруту. Для процесу прогнозування статистичні параметри трафіку, такі як дані, голос і відео, а також координати об'єктів і рівні потужності сигналу, збираються. Зважаючи на те, що більшість мобільних пристроїв обладнані пристроями GPS-зв'язку, які без зусиль можуть визначити координати місця розташування користувача, цей процес не вимагає використання додаткового обладнання, що підключається до мобільних

пристроїв. Вбудовані пристрої мобільного зв'язку також можуть використовуватися для вимірювання рівнів потужності сигналу.

Процес навчання нейронних мереж базується на зібраних даних. Прогнозуючи переміщення об'єктів мережі, перша нейронна мережа може визначити параметр маршрутизації Link Expiration Time (LET). Рівень потужності об'єктів, який також називають параметром сигнальної потужності, прогнозується другою нейронною мережею.

Параметр LET подано на рис. 3.6, де N_1 , N_2 і N_i – це мобільні пристрої.




Рисунок 3.6 – Прогнозування переміщення мобільного пристрою

N_1 підключено до N_2 у момент t_k ($LET_{N_1}(N_2)$). Географічні координати для N_1 і N_2 в даний момент рівні відповідно $N_1(X_{1t_k}, Y_{1t_k}, Z_{1t_k})$ і $N_2(X_{2t_k}, Y_{2t_k}, Z_{2t_k})$. Для прогнозування переміщення N_1 і N_2 потрібно оцінити об'єкти N як $(X_{1t_k+i}, Y_{1t_k+i}, Z_{1t_k+i}) \{i=0 \text{ до } N\}$ і $(X_{2t_k+i}, Y_{2t_k+i}, Z_{2t_k+i}) \{i=0 \text{ до } N\}$. Потім розраховується відстань $dt_k+i \{i=0 \text{ до } N\}$, що відділяє його від N_2 в $t_k+i \{i=0 \text{ до } N\}$. LET відповідає відстані, що відділяє N_1 і N_2 , котра представляє собою діапазон передачі. Розглядається функція, котра пов'язує відстань d між

N_1 і N_2 за часом t . Функція апроксимується по $N-1$ ступеню полінома $P(t)$. Коефіцієнти полінома $P(t)$ a_i визначаються системою рівнянь:

$$\begin{cases} \sum_{i=0}^{N-1} a_i t_{k+1}^{N-1-i} = d_{k+1}, \\ \sum_{i=0}^{N-1} a_i t_{k+2}^{N-1-i} = d_{k+2}, \\ \dots \\ \sum_{i=0}^{N-1} a_i t_{k+N}^{N-1-i} = d_{k+N}. \end{cases} \quad (3.6)$$

Зрештою, прогнозування пересування об'єкта допоможе покращити маршрутизацію потоків даних, оскільки буде обраний стабільний маршрут, що запобігає обривам зв'язку, що також знижує витрати на відновлення передачі даних і переналаштування устаткування [4].

Запропонований алгоритм подано на рис. 3.7.

Рекурентна нейронна мережа є найкращою нейронною мережею для прогнозування результатів (рис. 3.8). Це найскладніший тип нейронних мереж із зворотним зв'язком [5]. Зворотний зв'язок — це зв'язок від логічно більш віддаленого елемента до менш віддаленого. Зворотний зв'язок дозволяє запам'ятовувати та досягати цілей для послідовності реакцій на один стимул. Такі мережі є подібними до циклічного виконання з точки зору програмування, а з точки зору систем вони подібні до кінцевого автомату.

Дана структура використовується N раз для оцінки N спостережень часових рядів. N — це крок прогнозування. В кожному такому кроці k ($k \neq N$), у вхідний шар передається вихід мережі $S'(t + k)$, що дозволяє оцінити значення $S'(t + (k + 1))$, що і буде прогнозуванням наступного кроку ($k + 1$).

Далі розподіляється трафік з різних джерел, включаючи голос, дані та відео. Після цього створюються маршрути на основі прогнозованих значень і пріоритетів трафіку, а потім аналізуються результати, щоб визначити найбільшу питому вагу. Після цього вибирається найкращий маршрут. Алгоритм аналізує помилкові рішення. У цьому випадку відбувається

перезапит на навчання нейронної мережі, що дозволяє найбільш точно прогнозувати наступні результати прогнозування.




Рисунок 3.7 – Алгоритм маршрутизації на основі нейронних мереж




Рисунок 3.8 – Рекурентна нейронна мережа

Наступним чином проводиться перевірка надійності моделі короткострокового прогнозування на основі нейронних мереж: перевіряється виконання умов для залишкової частини, також відомої як помилки прогнозу:

- 1) незалежність;
- 2) випадковість;
- 3) нормальність розподілу.

Для перевірки незалежності (відсутності автокореляції) необхідно визначити відсутність систематичних залишків. Будуючи графік залежності залишків як часовий ряд, ми не повинні очікувати будь-якої тенденції до зміни, яка вказуватиме на автокореляцію, тобто на залежність кожного наступного значення залишків від попереднього. Критерії серій і поворотних точок можуть бути використані для перевірки випадковості рівнів ряду. Алгоритм полягає в послідовному порівнянні двох останніх рівнів ряду залишків. Якщо вихідний ряд є випадковою послідовністю, найдовша серія, яка складається лише з нулів або одиниць, повинна бути короткою, а загальне число серій повинно бути якомога меншим.

Описаний вище алгоритм дозволяє створити короткострокову модель прогнозу переміщення об'єктів в мережі та рівнів їх сигналу, щоб змінити

таблиці маршрутизації. Це підвищує ефективність управління мобільними мережами, дозволяючи заздалегідь відреагувати на зміни структури мережі та забезпечувати смугу пропускання трафіку з найменшими втратами та затримками до важливих видів трафіку.

4 ОЦІНЮВАННЯ ХАРАКТЕРИСТИК ТЕЛЕКОМУНІКАЦІЙНИХ СИСТЕМ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ

4.1 Виявлення аномалій у телекомунікаційних мережах за допомогою нейронних мереж

4.1.1 Безпека телекомунікаційних систем

Безпека телекомунікаційних систем є важливою та складною проблемою. Наразі значний прогрес у сфері інформаційно-комунікаційних технологій надає необхідні інструменти для передачі файлів, обміну повідомленнями та багатьох інших типів обміну інформацією. Зловмисні дії, мотиви яких різноманітні та розвиваються з часом, на жаль, зростають разом із розвитком комп'ютеризації. Віддалені атаки стають більш ймовірними через збільшення кількості телекомунікаційних систем у мережах, а також через постійно виявляються уразливості та недоліки операційних систем, програм, протоколів зв'язку тощо. Таким чином, атаки стають більш масштабованими та небезпечними.

Системи виявлення вторгнень (IDS) зазвичай запроваджуються постійним або регулярним моніторингом, щоб виявити будь-які спроби зламу систем безпеки. Тим не менш, у сучасному світі парадигм цих систем, які ґрунтуються на зіставленні сигнатур відомих векторів атак, уже недостатньо. Використання практик нейронних мереж є прогресивним і ефективним рішенням сьогодні, оскільки мережева активність може бути передбачуваною, а подальша поведінка може бути оцінена за допомогою вивчених моделей. Крім того, слід зазначити, що в секторі інформаційних технологій останнім часом спостерігається зростання попиту на використання технологій штучного інтелекту (ШІ) у нових продуктах. У середньому 54% проєктів, що засновані на технологіях штучного інтелекту, проходять шлях від планування розробки до виходу продукту на ринок, за даними дослідницької компанії Gartner.

У сфері кібернетичного захисту інформації також прослідковується подібна тенденція. Використання машинного навчання, штучних нейронних мереж і технологій глибинного навчання для створення нових і видалення старих шкідливих компонентів програмного забезпечення стає все більш поширеним. В результаті деякі добре відомі засоби захисту мереж фактично виходять з гри, оскільки їхні бінарні алгоритми просто не здатні обробити таку велику кількість значень, яку можна створити за допомогою квантових обчислень. З цієї причини провайдери послуг захисту використовують рішення, засновані на вищезгаданих алгоритмах, щоб виявити аномалії в мережах.

Аномалія мережі — це раптове, короткочасне відхилення від звичайного функціонування мережі. Зловмисники зі шкідливими намірами можуть спричинити аномалії, як-от атаки на відмову в обслуговуванні (DoS/DDoS) в IP-мережах. Для швидкого виявлення аномалій необхідно реагувати на зміни в інформаційній системі.

Розробка ефективної системи виявлення аномалій вимагає збору корисної інформації з великої кількості «забруднених» даних. Для цього використовують пристрої моніторингу мережі, які швидко збирають статистичні дані. Складно створити загальні моделі нормальної поведінки мережі та аномалій, оскільки різні аномалії проявляються в статистиці мережі по-різному.

У сфері ідентифікації випадків (IDS) слова «вторгнення» та «аномалії» зазвичай використовуються як синоніми, але обидва терміни мають певні відмінності. Тоді як аномалія стосується моделей даних, які не відповідають очікуваній нормальній поведінці, тобто відхиляються від того, що вважається нормальним, вторгнення — це зловмисна діяльність, котра намагається скомпрометувати конфіденційність, цілісність та доступність. Але аномалія не завжди є вторгненням, оскільки це залежить від контексту та сфери застосування. Наприклад, мережевий домен відстежує трафік, індекси продуктивності і журнали виявлення збоїв у мережі. Застосування виявлення аномалій використовується в багатьох сферах, наприклад, в промисловості збої датчиків, ситуації, що загрожують життю в медичних програмах, підозрілі дії

на відеоспостереженні та шахрайство з кредитними картками в сфері виявлення злочинів.

Тим не менш, менеджери ІТ-безпеки вважають будь-які події, які відрізняються від нормальної поведінки, можливими спробами вторгнення. Хоча вони відрізняються, концепції систем виявлення аномалій і вторгнень часто порівнюються.

Методи використаного навчання, статистичні методи та машинне навчання є основами методів виявлення аномалій. Одним із таких методів є глибинне навчання.

В останні роки активно вивчається глибинне навчання для програм обробки зображень і сигналів. Це метод, який використовує комбінацію різних методів нелінійного перетворення для виявлення важливих елементів у великій кількості даних або надзвичайно складних даних [17]. Двома алгоритмами, які найкраще демонструють глибинне навчання, є згорткові нейронні мережі (ЗНМ, англ. CNN) для розпізнавання зображень, і рекурентні нейронні мережі (РНМ, англ. RNN), які в основному використовуються для розпізнавання мовлення та обробки природної мови [9]. Локальне сприйнятливим поле та спільне вагове ядро CNN дозволяють відображати просторові характеристики шляхом виділення таких візуальних елементів, як кути, кінцеві точки та орієнтовані краї [6]. PNN має надзвичайно складну структуру, яка з'єднує основні нейронні одиниці в хронологічному порядку. Крім того, RNN зазвичай добре працює для моделювання послідовних даних шляхом навчання мережі з використанням вентильних вузлів LSTM.

Для визначення просторових і часових характеристик також досліджується поєднання шарів CNN і LSTM [19]. Поєднання CNN і LSTM може ефективно виділяти певні характеристики, оскільки обробка природної мови та розпізнавання мовлення потребують просторової та часової інформації [4]. У даний час ці переваги використовуються для класифікації та прогнозування даних сенсорів у промисловому секторі [12]. Це дослідження зосереджується на виявленні мережових аномалій за допомогою рекурентних

нейронних мереж (RNN), зокрема їх унікальних форм — довгої короткочасної пам'яті (LSTM-RNN) і згорткових нейронних мереж (CNN), які також мають форму LSTM-CNN. Буде проведено порівняння різних підходів, щоб визначити, яка з них найкраще підходить для пошуку аномалій у мережі.

4.1.2 Машинне навчання

Машинне навчання включає багато різних методів, включаючи глибинне навчання, яке використовує потоки нелінійних вузлів у кількох шарах для отримання та перетворення значення змінних сутності з вхідного вектора. За винятком початкового вхідного рівня, який отримує сигнали або вхідні вектори з зовнішнього середовища, окремі рівні такої системи мають на вході вихідні дані попередніх рівнів. Крім того, під час навчання систем можуть використовуватися методи, які не контролюються або контролюються. Це означає, що ці моделі можна використовувати як для контрольованих завдань, таких як класифікація, так і для неконтрольованих завдань, таких як аналіз шаблонів. Крім того, моделі глибинного навчання вимагають виділення сутностей нижчого рівня з сутностей вищого рівня, щоб отримати стратифіковане представлення вхідних даних. Це досягається за допомогою методу неконтрольованого навчання на різних рівнях сутностей.

Вивчення різних рівнів подання даних, які представляють різні рівні поглинання даних, є основою для аналізу понять і теорій. Згорткові нейронні мережі (CNN), мережі глибинних переконань (DBN), мережі глибинних/стекованих автокодерів (DAE/SAE) і мережі глибинних переконань є кількома структурами глибинного навчання, які описані в літературі. Обробка природної мови, розпізнавання мови, розпізнавання аудіо, розпізнавання та виявлення об'єктів і комп'ютерний зір є одними з багатьох областей, які використовують ці структури глибинного навчання. Це може бути частиною оцінки користувачів.

Алгоритми глибинного навчання використовують кілька рівнів нелінійної обробки для екстракції та перетворення ознак. Послідовні шари використовують вихідні дані попередніх шарів як вхідні дані; навчання без нагляду (наприклад, аналіз моделі) та/або під наглядом (наприклад, класифікація); вивчення кількох рівнів представлень, пов'язаних з різними рівнями абстракції; і використання вихідної інформації з попередніх шарів. Ці рівні є ієрархією ідей.

Залежно від того, для чого вони були створені, глибинні навчання поділяються на три основні категорії: гібридні, мережі керованого або генеративного навчання, мережі неконтрольованого або генеративного навчання. Підвиди глибинного навчання показані на рис. 4.1.



Рисунок 4.1 – Класифікація нейронних мереж

Насправді всі алгоритми глибинного навчання є нейронними мережами з певними базовими характеристиками. Усі вони складаються з шарів взаємопов'язаних нейронів. Їх відрізняє як формування, так і архітектура мережі.

4.1.3 Рекурентні нейронні мережі типу RNN/RNN LSTM

Рекурентні нейронні мережі (англ. Recurrent Neural Networks, RNN) мають зворотні зв'язки і дозволяють зберігати інформацію. Фрагмент нейронної мережі на рис.4.2. А отримує значення x_t і потім повертає значення h_t на схемі. LSTM є однією з різновидів рекурентної нейронної мережі (RNN), яка широко використовується для обробки даних часових рядів, оскільки має зворотний зв'язок, що дозволяє передавати інформацію від одного кроку навчання мережі до іншого.




Рисунок 4.2 – Рекурентна мережа

У типовій RNN вихід будь-якого шару базується на попередньому виході, а також на поточному вході. Тим не менш, проблема зникаючих градієнтів є однією з найважливіших проблем для навчання стандартної RNN. Рівняння 1 демонструє, як вагові значення нейронної мережі оновлюються за допомогою градієнтів. Але коли значення градієнта з часом стає надзвичайно малим, це не сприяє навчанню. Невеликі зміни градієнта відбуваються в RNN, особливо на попередніх шарах. Таким чином, він не може зберігати інформацію для довгих послідовностей:

$$\text{Нова вага} = \text{вага} - \text{швидкість_навчання} * \text{градієнт} \quad (4.1)$$

За допомогою довготривалої короткочасної пам'яті (LSTM) RNN може вирішити серйозні проблеми, такі як раптове зникнення потоку даних і «вибух

мережевого трафіку». LSTM має входні асоціації, як і стандартні нейронні системи прямого зв'язку. Вона може обробляти не лише окремі інформаційні фокуси, як-от зображення, але й цілі масиви даних, як-от відео. Багато варіантів розвитку LSTM були запропоновані.

Тепер більшість сучасних класичних LSTM включають коригування, такі як асоціації комірок і пропуски шару фільтра забуття. Інші варіації включають простіший дизайн Gated Recurrent Unit (GRU). Результати 2018 року показали, що класичний LSTM є кращим у порівнянні з різними варіаціями щодо підтримки різних інформаційних індексів.

Формули реалізації, які не містять комірки та надають передовий перехід:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4.2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4.3)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4.4)$$

$$c_t = (c_{t-1}) \odot (f_t + i_t \odot \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)) \quad (4.5)$$

$$h_t = \tanh(c_t) \odot o_t \quad (4.6)$$

Існує три основні сценарії, згідно яких кожна комірка LSTM може бути або шаром фільтру забуття f_t , або входним фільтром i_t , або вихідним фільтром o_t у момент часу t . Глибинно розрахований компонент сигмовидної ємності σ використовується для активації входів. x_t — це входна інформація. Прихований стан з попереднього кроку позначається як h_{t-1} . Навантаження позначаємо як W . Зміщення входів або стану позначається як b . Оновлений стан комірки заповнюється як пам'ять і визначається як за допомогою h_t . Шари фільтру

забуття – це значення між 0 і 1. Знак $\odot$ - це компонентне множення двох векторів. Комірки LSTM здатні навчатися при виконання складних і тривалих задач, коли вміст пам'яті сильно перезавантажується.

Оскільки дані часових рядів можна отримати за допомогою часової кореляції мережевого трафіку, розглянемо LSTM. Крім того, завдяки здатності вивчати просторові особливості RNN добре обробляє зображення. Таким чином, інтеграція RNN з LSTM дозволяє значно збільшити просторові та часові характеристики необроблених даних. У результаті це може призвести до підвищення точності технологій виявлення вторгнень і аномалій.

4.1.4 Виявлення аномалій на основі RNN-LSTM

Останнім часом RNN-LSTM часто використовується для аналізу журналу даних, оскільки вони схожі на методи LSTM, які використовуються для обробки природної мови [17]. Для виявлення та прогнозування збою системи використовується метод кластеризації для кількох записів журналу, які вводяться в мережу LSTM. Коли необроблені дані обробляються та аналізуються для виявлення, використовується узагальнене виявлення та діагностика на основі LSTM. Використовуючи в журнальних даних, мережа LSTM, яка має глибину, служить входом для наступного рівня LSTM, а повторюваний рівень у часі може бути розгорнутий як мережа прямого зв'язку. У порівнянні зі звичайною RNN, LSTM не вимагає попередньої обробки даних або взагалі не вимагає її. Оскільки він працює на необроблених даних, він також не вимагає функцій, підготовлених експертами, та не потребує попередньої анотації для функціонування аномалій.

Для пошуку зловмисних точок у латентних функціях RNN-LSTM може виконувати багатовимірний послідовний часовий ряд без зменшення розмірності. У деяких дослідженнях LSTM використовується для використання багатовимірного розподілу Гаусса. Використовуючи LSTM для виявлення аномалій, деякі методи подібні до рішення, запропонованого [11]; однак

загалом неспецифічні дослідження показали результати багатьох джерел даних журналу, включаючи моделювання часових рядів LSTM. У багатоваріантних ситуаціях необхідна анотація, і такі проблеми, як неструктуровані дані, повинні бути розглянуті, оскільки виявлення аномалій у форматі послідовного журналу передбачає вивчення довгострокових залежностей, які сприяють кінцевій ефективності виявлення.

Запропонована структура виявлення аномалій для одновимірних даних часового ряду [16]. Набір даних NAB підтвердив їхню структуру, розділивши дані в основному на три класи: «На основі тесту Дікі-Фуллера, швидкого перетворення Фур'є (ШПФ) і коефіцієнта кореляції Пірсона, дані поділені на три класи: (1) стаціонарні, (2) періодичні та (3) нестаціонарні та неперіодичні часові ряди». Для класифікації аномалій у часових рядах третього типу використовується Gated Recurrent Unit (GRU), варіація моделі LSTM. У цьому методі помилка передбачення відображається на нормальному розподілі для класифікації точок даних. Їхній метод досягає майже ідеальної точності, запам'ятовування та показника F1 для всіх тестованих наборів даних.

Структура, представлена в [9], використовує стековану мережу LSTM для прогнозування на ковзному вікні вхідних даних над даними. Цей метод є досить схожим. Завдяки передбаченням створюється набір помилок, які відповідають класифікатору GNB, щоб визначити, чи є точки даних нормальними чи аномальними. Використовується набір даних про трафік із двох різних джерел, хоча він схожий на набір даних NAB. Цей тип інфраструктури також пропонує широкі можливості для пошуку аномалій у даних часових рядів.

Згадані методи виявлення аномалій досить ефективні. Вони прогнозують дані часових рядів за допомогою форми мережі на основі LSTM, а для класифікації аномалій використовують класичний метод машинного навчання. Прогнози створюють набір даних про помилки, а форма нормального розподілу змінюється відповідно до помилки. Після цього на основі отриманих параметрів точки даних можна класифікувати як нормальні чи аномальні.

Недолік цього дослідження полягає в тому, що вони не досліджують ефективність своїх моделей у багатовимірних даних.

Після збору початкових даних з інструменту вони попередньо обробляються, перш ніж поділяються на набір для навчання та перевірки, який містить лише звичайні затягування, і набір для тестування, який містить змішані дані про звичайні та аномальні затягування. Після цього модель LSTM будується відповідно до архітектури оптимізатора, використовується навчальний набір для навчання моделі, а гіперпараметри налаштовуються відповідно до продуктивності набору перевірки. Після цього для остаточного тестування продуктивності навченої моделі LSTM можна використати тестовий набір звичайних і несправних затягувань. Після цього тестовий набір можна навчити та перевірити класифікатор аномалій, оскільки він не використовується для вибору параметрів моделі LSTM і не впливає на її продуктивність.

4.1.5 Згорткова нейронна мережа CNN/LSTM-CNN

Варіант нейронної мережі, згорткова нейронна мережа (CNN), має на меті вивчення відповідних представлень ознак вхідних даних. Розподіл ваги та об'єднання відрізняють CNN від MLP (у нашому випадку RNN). Кожен рівень мережі CNN може складатися з кількох ядер згортки, які складають різні карти функцій. Карти характеристик наступного шару показують, як кожна сусідня область нейрона пов'язана з наступним нейроном. Усі просторові шари входу поділяються на ядро для створення карти функцій. Для класифікації використовується один або кілька повністю пов'язаних шарів [1] після кількох шарів згортки та кластеризації.

Модель може вивчати той самий шаблон, що виникає в різних позиціях входів завдяки використанню спільних вагових коефіцієнтів CNN. Це дозволяє їй навчитися використовувати окремі детектори для кожної позиції. Оскільки кількість з'єднань між шарами згортки зменшується, шари об'єднання зменшують обчислювальне навантаження. Крім того, властивості

інваріантності трансляції покращуються шарами кластеризації, які також покращують поле прийому наступних згорткових шарів. Як правило, в кінці потоку згортки мережі додається один або кілька повністю пов'язаних рівнів, а функція втрат використовується для вимірювання помилок для навчання. CNN може виявити мережеві аномалії, як показано дослідженням [3]. Наприклад, ми використовуємо чотири показники ефективності: точність (Acc), уточнення (Pre), відкликання (Rec) і значення F1 для оцінки нашої моделі CNN. Рівняння 7, 8, 9 і 10 використовуються для обчислення математичного представлення цих показників:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.7)$$

$$Pre = \frac{TP}{TP + FP} \quad (4.8)$$

$$Rec = \frac{TP}{TP + FN} \quad (4.9)$$

$$F1 = \frac{2 \times Pre \times Rec}{Pre + Rec} \quad (4.10)$$

TP позначають справжні позитивні результати, TN позначають справжні негативні результати, FP позначають помилкові позитивні результати, FN позначають помилкові негативні результати.

Таблиця 4.1 демонструє результати оцінки. Запропонована модель CNN-LSTM демонструє хороші результати порівняно з іншими існуючими методами. Порівняно з іншими моделями глибокого навчання, стандартні алгоритми CNN демонструють низьку продуктивність, як показано в таблиці 1. Стандартна точність CNN становить 90,79%, але точність збільшується за допомогою методів нормалізації до 93,83%.

Таблиця 4.1 – Уточнення, відкликання та значення F1 для різних мереж

Модель	Уточнення %		Відкликання %		Значення F1 %	
	Норма	Атака	Норма	Атака	Норма	Атака
Стандартна CNN	76,69	98,86	97,47	88,11	85,84	93,18
LSTM	84,53	98,31	96,02	92,95	89,91	95,55
CNN (L2Reg.)	84,24	98,56	96,62	92,75	90,00	95,56
CNN-LSTM	93,18	97,60	94,04	97,24	93,61	97,42

Також, незважаючи на те, що продуктивність LSTM значно нижча, ніж у CNN з нормалізацією, вона все ще є дещо вищою порівняно зі стандартними CNN. Крім того, точність 96,32%, отримана за допомогою поєднання CNN з LSTM, перевершує всі інші алгоритми. Це свідчить про те, що запропонована гібридна модель CNN-LSTM є ефективною для виявлення вторгнень. Тим не менш, порівняно з усіма іншими алгоритмами, модель CNN (L2Reg.) демонструє більшу відкликаність для нормального класу та уточнюваність для класу атаки. Тим не менш, модель CNN-LSTM надає найкращий показник F1 для двох класів.

Крім того, ми можемо оцінити ефективність запропонованого нами підходу до класифікації даних атаки та звичайних даних. Кожна подія в наборі для тестування класифікується як подія атаки або звичайна подія. Модель CNN-LSTM, запропонована, демонструє вищий ступінь точності 0,97 у вірному виявленні подій атаки. Тим не менш, точність для звичайних подій трафіку становить 0,94. Це пов'язано з тим, що, порівняно з класами атаки, нормальні зразки не використовуються під час фаз навчання та тестування.

Більшість характеристик рекурентних і згорткових нейронних мереж, а також їх модифікації в парі з LSTM, були вивчені. Якщо розглядати їх з точки зору ефективності виявлення мережевих аномалій, моделі, які також використовуються шари довгої короткотривалої пам'яті, виявляться

найефективнішими. Варто зазначити, що всі науковці використовували набір даних NSL-KDD під час проведення аналізу. Набір даних NSL-KDD розроблений для вирішення деяких проблем, властивих набору даних KDD'99. Незважаючи на те, що ця нова версія набору даних KDD має деякі проблеми, і через відсутність загальнодоступних наборів даних для мережевих IDS вона може не бути ідеальним зображенням існуючих реальних мереж, вважається, що вона може бути використана як ефективний еталонний набір даних, щоб допомогти дослідникам порівняти різні методи виявлення вторгнень.

Не дивно, що моделі рекурентних нейронних мереж мають найнижчу ефективність виявлення аномалій, як показали незалежні дослідження вчених. Хоча оцінки різних дослідників відрізняються на кілька відсотків, згорткові нейронні мережі перевершують рекурентні. Точність виявлення значно збільшується завдяки додаванню шарів LSTM. До прикладу, точність може зрости приблизно на тридцять відсотків у рекурентних нейронних мережах. Знову ж таки, вибір між CNN-LSTM і RNN-LSTM принесе кращі результати, оскільки згорткові нейронні мережі є особливістю їх структури. Крім того, рекурентні нейронні мережі потребують більшої кількості часу, щоб виявити аномалії через рекурсію кожного компонента в мережі. Крім того, додавання додаткових шарів довгострокової короткотривалої пам'яті збільшить навантаження на ресурси телекомунікаційної системи.

З іншого боку, рекурентні нейронні мережі з шарами LSTM мають найвищі значення показника F1 (таблиця 1). Отже, тут виникає питання про те, як розподілити показники, які можуть змінюватися залежно від ситуації.

Але лише кілька шарів довгострокової короткострокової пам'яті не вирішить проблему використання часу. Це пов'язано з тим, що сама LSTM має дуже низький рівень точності виявлень, який іноді перевищує 80%. Загалом, таке рішення можна було б використовувати в невеликих обчислювальних системах, які не потребують великих ресурсів. Однак для отримання найвищої точності LSTM краще поєднувати з однією з існуючих нейронних мереж.

Таким чином, дослідження показали, що згорткова нейронна мережа з довгою короткою пам'яттю найкраще підходить для виявлення мережових аномалій. Вона достовірніша за звичайні шари довгої короткотривалої пам'яті та значно швидша за рекурентну нейронну мережу. Крім того, вона надає широкий спектр можливостей для виявлення мережних аномалій і робить його більш простим у використанні. Це спростить роботу аналітиків, автоматизує процес, зекономить час і зменшить людські помилки. З наукової точки зору ця робота є важливою, оскільки відкриває нові перспективи для досліджень у галузі кібернетичного захисту.

4.2 Нейро-нечіткий підхід до маршрутизації

4.2.1 Особливості маршрутизації в ТКС

Маршрутизація пакетів даних займає важливе місце в управлінні телекомунікаційною системою. Алгоритм маршрутизації є складовою програмного забезпечення маршрутизатора – пристрою, відповідального за вибір вихідної лінії, на яку надійшов пакет має бути переданий [1, 7]. Вибір оптимального маршруту повинен враховувати топологію мережі та її властивості, довжину черг у вузлах, відстань між вузлами, швидкість передачі даних і т.д. Зазначимо, що в умовах постійного зростання навантажень на сучасну телекомунікаційну систему, впливу на неї зовнішніх та внутрішніх перешкод, завдання оптимальної маршрутизації не вирішується повною мірою. Незважаючи на велику кількість запропонованих методів та алгоритмів маршрутизації [2,5], залишаються невирішеними ряд завдань з визначення таблиць маршрутизації для оптимізації та адаптації маршрутів певного класу трафіку.

Таким чином, задача дослідження сучасних алгоритмів маршрутизації з метою поліпшення їх характеристик та створення нових – інтелектуальних методів та алгоритмів маршрутизації є актуальною [9, 10, 11,12].

Як правило, задача маршрутизації представляється як граф [2]. Нехай дано направлений зважений граф $G = (V, E)$, в якому кожен вузол з множини V представляє собою пристрій, що обробляє та передає дані, а кожне ребро з множини E є лінією зв'язку. При моделюванні алгоритмів маршрутизації виникають дві проблеми.

По-перше, потік даних не є статичним, по-друге, він має стохастичний характер [8].

Слід зазначити, що останнім часом особливу актуальність набувають інтелектуальні адаптивні методи маршрутизації [6]. Дані методи дозволяють адаптувати алгоритм маршрутизації до часових та до просторових змін трафіку. Наприклад, було запропоновано новий підхід до задачі маршрутизації – алгоритм AntNet. Це адаптивний та інтелектуальний алгоритм, що базується на агентах. Він демонструє кращі результати продуктивності серед традиційних алгоритмів. Алгоритм AntNet використовує для маршрутизації даних по мережі рісвий інтелект. У різних зарубіжних телекомунікаційних компаніях широке застосування отримали маршрутизатори, засновані на теорії штучного інтелекту [4, 5]. Мережеві пристрої компанії Cisco (AIR) забезпечують накопичення та розподіл ресурсів у серії мобільного зв'язку для оптимізації передачі даних за допомогою технології адаптивної інтелектуальної маршрутизації [4]. Технологія Cisco AIR забезпечує інтелектуальне управління трафіком сервісів на рівні периметра мережі, включаючи:

- маршрутизацію низькодохідного трафіка прямо в Інтернет;
- маршрутизацію трафіку з високим пріоритетом та низьким допустимим часом затримки без глибокого занурення в пакетне ядро;
- утримання локального трафіку на локальному рівні;
- створення нових сервісів і бізнес-моделей.

Іншою провідною закордонною компанією запропоновано інтелектуальний маршрутизатор QLogic iSR6140, який розроблений для універсалізації з'єднань між серверами та сховищами у мережі зберігання даних

(SAN) [5]. Компанією Microsoft представлений інтелектуальний маршрутизатор ARTA, який дозволяє:

- автоматичний пошук маршрутизації за критерієм найменшої вартості;
- автоматичний пошук маршрутизації за критерієм якості з'єднання;
- автоматичний пошук маршрутизації за критерієм прибутку тощо.

Автоматизований механізм маршрутизації за критерієм найменшої вартості (ALCR), заснований на методиці Artilium, відправляє запити на з'єднання за найбільш економічним ефективним напрямом, аналізуючи стан КС та оцінюючи при цьому якість сигналу. Це гарантує, що з'єднання встановлюється з найбільшою ефективністю, згідно з критеріями співвідношення вартості-якості, або ж по одному з цих критеріїв. Адміністрування цього процесу обмежується тільки оновленням параметрів. Слід зазначити, що алгоритми роботи маршрутизаторів не анонсуються, тому що є комерційною таємницею.

Успішними можуть бути методи теорії нечіткої логіки, яка враховує досвід і знання системних адміністраторів), а також теорії нейронних мереж (здатних до навчання) [3].

Динамічна (нестационарна) модель ТКС із змінною структурою та змінними параметрами описується графом:

$$G(t) = G(A(t), R(t), W(t)), t \in [t_0, t_T] , \quad (4.11)$$

де A – це вузли,

R – це канали зв'язку,

W – це ваги (параметри) каналів зв'язку ТКС, які можуть змінюватися з часом на заданому інтервалі.

Використання таких «динамічних» графів і відповідних їм матричних моделей ТКС обумовлено тим, що реальна динаміка ТКС зі змінною структурою та параметрами, що змінюються, все ще слабо вивчена.

На основі аналізу вимог до алгоритмів та методів маршрутизації можна визначити, що інтелектуальна маршрутизація повинна володіти наступними характеристиками.

- адаптацією (автоматичним самоналаштуванням) по відношенню до змінної кількості користувачів, їх запитів та персональних вимог до якості послуг, до змінної топології ТКС і параметрам вузлів та каналів зв'язку тощо;
- навчанням та самонавчанням новим функціям та правилам функціонування ТКС;
- самоорганізацією структури та функцій маршрутизаторів в залежності від змін у ТКС;
- передбаченням та запобіганням відмов та мережевих конфліктів тощо.

4.2.2 Аналіз класичного підходу

Як приклад розглянемо матричний алгоритм пошуку найкоротшого шляху від вузла до вузла [2]. Припустимо, є локальна телекомунікаційна мережа з параметрами затримки передачі даних, яку можна представити у вигляді графа (рис. 1) і матриці відстаней L . Значення матриці вказують поточний час затримки передачі даних від вузла до вузла в мережі в мілісекундах. Завданням алгоритму маршрутизації є пошук такого маршруту, який дозволить доставити інформацію від вузла до вузла за мінімальний час, тобто з мінімальною затримкою.

Після ряду перетворень та розрахунків за традиційним методом, отримаємо підсумкову матрицю значень сумарних затримок інформації у ТКС. На підставі даних цієї матриці маршрутизатор приймає рішення про вибір оптимального маршруту (мінімальні значення між вузлами).

$$L = \begin{pmatrix} 0 & 60 & \infty & 60 & \infty \\ 60 & 0 & 50 & 80 & 90 \\ \infty & 50 & 0 & \infty & 70 \\ 60 & 80 & \infty & 0 & 30 \\ \infty & 90 & 70 & 30 & 0 \end{pmatrix} \quad (4.12)$$




Рисунок 4.3 – Телекомунікаційна мережа як граф

Зведення матриці L у ступінь максимального рангу $R_{\max}$ дасть нам матрицю оптимальних шляхів від вузла до вузла між усіма парами вузлів графа $L_{\text{opt}} = L^{(R_{\max})}$.

Якщо ж при зведенні матриці L деякий ступінь q виявиться, що:

$$L^q = L^{(q-1)}, \quad (4.13)$$

то обчислювальний процес слід перервати, так як це тягне за собою тотожність:

$$L^q = L^{(q+1)}. \quad (4.14)$$

Отже, елементи матриці $L^{(2)}$. Звіряємо отриману матрицю з матрицею попередньою і одержуємо $L^{(2)} \neq L$. Це означає, що пошук оптимальних шляхів слідує продовжити.

Для цього обчислюємо елементи матриці $L^{(3)}$, де

$$L^{(3)} = L^{(2)} \times L.$$

Отримана матриця $L^{(3)} = L^{(2)}$. З цього робимо висновок, що $L_{opt} = L^{(3)} = L^{(2)}$, отже, оптимальні шляхи знайдені, та розрахунок матриці 4 рангу можна не робити [25].

Виходячи з цієї підсумкової матриці, маршрутизатор визначає найкращий маршрут, наприклад, затримка даних від вузла 1 до 5 мінімальна при передачі пакета через вузол 4, тому що тоді сумарна затримка буде дорівнювати 90, порівняно з передачею через вузли 2 і 3, де затримка складе 180 і т.д.

Незважаючи на широке поширення даного алгоритму, в умовах частих змін параметрів ТКС, розрахунок нових значень матриць і вибір відповідних маршрутів є трудомісткою задачею, що займає великий обсяг пам'яті маршрутизатору та достатню кількість часу, протягом якого значення параметрів затримки можуть змінитися. Таким чином, новий маршрут не буде оптимальним у плані мінімізації затримки.

4.2.3 Аналіз нейромережевого підходу

З огляду на те, що структура телекомунікаційної мережі має певні риси, пов'язані зі структурою нейронних мереж, принципи нейронних мереж (НМ) є правильним підходом для оптимізації процесу маршрутизації.

Навчання НМ може відбуватися в одному з трьох різних способів: навчання з учителем, де реакції НМ відомі; навчання без учителя, де НМ

використовує вхідні сигнали для формування своїх реакцій; і навчання з підкріпленням, де зовнішнє середовище визначає винагороди та покарання. У цьому випадку навчання з вчителем неможливе, оскільки вихідні реакції НМ невідомі. Таким чином, вважається, що завади випадково діють на випадкові вузли. Навчання без вчителя зазвичай не використовується для задач, у яких необхідно визначити внутрішні зв'язки, залежності та закономірності між об'єктами навчальної вибірки.

У навчанні мережі використовується підкріплення. Навчання з підкріпленням не вимагає попереднього знання вихідної реакції, а взаємодія з навколишнім середовищем. Сигнал підкріплення створюється в відповідь на взаємодію, що дозволяє визначити найкращі маршрути передачі інформації на цьому етапі роботи мережі. Пропонується використовувати алгоритм навчання з підкріпленням, оскільки навчання НМ є специфічним для телекомунікаційних мереж.

Навчання з підкріпленням передбачає отримання агентом винагород та штрафів, котрі поступають з навколишнього середовища (рис. 4.4).




Рисунок 4.4 – Схема навчання з підкріпленням

В даній ситуації $x(t)$ агент виконує дію $a(t)$, отримує підкріплення $r(t)$ і потрапляє в ситуацію $x(t+1)$, $t = 0, 1, 2, 3, \dots$. Підкріплення $r(t)$ може бути як доатнім (винагорода) так і від'ємним (штраф). Мета агента – максимізувати сумарну винагороду $U(x(t))$, котру можна буде отримати в майбутньому.

Можливі два види підкріплення існують: альфа-система підкріплення змінює вагу всіх активних зв'язків на певну величину, а вага неактивних зв'язків залишається незмінною. Бета-система підкріплення змінює вагу всіх

активних зв'язків на певну величину, а потім ця зміна поділяється на загальну кількість зв'язків. Останній метод є консервативним щодо ваги, оскільки загальна вага всіх зв'язків залишається незмінною. Ця властивість оптимізує обсяг пам'яті мікроконтролера для зберігання ваги зв'язків, тому вона є кращою в ситуаціях, коли мало ресурсів.

На рис. 4.5 показано блок-схему оптимізованого алгоритму маршрутизації за принципами нейронних мереж. На першому етапі створюється таблиця маршрутизації, яка базується на кількісній чи якісній оцінці маршруту. Умови, в яких працює мережа, визначають оцінку маршруту. Якщо відомо, що в середовищі існують значні завади, то варто проводити якісну оцінку; якщо це не так, то варто проводити кількісну оцінку. Мережа починає працювати з таблиці маршрутизації, яка потім доповнюється значеннями ваги для кожного маршруту.

На початку кожен маршрут матиме однакову вагу. Після цього кожному пакету, який успішно доставлявся по маршруту, присвоюється нове значення ваги, яке є більшим ніж попереднє. У випадку, якщо пакет не підтверджується або надсилається з помилкою, відповідному маршруту присвоюється менше значення ваги, ніж попередньому. Через деякий час вагові коефіцієнти стають більш важливими, ніж метрика (кількісна чи якісна оцінка), і маршрут, у якому більша вага, вважається оптимальним. Таким чином, телекомунікаційна мережа адаптується до змін навколишнього середовища.

4.2.4 Аналіз нейро-нечіткого підходу

Для аналізу ефективності інтелектуальних технологій у галузі маршрутизації, пропонується використання нового підходу, що дозволяє оперативно та достовірно визначати підсумкові значення затримки даних між вузлами та враховувати досвід експертів – проектувальників та адміністраторів ТКС.

Даний підхід заснований на використанні апарату гібридних або нейро-нечітких мереж (ННМ) [25]. Даний апарат отримав успішну апробацію в промислових системах інтелектуального управління і може бути також використаний для пошуку оптимальних маршрутів у ТКС [4].




Рисунок 4.5 – Блок-схема запропонованого алгоритму маршрутизації

Нейро-нечітка мережа є сукупність окремих нейронів, пов'язаних з них між собою деяким фіксованим чином. При цьому взаємозв'язок нейронів визначається або задається структурою (топологією) нейронної мережі, а процес навчання ННМ відбувається за принципами дії системи нечіткого висновку [3]. У процесі створення ННМ ключову роль виконує експерт у галузі телекомунікацій. Експерт вносить свої коригування на етапі фазифікації [6] вхідних та вихідних параметрів алгоритму маршрутизації.

Процес навчання розробленої ННМ на визначення сумарних затримок і пошуку найкращих маршрутів ТКС складається з ряду етапів, виконаних з урахуванням гібридного методу навчання [30] з кількістю циклів навчання, рівним 30, визначеним в результаті комп'ютерних експериментів і дозволяє отримати точні значення затримки даних від вузла до вузла, що відповідають матриці L .

Таким чином, інтелектуальний або нейро-нечіткий маршрутизатор, що діє на основі алгоритму Сугено, має здатністю швидкого визначення сумарної затримки між вузлами в широкому діапазоні зміни параметрів ТКС.

З урахуванням даної можливості маршрутизатор зможе успішно адаптуватися до різних змін параметрів КС.

Ще однією перевагою ННМ як уже зазначалося, є їх можливість до екстраполяції даних або до короткострокового прогнозу. ННМ на основі накопичених даних визначає аналітичну залежність (лінійного або нелінійного виду) за допомогою якої виконує процедури інтерполяції та екстраполяції. Можливість спрогнозувати, до певного моменту час роботи ТКС, очікуване значення затримки даних на певному вузлі, дозволить маршрутизатору вибрати оптимальний маршрут передачі інформації.

4.2.5 Результати моделювання

Проведемо моделювання роботи нейро-нечіткого контролера у програмі Matlab. Запропонована нейро-нечітка мережа має три вхідні змінні, кожна з

яких має три рівні. В якості вхідних даних були обрані такі важливі параметри, як залишкова енергія, навантаження трафіку та відстань. Вихід ННМ – це статус маршруту, який має 11 рівнів: 0, 0.1, 0.2 ... 0.9, 1, де 1 – найвищий статус.

Створення нейронної мережі подано на рис 4.6, її вигляд – на рис.4.7, а результат роботи – на рис. 4.8. Згідно рис. 4.9 мережу навчено правильно.




Рисунок 4.6 – Створення нейро-нечіткої мережі у програмі Matlab




Рисунок 4.7 – Вигляд нейро-нечіткої мережі у програмі Matlab

Імітаційна перевірка створеної нейро-нечіткої мережі показує високу степінь її адекватності щодо мінімальних сумарних значень затримок між вузлами, що дає можливість застосовувати даний підхід при проектуванні інтелектуальних маршрутизаторів здатних до адаптації. Підхід допомагає вирішити задачу розрахунку мінімальної затримки даних між вузлами в мережі

та відповідного розрахунок найкоротшого шляху між вузлами телекомунікаційної мережі зі значною швидкістю у порівнянні з традиційним підходом.



Рисунок 4.8 – Результат роботи




Рисунок 4.9 – Результат навчання мережі

Також інтелектуальний підхід є найбільш застосовним, так як нейронечіткі мережі, завдяки наявності нечіткої бази знань, враховують думку експертів-адміністраторів, здатні самонавчатися та працювати з нелінійними даними.

При прогнозуванні очікуваного значення затримки між вузлами телекомунікаційної мережі на наступний день, можна помітити абсолютну

подібність отриманих результатів з вихідними, що дає можливість інтелектуальному маршрутизатору або системному адміністратору, заздалегідь планувати маршрут передачі даних, тим самим мінімізуючи значення затримок.

Використання цього підходу на практиці дозволить ефективно керувати потоками даних в умовах змінного навантаження ТКС.

5 ЕКОНОМІЧНА ЧАСТИНА

Виконання науково-дослідної роботи завжди передбачає отримання певних результатів і вимагає відповідних витрат. Результати виконаної роботи завжди дають нам нові знання, які в подальшому можуть бути використані для удосконалення та/або розробки (побудови) нових, більш продуктивних зразків техніки, процесів та програмного забезпечення.

Дослідження на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж» може бути віднесено до фундаментальних і пошукових наукових досліджень і спрямоване на вирішення наукових проблем, пов'язаних з практичним застосуванням. Основою таких досліджень є науковий ефект, який виражається в отриманні наукових результатів, які збільшують обсяг знань про природу, техніку та суспільство, які розвивають теоретичну базу в тому чи іншому науковому напрямку, що дозволяє виявити нові закономірності, які можуть використовуватися на практиці.

Для цього випадку виконаємо такі етапи робіт:

- 1) здійснимо проведення наукового аудиту досліджень, тобто встановлення їх наукового рівня та значимості;
- 2) проведемо планування витрат на проведення наукових досліджень;
- 3) здійснимо розрахунок рівня важливості наукового дослідження та перспективності, визначимо ефективність наукових досліджень.

5.1 Оцінювання наукового ефекту

Основними ознаками наукового ефекту науково-дослідної роботи є новизна роботи, рівень її теоретичного опрацювання, перспективність, рівень розповсюдження результатів, можливість реалізації. Науковий ефект НДР на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж» можна охарактеризувати двома показниками: ступенем наукової новизни та рівнем теоретичного опрацювання.

Значення показників ступеня новизни і рівня теоретичного опрацювання науково-дослідної роботи в балах наведені в табл. 5.1 та 5.2.

Таблиця 5.1 – Показники ступеня новизни науково-дослідної роботи виставлені експертами

Ступінь новизни	Характеристика ступеня новизни	Значення ступеня новизни, бали		
		Експерти (ПІБ, посада)		
		1	2	3
1	2	3	4	5
Принципово нова	Робота якісно нова за постановкою задачі і ґрунтується на застосуванні оригінальних методів дослідження. Результати дослідження відкривають новий напрям в даній галузі науки і техніки. Отримані принципово нові факти, закономірності; розроблена нова теорія. Створено принципово новий пристрій, спосіб, метод	0	68	0
Нова	Отримана нова інформація, яка суттєво зменшує невизначеність наявних значень (по-новому або вперше пояснені відомі факти, закономірності, впроваджені нові поняття, розкрита структура змісту). Проведено суттєве вдосконалення, доповнення і уточнення раніше досягнутих результатів	55	0	60
Відносно нова	Робота має елементи новизни в постановці задачі і методах дослідження. Результати дослідження систематизують і узагальнюють наявну інформацію, визначають шляхи подальших досліджень; вперше знайдено зв'язок (або знайдено новий зв'язок) між явищами. В принципі відомі положення розповсюджені на велику кількість об'єктів, в результаті чого знайдено ефективне рішення. Розроблені більш прості способи для досягнення відомих результатів. Проведена часткова раціональна модифікація (з ознаками новизни)	0	0	0

Продовження таблиці 5.1.

1	2	3	4	5
Традиційна	Робота виконана за традиційною методикою. Результати дослідження мають інформаційний характер. Підтверджені або поставлені під сумнів відомі факти та твердження, які потребують перевірки. Знайдено новий варіант рішення, який не дає суттєвих переваг в порівнянні з існуючим	0	0	0
Не нова	Отримано результат, який раніше зафіксований в інформаційному полі, та не був відомий авторам	0	0	0
Середнє значення балів експертів		61,0		

Згідно отриманого середнього значення балів експертів ступінь новизни характеризується як принципово нова, тобто робота якісно нова за постановкою задачі і ґрунтується на застосуванні оригінальних методів дослідження.

Таблиця 5.2 – Показники рівня теоретичного опрацювання науково-дослідної роботи виставлені експертами

Характеристика рівня теоретичного опрацювання	Значення показника рівня теоретичного опрацювання, бали		
	Експерт (ПІБ, посада)		
	1	2	3
Відкриття закону, розробка теорії	0	0	0
Глибоке опрацювання проблеми: багатоаспектний аналіз зв'язків, взаємозалежності між фактами з наявністю пояснень, наукової систематизації з побудовою евристичної моделі або комплексного прогнозу	69	70	70
Розробка способу (алгоритму, програми), пристрою, отримання нової речовини	0	0	0
Елементарний аналіз зв'язків між фактами та наявною гіпотезою, класифікація, практичні рекомендації для окремого випадку тощо	0	0	0
Опис окремих елементарних фактів, викладення досвіду, результатів спостережень, вимірювань тощо	0	0	0
Середнє значення балів експертів	69,7		

Згідно отриманого середнього значення балів експертів рівень теоретичного опрацювання науково-дослідної роботи характеризується як глибоке опрацювання проблеми: багатоаспектний аналіз зв'язків, взаємозалежності між фактами з наявністю пояснень, наукової систематизації з побудовою евристичної моделі або комплексного прогнозу.

Показник, який характеризує рівень наукового ефекту, визначаємо за формулою [36]:

$$E_{\text{нау}} = 0,6 \cdot k_{\text{нов}} + 0,4 \cdot k_{\text{теор}}, \quad (5.1)$$

де $k_{\text{нов}}$, $k_{\text{теор}}$ - показники ступеня новизни та рівня теоретичного опрацювання науково-дослідної роботи, $k_{\text{нов}} = 61,0$, $k_{\text{теор}} = 69,7$ балів;

0,6 та 0,4 – питома вага (значимість) показників ступеня новизни та рівня теоретичного опрацювання науково-дослідної роботи.

$$E_{\text{нау}} = 0,6 \cdot k_{\text{нов}} + 0,4 \cdot k_{\text{теор}} = 0,6 \cdot 61,0 + 0,4 \cdot 69,67 = 64,47 \text{ балів.}$$

Визначення характеристики показника $E_{\text{нау}}$ проводиться на основі висновків експертів виходячи з граничних значень, які наведені в табл. 5.3.

Таблиця 5.3 – Граничні значення показника наукового ефекту

Досягнутий рівень показника	Кількість балів
Високий	70...100
Середній	50...69
Достатній	15...49
Низький (помилкові дослідження)	1...14

Відповідно до визначеного рівня наукового ефекту проведеної науково-дослідної роботи на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж», даний рівень становить 64,47 балів і відповідає статусу - середній рівень. Тобто у даному випадку можна вести мову про потенційну фактичну ефективність науково-дослідної роботи.

5.2 Розрахунок витрат на здійснення науково-дослідної роботи

Витрати, пов'язані з проведенням науково-дослідної роботи на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж», під час планування, обліку і калькулювання собівартості науково-дослідної роботи групуємо за відповідними статтями.

5.2.1 Витрати на оплату праці

До статті «Витрати на оплату праці» належать витрати на виплату основної та додаткової заробітної плати керівникам відділів, лабораторій, секторів і груп, науковим, інженерно-технічним працівникам, конструкторам, технологам, креслярам, копіювальникам, лаборантам, робітникам, студентам, аспірантам та іншим працівникам, безпосередньо зайнятим виконанням конкретної теми, обчисленої за посадовими окладами, відрядними розцінками, тарифними ставками згідно з чинними в організаціях системами оплати праці.

Витрати на основну заробітну плату дослідників ($З_o$) розраховуємо у відповідності до посадових окладів працівників, за формулою [36]:

$$З_o = \sum_{i=1}^k \frac{M_{ni} \cdot t_i}{T_p}, \quad (5.2)$$

де k – кількість посад дослідників залучених до процесу досліджень;

M_{ni} – місячний посадовий оклад конкретного дослідника, грн;

t_i – число днів роботи конкретного дослідника, дн.;

T_p – середнє число робочих днів в місяці, $T_p=24$ дні.

$$З_o = 18200,00 \cdot 6 / 24 = 4550,00 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці 5.4.

Таблиця 5.4 – Витрати на заробітну плату дослідників

Найменування посади	Місячний посадовий оклад, грн	Оплата за робочий день, грн	Число днів роботи	Витрати на заробітну плату, грн
Керівник науково-дослідної роботи з дослідження телекомунікаційних систем	18200,00	758,33	6	4550,00
Інженер-дослідник телекомунікаційних систем та мереж	17900,00	745,83	22	16408,33
Науковий співробітник	17950,00	747,92	6	4487,50
Провідний фахівець	8250,00	343,75	4	1375,00
Всього				26820,83

Витрати на основну заробітну плату робітників ($З_p$) за відповідними найменуваннями робіт НДР на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж» розраховуємо за формулою:

$$З_p = \sum_{i=1}^n C_i \cdot t_i, \quad (5.3)$$

де C_i – погодинна тарифна ставка робітника відповідного розряду, за виконану відповідну роботу, грн/год;

t_i – час роботи робітника при виконанні визначеної роботи, год.

Погодинну тарифну ставку робітника відповідного розряду C_i можна визначити за формулою:

$$C_i = \frac{M_M \cdot K_i \cdot K_c}{T_p \cdot t_{зм}}, \quad (5.4)$$

де M_M – розмір прожиткового мінімуму працездатної особи, або мінімальної місячної заробітної плати (в залежності від діючого законодавства), прийmemo $M_M=8000,00$ грн;

K_i – коефіцієнт міжкваліфікаційного співвідношення для встановлення тарифної ставки робітнику відповідного розряду (табл. Б.2, додаток Б) [36];

K_c – мінімальний коефіцієнт співвідношень місячних тарифних ставок робітників першого розряду з нормальними умовами праці виробничих об'єднань і підприємств до законодавчо встановленого розміру мінімальної заробітної плати.

T_p – середнє число робочих днів в місяці, приблизно $T_p = 24$ дн;

$t_{зм}$ – тривалість зміни, год.

$C_1 = 8000,00 \cdot 1,10 \cdot 1,15 / (24 \cdot 8) = 52,71$ грн.

$З_{pl} = 52,71 \cdot 6,00 = 316,25$ грн.

Таблиця 5.5 – Величина витрат на основну заробітну плату робітників

Найменування робіт	Тривалість роботи, год	Розряд роботи	Тарифний коефіцієнт	Погодинн а тарифна ставка, грн	Величина оплати на робітника грн
1	2	3	4	5	6
Установка обладнання для забезпечення моделювання методів оптимізації	6,00	2	1,10	52,71	316,25
Підготовка робочого місця інженера-дослідника телекомунікаційних систем	6,50	4	1,50	71,88	467,19
Інсталяція програмного забезпечення моделювання поведінки систем	7,20	3	1,35	64,69	465,75
Компіляція програмних блоків	5,35	2	1,10	52,71	281,99

Продовження таблиці 5.5

1	2	3	4	5	6
Налагодження програмних блоків	7,20	5	1,70	81,46	586,50
Формування бази даних нейромережі	12,00	2	1,10	52,71	632,50
Попереднє тренування нейромережі	11,00	2	1,10	52,71	579,79
Тестування методів оптимізації на основі нейромережі	6,20	2	1,10	52,71	326,79
Всього					3656,76

Додаткову заробітну плату розраховуємо як 10 ... 12% від суми основної заробітної плати дослідників та робітників за формулою:

$$Z_{\text{доп}} = (Z_o + Z_p) \cdot \frac{H_{\text{доп}}}{100\%}, \quad (5.5)$$

де $H_{\text{доп}}$ – норма нарахування додаткової заробітної плати. Прийmemo 10%.

$$Z_{\text{доп}} = (26820,83 + 3656,76) \cdot 10 / 100\% = 3047,76 \text{ грн.}$$

5.2.2 Відрахування на соціальні заходи

Нарахування на заробітну плату дослідників та робітників розраховуємо як 22% від суми основної та додаткової заробітної плати дослідників і робітників за формулою:

$$Z_n = (Z_o + Z_p + Z_{\text{доп}}) \cdot \frac{H_{\text{зн}}}{100\%} \quad (5.6)$$

де $H_{\text{зн}}$ – норма нарахування на заробітну плату. Приймаємо 22%.

$$Z_n = (26820,83 + 3656,76 + 3047,76) \cdot 22 / 100\% = 7375,58 \text{ грн.}$$

5.2.3 Сировина та матеріали

До статті «Сировина та матеріали» належать витрати на сировину, основні та допоміжні матеріали, інструменти, пристрої та інші засоби і предмети праці, які придбані у сторонніх підприємств, установ і організацій та витрачені на проведення досліджень за темою «Методи оптимізації телекомунікаційних систем на основі нейронних мереж».

Витрати на матеріали на даному етапі проведення досліджень в основному пов'язані з використанням моделей елементів та моделювання роботи і досліджень за допомогою комп'ютерної техніки та створення експериментальних математичних моделей або програмного забезпечення, тому дані витрати формуються на основі витратних матеріалів характерних для офісних робіт.

Витрати на матеріали (M), у вартісному вираженні розраховуються окремо по кожному виду матеріалів за формулою:

$$M = \sum_{j=1}^n H_j \cdot C_j \cdot K_j - \sum_{j=1}^n B_j \cdot C_{ej}, \quad (5.7)$$

де H_j – норма витрат матеріалу j -го найменування, кг;

n – кількість видів матеріалів;

C_j – вартість матеріалу j -го найменування, грн/кг;

K_j – коефіцієнт транспортних витрат, ($K_j = 1,1 \dots 1,15$);

B_j – маса відходів j -го найменування, кг;

C_{ej} – вартість відходів j -го найменування, грн/кг.

$$M_1 = 4 \cdot 195,00 \cdot 1,05 - 0 \cdot 0 = 819,00 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці.

Таблиця 5.6 – Витрати на матеріали

Найменування матеріалу, марка, тип, сорт	Ціна за 1 кг, грн	Норма витрат, кг	Величина відходів, кг	Ціна відходів, грн/кг	Вартість витраченого матеріалу, грн
Офісний папір Ultra Plus	195,00	4	0	0	819,00
Папір для записів Parers Light A5	114,00	2	0	0	239,40
Органайзер офісний OFFICE	194,00	1	0	0	203,70
Канцелярське приладдя (набір офісного працівника)	172,00	4	0	0	722,40
Картридж для принтера Eгіхon EZ2500	920,00	2	0	0	1932,00
Диск оптичний New CD-RW	28,00	3	0	0	88,20
Flesh-пам'ять King 64 GB	144,00	2	0	0	302,40
Тека для паперів BOX	105,00	5	0	0	551,25
Всього					4858,35

5.2.4 Розрахунок витрат на комплектуючі

Витрати на комплектуючі (K_e), які використовують при проведенні НДР на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж» відсутні.

5.2.5 Спецустаткування для наукових (експериментальних) робіт

До статті «Спецустаткування для наукових (експериментальних) робіт» належать витрати на виготовлення та придбання спецустаткування необхідного

для проведення досліджень, також витрати на їх проектування, виготовлення, транспортування, монтаж та встановлення.

Балансову вартість спецустаткування розраховуємо за формулою:

$$B_{\text{спец}} = \sum_{i=1}^k C_i \cdot C_{\text{пр.і}} \cdot K_i, \quad (5.8)$$

де C_i – ціна придбання одиниці спецустаткування даного виду, марки, грн;

$C_{\text{пр.і}}$ – кількість одиниць устаткування відповідного найменування, які придбані для проведення досліджень, шт.;

K_i – коефіцієнт, що враховує доставку, монтаж, налагодження устаткування тощо, ($K_i = 1, 10 \dots 1, 12$);

k – кількість найменувань устаткування.

$$B_{\text{спец}} = 2599,00 \cdot 1 \cdot 1,05 = 2728,95 \text{ грн.}$$

Отримані результати зведемо до таблиці 5.7.

Таблиця 4.7 – Витрати на придбання спецустаткування по кожному виду

Найменування устаткування	Кількість, шт	Ціна за одиницю, грн	Вартість, грн
Маршрутизатор інтернет WiFi6 TP-Link Archer AX23	1	2599,00	2728,95
Всього			2728,95

5.2.6 Програмне забезпечення для наукових (експериментальних) робіт

До статті «Програмне забезпечення для наукових (експериментальних) робіт» належать витрати на розробку та придбання спеціальних програмних засобів і програмного забезпечення, (програм, алгоритмів, баз даних) необхідних для проведення досліджень, також витрати на їх проектування, формування та встановлення.

Балансову вартість програмного забезпечення розраховуємо за

формулою:

$$B_{\text{прог}} = \sum_{i=1}^k C_{\text{прог}} \cdot C_{\text{прог},i} \cdot K_i, \quad (5.9)$$

де $C_{\text{прог}}$ – ціна придбання одиниці програмного засобу даного виду, грн;

$C_{\text{прог},i}$ – кількість одиниць програмного забезпечення відповідного найменування, які придбані для проведення досліджень, шт.;

K_i – коефіцієнт, що враховує інсталяцію, налагодження програмного засобу тощо, ($K_i = 1, 10 \dots 1, 12$);

k – кількість найменувань програмних засобів.

$$B_{\text{прог}} = 9860,00 \cdot 1 \cdot 1,1 = 10846,00 \text{ грн.}$$

Отримані результати зведемо до таблиці 5.8

Таблиця 5.8 – Витрати на придбання програмних засобів по кожному виду

Найменування програмного засобу	Кількість, шт	Ціна за одиницю, грн	Вартість, грн
Математичне середовище MatLab 12	1	9860,00	10846,00
Прикладне ПЗ Mathematica	1	7580,00	8338,00
Хмарний хостинг Cloud Professiona для отримання даних (доступ, місяць)	2	560,00	1232,00
Абонентна плата доступу до мережі Internet (за місяць)	2	400,00	880,00
Collaboratory	1	40,38	44,42
Підтримка домену (місяць)	2	40,38	88,84
VDS (Virtual Dedic Server) Сервер для середовища розробки та тестування	2	3450,00	7590,00
Доступ до нейронної мережі (місяць)	2	250,00	550,00
Всього			29569,25

5.2.7 Амортизація обладнання, програмних засобів та приміщень

В спрощеному вигляді амортизаційні відрахування по кожному виду обладнання, приміщень та програмному забезпеченню тощо, розраховуємо з використанням прямолінійного методу амортизації за формулою:

$$A_{обл} = \frac{Ц_{б}}{T_{г}} \cdot \frac{t_{вик}}{12}, \quad (5.10)$$

де $Ц_{б}$ – балансова вартість обладнання, програмних засобів, приміщень тощо, які використовувались для проведення досліджень, грн;

$t_{вик}$ – термін використання обладнання, програмних засобів, приміщень під час досліджень, місяців;

$T_{г}$ – строк корисного використання обладнання, програмних засобів, приміщень тощо, років.

$$A_{обл} = (22599,00 \cdot 1) / (2 \cdot 12) = 941,63 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці 5.9.

Таблиця 5.9 – Амортизаційні відрахування по кожному виду обладнання

Найменування обладнання	Балансова вартість, грн	Строк корисного використання, років	Термін використання обладнання, місяців	Амортизаційні відрахування, грн
1	2	3	4	5
Персональний комп'ютер дослідника телекомунікаційних систем (HP Laptop 15seq2053ua)	22599,00	2	1	941,63
Робоче місце інженера-дослідника	8415,00	5	1	140,25

Продовження таблиці 5.9.

1	2	3	4	5
Пристрої виводу інформації	7430,00	4	1	154,79
Оргтехніка	7050,00	5	1	117,50
Приміщення лабораторії дослідження ТКС	415000,00	25	1	1383,33
Операційна система Microsoft Windows 10 Home	6520,00	3	1	181,11
Microsoft Office 2016	6480,00	3	1	180,00
Електронно-обчислювальний комплекс моделювання систем QUBE QB i9 10900KF RTX 3060 TI 8GB 1642	59699,00	4	1	1243,73
Всього				4342,34

5.2.8 Паливо та енергія для науково-виробничих цілей

Витрати на силову електроенергію (B_e) розраховуємо за формулою:

$$B_e = \sum_{i=1}^n \frac{W_{yi} \cdot t_i \cdot C_e \cdot K_{gni}}{\eta_i}, \quad (5.11)$$

де W_{yi} – встановлена потужність обладнання на визначеному етапі розробки, кВт;

t_i – тривалість роботи обладнання на етапі дослідження, год;

C_e – вартість 1 кВт-години електроенергії, грн; (вартість електроенергії визначається за даними енергопостачальної компанії), прийmemo $C_e = 10,98$ грн;

K_{eni} – коефіцієнт, що враховує використання потужності, $K_{eni} < 1$;

η_i – коефіцієнт корисної дії обладнання, $\eta_i < 1$.

$$B_e = 0,05 \cdot 180,0 \cdot 10,98 \cdot 0,95 / 0,97 = 98,82 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці.

Таблиця 5.10 – Витрати на електроенергію

Найменування обладнання	Встановлена потужність, кВт	Тривалість роботи, год	Сума, грн
Персональний комп'ютер дослідника ТКС (HP Laptop 15seq2053ua)	0,05	180,0	98,82
Робоче місце інженера-дослідника	0,11	180,0	217,40
Пристрої виводу інформації	0,06	5,0	3,29
Оргтехніка	0,45	2,5	12,35
Маршрутизатор інтернет WiFi6 TP-Link Archer AX23	0,02	180,0	39,53
Електронно-обчислювальний комплекс обробки зображень на базі QUBE QB i9 10900KF RTX 3060 TI 8GB 1642	0,45	180,0	889,38
Всього			1260,78

5.2.9 Службові відрядження

До статті «Службові відрядження» дослідної роботи на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж» належать витрати на відрядження штатних працівників, працівників організацій, які працюють за договорами цивільно-правового характеру, аспірантів, зайнятих розробленням досліджень, відрядження, пов'язані з проведенням випробувань

машин та приладів, а також витрати на відрядження на наукові з'їзди, конференції, наради, пов'язані з виконанням конкретних досліджень.

Витрати за статтею «Службові відрядження» відсутні.

5.2.10 Витрати на роботи, які виконують сторонні підприємства, установи і організації

Витрати за статтею «Витрати на роботи, які виконують сторонні підприємства, установи і організації» відсутні.

5.2.11 Інші витрати

До статті «Інші витрати» належать витрати, які не знайшли відображення у зазначених статтях витрат і можуть бути віднесені безпосередньо на собівартість досліджень за прямими ознаками.

Витрати за статтею «Інші витрати» розраховуємо як 50...100% від суми основної заробітної плати дослідників та робітників за формулою:

$$I_{\text{е}} = (Z_{\text{o}} + Z_{\text{р}}) \cdot \frac{H_{\text{ів}}}{100\%}, \quad (5.12)$$

де $H_{\text{ів}}$ – норма нарахування за статтею «Інші витрати», приймемо $H_{\text{ів}} = 50\%$.

$$I_{\text{е}} = (26820,83 + 3656,76) \cdot 50 / 100\% = 15238,80 \text{ грн.}$$

5.2.12 Накладні (загальновиробничі) витрати

До статті «Накладні (загальновиробничі) витрати» належать: витрати, пов'язані з управлінням організацією; витрати на винахідництво та раціоналізацію; витрати на підготовку (перепідготовку) та навчання кадрів; витрати, пов'язані з набором робочої сили; витрати на оплату послуг банків;

витрати, пов'язані з освоєнням виробництва продукції; витрати на науково-технічну інформацію та рекламу та ін.

Витрати за статтею «Накладні (загальновиробничі) витрати» розраховуємо як 100...150% від суми основної заробітної плати дослідників та робітників за формулою:

$$B_{нзв} = (3_o + 3_p) \cdot \frac{H_{нзв}}{100\%}, \quad (5.13)$$

де $H_{нзв}$ – норма нарахування за статтею «Накладні (загальновиробничі) витрати», прийmemo $H_{нзв} = 105\%$.

$$B_{нзв} = (26820,83 + 3656,76) \cdot 105 / 100\% = 32001,47 \text{ грн.}$$

Витрати на проведення науково-дослідної роботи на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж» розраховуємо як суму всіх попередніх статей витрат за формулою:

$$B_{заг} = 3_o + 3_p + 3_{доо} + 3_n + M + K_e + B_{стел} + B_{прк} + A_{обл} + B_e + B_{св} + B_{сп} + I_e + B_{нзв}. \quad (5.14)$$

$$B_{заг} = 26820,83 + 3656,76 + 3047,76 + 7375,58 + 4858,35 + 2728,95 + 29569,25 + 4342,34 + 1260,78 + 15238,80 + 32001,47 = 130900,87 \text{ грн.}$$

Загальні витрати $3B$ на завершення науково-дослідної (науково-технічної) роботи та оформлення її результатів розраховується за формулою:

$$3B = \frac{B_{заг}}{\eta}, \quad (5.15)$$

де η - коефіцієнт, який характеризує етап (стадію) виконання науково-дослідної роботи, прийmemo $\eta = 0,95$.

$$3B = 130900,87 / 0,95 = 137790,39 \text{ грн.}$$

5.3 Оцінювання важливості та наукової значимості науково-дослідної роботи

Оцінювання та доведення ефективності виконання науково-дослідної роботи фундаментального чи пошукового характеру є достатньо складним процесом і часто базується на експертних оцінках, тому має вірогідний характер.

Для обґрунтування доцільності виконання науково-дослідної роботи на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж» використовується спеціальний комплексний показник, що враховує важливість, результативність роботи, можливість впровадження її результатів у виробництво, величину витрат на роботу.

Комплексний показник K_p рівня науково-дослідної роботи може бути розрахований за формулою:

$$K_p = \frac{I^n \cdot T_C \cdot R}{B \cdot t}, \quad (5.16)$$

де I – коефіцієнт важливості роботи. Прийmemo $I = 4$;

n – коефіцієнт використання результатів роботи; $n = 0$, коли результати роботи не будуть використовуватись; $n = 1$, коли результати роботи будуть використовуватись частково; $n = 2$, коли результати роботи будуть використовуватись в дослідно-конструкторських розробках; $n = 3$, коли результати можуть використовуватись навіть без проведення дослідно-конструкторських розробок. Прийmemo $n = 3$;

T_C – коефіцієнт складності роботи. Прийmemo $T_C = 1$;

R – коефіцієнт результативності роботи; якщо результати роботи плануються вище відомих, то $R = 4$; якщо результати роботи відповідають відомому рівню, то $R = 3$; якщо нижче відомих результатів, то $R = 1$. Прийmemo $R = 3$;

B – вартість науково-дослідної роботи, тис. грн. Прийmemo $B = 137790,39$ грн;

t – час проведення дослідження. Прийmemo $t = 0,08$ років, (1 міс.).

Визначення показників I , n , T_C , R , B , t здійснюється експертним шляхом або на основі нормативів [36].

$$K_p = \frac{I^n \cdot T_C \cdot R}{B \cdot t} = 4^3 \cdot 1 \cdot 3 / 137,8 \cdot 0,08 = 16,72.$$

Якщо $K_p > 1$, то науково-дослідну роботу на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж» можна вважати ефективною з високим науковим, технічним і економічним рівнем.

5.4 Висновок до розділу

Витрати на проведення науково-дослідної роботи на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж» складають 137790,39 грн. Відповідно до проведеного аналізу та розрахунків рівень наукового ефекту проведеної науково-дослідної роботи на тему «Методи оптимізації телекомунікаційних систем на основі нейронних мереж» є середній, а дослідження актуальними, рівень доцільності виконання науково-дослідної роботи $K_p > 1$, що свідчить про потенційну ефективність з високим науковим, технічним і економічним рівнем.

ВИСНОВКИ

Оптимізація телекомунікаційних систем за допомогою нейронних мереж — це ефективний підхід, який використовує здатність нейронних мереж навчатися з даних та знаходити складні патерни. Можливими є такі застосування нейронних мереж:

1. Прогнозування навантаження: Нейронні мережі можуть аналізувати статистичні дані про трафік і використовувати їх для прогнозування майбутнього навантаження. Це дозволяє ефективно планувати ресурси і уникати перевантажень.
2. Оптимізація маршрутизації: За допомогою нейронних мереж можна оптимізувати маршрути передачі даних у мережі, враховуючи різні параметри, такі як затримки, пропускна спроможність і надійність зв'язку.
3. Управління ресурсами: Нейронні мережі можуть допомогти у розподілі ресурсів (наприклад, частот або смуг пропускання) між різними користувачами або сервісами, що дозволяє зменшити витрати та підвищити ефективність.
4. Виявлення аномалій: Нейронні мережі можуть навчатися на трафіку з нормальними характеристиками і виявляти аномалії, що може вказувати на кібератаки або проблеми з якістю зв'язку.
5. Управління якістю послуг: Нейронні мережі можуть аналізувати дані про якість послуг у реальному часі і автоматично налаштовувати параметри мережі для забезпечення оптимальної якості зв'язку.
6. Оптимізація розташування базових станцій: Нейронні мережі можуть допомогти у визначенні оптимальних місць для розташування базових станцій, враховуючи фактори, такі як щільність населення, рельєф місцевості та існуюча інфраструктура.
7. Системи підтримки рішень: Нейронні мережі можуть використовуватися в системах підтримки рішень для допомоги операторам у прийнятті обґрунтованих рішень щодо управління мережею.

Загалом, нейронні мережі відкривають нові можливості для оптимізації телекомунікаційних систем, дозволяючи більш ефективно управляти ресурсами, покращувати якість послуг і адаптувати мережу до змінних умов.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Климаш М.М. Підвищення ефективності розподілу ресурсів телекомунікаційної мережі шляхом зміни маршрутів передавання даних [Електронний ресурс] / М.М. Климаш, Б.А. Бугиль, О.А. Лаврів, І.В. Демидов // Проблеми телекомунікацій. – 2012. – № 4 (9). – С. 32 – 44.
2. Климаш Ю.В. Комплексний метод маршрутизації інформаційних потоків у самоорганізованих мережах / Ю.В. Климаш, О.М. Шпур, М.В. Кайдан // Вісник Національного університету «Львівська політехніка». Радіoeлектроніка та телекомунікації №885 – Львів. – 2017. – С.76-87
3. Климаш М.М. Модель адаптивного управління радіоресурсами в безпроводних гетерогенних мережах / М.М. Климаш, М.І. Бешлей, А.Р. Масюк // VIII Міжнародна науково-технічна конференція «Проблеми телекомунікацій» ПТ-2015: збірник матеріалів конференції (22-25 квітня 2015р., м. Київ, Україна), 2015 - К.: НТТУ «КПІ». – С.40-42.
4. Захарченко С. М. Метод вдосконалення одношляхових протоколів динамічної маршрутизації / С. М. Захарченко, К. І. Шевчук // Інформаційні технології та комп'ютерна інженерія. - 2018. - № 2. - С. 16-25. - Режим доступу: http://nbuv.gov.ua/UJRN/Itki_2018_2_5
5. Бешлей М.І. Підвищення ефективності роботи гетерогенних мереж методом динамічного перерозподілу ресурсів між різними безпроводовими технологіями / Бешлей М.І., Селюченко М.О., Гуськов П.О., Масюк А.Р. // Міжнародна науково-технічна конференція «Сучасні інформаційно-телекомунікаційні технології»: матеріали науково-технічної конференції (17-20 листопада 2015 р. м.Київ), Т.2 – К: ДУТ. – 2015. – С. 49–50.
6. М.О. Селюченко, Г.В. Бешлей, А.Р. Масюк, М.І. Бешлей, "Багаторівневе управління ресурсами в гетерогенній мульти-операторській мережі," 1st International Conference "Advanced Information and Communication Technologies"(AICT'2015), Lviv, 2015, pp. 125 – 128.

7. Масюк А. Р. Алгоритм інтелектуального вертикального хендоверу в гетерогенній мобільній мережі на основі хмарних обчислень / А. Р. Масюк, І.Б. Стрихалюк, М. В. Брич, І. О. Кагало, Г. В. Бешлей // Вісник Національного університету «Львівська політехніка». Серія: Радіoeлектроніка та телекомунікації. — Львів: Видавництво Львівської політехніки, 2017. — № 874. — С. 110–121.
8. Лемешко О. В., Єременко О. С. Розробка та дослідження лінійної оптимізаційної моделі швидкої перемаршрутизації з балансуванням навантаження в телекомунікаційних мережах. Радіoeлектроніка и информатика. 2017. № 4 (79). С. 18–25.
9. Лемешко О. В., Єременко О. С. Динамічна модель маршрутизації при забезпеченні якості обслуговування за показником ймовірності своєчасної доставки пакетів. XI Міжнародна науково-технічна конференція «Проблеми телекомунікацій» ПТ-2017: збірник матеріалів конференції (м. Київ, 18–21 квітня 2017). Київ: КПІ ім. Ігоря Сікорського, 2017. С. 285–287.
10. Одарченко Р.С. Гнатюк В.А. Концептуальні засади підвищення рівня кібербезпеки сучасних стільникових мереж // Безпека інформації. - 2016. - Т. 22, № 2. - С. 143-149.
11. Одарченко Р.С. Обґрунтування основних вимог до систем безпеки стільникових мереж 5-го покоління. - Безпека інформації. Вип №3 (Том 21) - 2015., С. 229-235
12. Одарченко Р.С., Беженар Ю.В., Ксендзенко А.О. Аналіз вразливостей систем захисту інформації в мережі Wi-Max та методів їх усунення // Захист інформації. Зб. наукових праць.- К .: НАУ, 2011. - Вип. 18. - С. 39-44.
13. Куліш Є.Б. Використання адаптивної динамічної маршрутизації на мультисервісних мережах зв'язку / Є.Б. Куліш, А.Г. Ложковський, В.В. Кичак // Вимірювальна та обчислювальна техніка в технологічних процесах. – 2013. - №1. – С. 198-201.

- 14.Т.А. Максимюк, Б.П. Шубин, Д.О. Мисаковець, В.С. Андрушак, С.С. Думич, “Метод адаптивного логічного розділення мережі 5G на основі глибокого навчання”, Вчені записки Таврійського Національного університету імені В.І. Вернадського. Серія: Технічні науки, том 31(70), № 5, С. 36-42, 2020.
- 15.Глоба Л. С. Метод вибору мережі доступу в мобільній системі SDR при вертикальному хендовері / Л. С. Глоба, С. В. Суліма, В. В. Курдеча // Вісник Національного університету "Львівська політехніка". – 2014. – № 796 : Радіoeлектроніка та телекомунікації. – С. 69-74.
- 16.Єрохін В. Ф. Аналіз і прогноз розвитку систем мобільного зв'язку загального користування / В. Ф. Єрохін, Б. А. Гиндич, О. В. Кувшинов. — Збірник наукових праць ВІПІ НТУУ „КПІ” № 1. — 2011. — С. 54–64.
- 17.Москаленко А. О. Дослідження механізмів забезпечення інформаційної безпеки в існуючих та перспективних системах рухомого зв'язку А. О. Москаленко, О. В. Федін // Наука і техніка Повітряних Сил Збройних Сил України. - 2013. - № 1. - С. 99-103.
- 18.Бак Р.І. Метод балансування абонентського навантаження мережі коміркового зв'язку / Бак Р.І., Чайковський І.Б., Бурачок Р.А. // Вісник Національного університету "Львівська політехніка". Радіoeлектроніка та телекомунікації. – 2013. № 766. С. 110-115.
- 19.Усік П.С., Смірнов О.А. Дослідження перспектив використання технологічних рішень в мережах 5g. Кібербезпека та інформаційні технології: монографія. Харків: ДІСА ПЛЮС, 2020. С. 122–135.
- 20.Бондарев А.П., Мандзій Б.А., Давіденко С.В. Пристрої цифрових систем стільникового зв'язку. Навчальний посібник. — Львів: Видавництво Львівської політехніки, 2011. — 224 с.
- 21.Троцько В.В. Методи штучного інтелекту: навчально-методичний і практичний посібник. – Київ: Університет економіки та права «КРОК», 2020 – 86 с.

- 22.Інтелектуальні системи автоматизації : монографія / Аврунін О. Г., Владов С. І., Петченко М. В., Семенець В. В., Татарінов В. В., Тельнова Г. В., Філатов В. О., Шмельов Ю. М., Шушляпіна Н. О. – Кременчук : Видавництво «НОВАБУК», 2021. – 322 с.
- 23.Дранишников Л.В.Інтелектуальні методи в управлінні: навчальний посібник. — Кам'янське: ДДТУ, 2018. — 416 с.
- 24.Кирик В. В. Математичний апарат штучного інтелекту в електроенергетичних системах. – Київ : КПІ ім. Ігоря Сікорського, Вид-во «Політехніка» 2019. – 226 с.
- 25.Методи та системи штучного інтелекту: навч. посібник /. А. С. Савченко, О. О. Синельніков. - К. : НАУ, 2017. — 176 с
- 26.Нікольський Ю. В. Системи штучного інтелекту : навч. посібник. – 2-ге вид., випр. та доп. / Нікольський Ю. В. – Львів : Магнолія-2006, 2013. – 279 с/
- 27.Кононюк А.Ю. Нейронні мережі і генетичні алгоритми – К.:«Корнійчук», . 2008. – 446 с.
- 28.Навчальний посібник «Методи та системи штучного інтелекту» для студентів спеціальності 122 «Комп'ютерні науки» / Уклад.: І.М. Удовик, Г.М. Коротенко, Л.М. Коротенко, В.О. Трусов, А.Т. Харь. – Д.: Державний ВНЗ «Національний гірничий університет», 2017. – 105 с.
- 29.Терейковський, І. А. Штучні нейронні мережі: базові положення: навчальний посібник для здобувачів ступеня бакалавра за освітньою програмою «Системне програмування та спеціалізовані комп'ютерні системи» спеціальності 123 Комп'ютерна інженерія / І. А. Терейковський, Д. А. Бушуєв, Л. О. Терейковська ; КПІ ім. Ігоря Сікорського. – Київ : КПІ ім. Ігоря Сікорського, 2022. – 123 с.
- 30.Терейковський, І. А. Інтелектуалізовані методи захисту інформації: нейронні мережі в захисті інформації : навчальний посібник для здобувачів ступеня бакалавр за освітньою програмою «Системне програмування та спеціалізовані комп'ютерні системи» спеціальності 123

Комп'ютерна інженерія / І. А. Терейковський, А. О. Корченко ; КПІ ім. Ігоря Сікорського. – Київ : КПІ ім. Ігоря Сікорського, 2022. – 176 с.


31. Застосування штучних нейронних мереж для обробки інформації в технічних системах моніторингу навколишнього середовища. Навчальний посібник. / Перелигін Б.В., Ткач Т.Б.; Одеський держ. Екологічний університет. – Одеса: ТЕС, 2014 р. – 218 с.
32. Основи нейрокомп'ютингу : навчально-методичний посібник до практичних занять / В. Д. Дмитрієнко, О. Ю. Заковоротний, В. І. Носков, М. В. Мезенцев. – Х.: НТМТ, 2014. – 140 с.
33. Нейронні мережі : теорія та практика: навч. посіб. С. О. Субботін. – Житомир : Вид. О. О. Євенок, 2020. – 184 с.
34. Теорія та практика нейронних мереж : навч. посіб. / Л. М. Добровська, І. А. Добровська. – К. : НТУУ «КПІ», «Політехніка», 2015. – 396 с.
35. С.В. Ткаліченко. Штучні нейронні мережі: Навчальний посібник. – Кривий Ріг: Державний університет економіки і технологій, 2023. – 150 с.
36. Методичні вказівки до виконання економічної частини магістерських кваліфікаційних робіт / Уклад. : В. О. Козловський, О. Й. Лесько, В. В. Кавецький. – Вінниця : ВНТУ, 2021. – 42

ДОДАТКИ

Додаток А
(обов'язковий)

ІЛЮСТРАТИВНА ЧАСТИНА
МЕТОДИ ОПТИМІЗАЦІЇ ТЕЛЕКОМУНІКАЦІЙНИХ СИСТЕМ
НА ОСНОВІ НЕЙРОННИХ МЕРЕЖ
назва магістерської кваліфікаційної роботи

Інтелектуальні технології



Інтелектуальні технології характеризуються такими відмінностями:


- Відсутність моделі.
- Апроксимація замість точного рішення.
- Більш швидке знаходження потрібного розв'язку.

Основна область застосування – вирішення проблем оптимізації.


Класифікація нейронних мереж



Штучна нейронна мережа



Прогнозування напруженості поля



Розподіл частотних каналів у мережі




Рисунок 1 - Розподіл частотних каналів для чотирьохкоміркової мережі




Рисунок 2 - Подання виходів 4×11 нейронів, використовуваних

Прогнозування характеристик




Рисунок 1 – Нейронна мережа з прямим поширенням сигналу




Рисунок 2 – Статистична оцінка помилки прогнозування




Рисунок 3 – Дослідження роботи нейронної мережі в умовах зашумленості вхідних значень

Керування мережею




Рисунок 1 – Прогнозування переміщення мобільного пристрою




Рисунок 2 – Рекурентна нейронна мережа




Рисунок 3 – Блок-схема алгоритму керування

Маршрутизація в мережі




Рисунок 1 – Телекомунікаційна мережа як граф




Рисунок 2 – Схема навчання з підкріпленням




Рисунок 3 – Блок-схема алгоритму маршрутизації

Розроблення мережі у програмі Matlab




Рисунок 1 - Створення нейро-нечіткої мережі у програмі Matlab




Рисунок 2— Вигляд нейро-нечіткої мережі у програмі Matlab

Моделювання мережі у програмі Matlab



Рисунок 1 - Результат роботи мережі у програмі Matlab




Рисунок 2 – Результат навчання мережі

ПРОТОКОЛ ПЕРЕВІРКИ МАГІСТЕРСЬКОЇ КВАЛІФІКАЦІЙНОЇ РОБОТИ

Назва роботи: Методи оптимізації телекомунікаційних систем на основі нейронних мереж

Тип роботи: Магістерська кваліфікаційна робота

Підрозділ кафедра ІКСТ, факультет ІЕС

Керівник Семенова О.О., к.т.н., доцент

Показники звіту подібності

Turnitin	
Оригінальність	80%
Загальна схожість	20%

Аналіз звіту подібності (відмітити потрібне)

- Запозичення, виявлені у роботі, оформлені коректно і не містять ознак плагіату.
- Виявлені у роботі запозичення не мають ознак плагіату, але їх надмірна кількість викликає сумніви щодо цінності роботи і відсутності самостійності її автора. Роботу направити на доопрацювання.
- Виявлені у роботі запозичення є недобросовісними і мають ознаки плагіату та/або в ній містяться навмисні спотворення тексту, що вказують на спроби приховування недобросовісних запозичень.

Заявляю, що ознайомлений (-на) з повним звітом подібності, який був згенерований Системою щодо роботи (додається)

Автор Чев
(підпис)

Чорний К.П.
(прізвище, ініціали)

Опис прийнятого рішення

Особа, відповідальна за перевірку

ку ИЗ
(индиге)

Васильківський М.В.
(прізвище, ініціали)

Експерт _____
(за потреби) (підпис)

(прізвище, ініціали, посада)