

Національний університет «Полтавська політехніка імені Юрія Кондратюка»
Навчально-науковий інститут інформаційних технологій і робототехніки
Кафедра автоматики, електроніки та телекомунікацій

ПОЯСНЮВАЛЬНА ЗАПИСКА

до кваліфікаційної роботи

магістр

на тему: **Застосування нейромережевих алгоритмів для підвищення якості
обслуговування абонентів у телекомунікаційних мережах**

Виконав: студент б курсу, групи 601-ТТ
спеціальності 172 «Телекомунікації та
радіотехніка»

Зіберов П.В.

Керівник Індик С.В.

Рецензент Шефер О.В.

Національний університет «Полтавська політехніка імені Юрія Кондратюка»
Інститут Навчально-науковий інститут інформаційних технологій і робототехніки
Кафедра Автоматики, електроніки та телекомунікацій
Ступінь вищої освіти Магістр
Спеціальність 172 «Телекомунікації та радіотехніка»

ЗАТВЕРДЖУЮ

Завідувач кафедри автоматичної,
електроніки та телекомунікацій

_____ О.В. Шефер
“ ___ ” _____ 2024 р.

ЗАВДАННЯ

НА МАГІСТЕРСЬКУ РОБОТУ СТУДЕНТУ

Зіберову Павлу В'ячеславовичу

- Тема проекту (роботи) «Застосування нейромережових алгоритмів для підвищення якості обслуговування абонентів у телекомунікаційних мережах»
керівник проекту (роботи) Індик Сергій Володимирович, к.т.н., доцент, затверджена наказом вищого навчального закладу від “ ___ ” ___ 2024 року № ___
- Строк подання студентом проекту (роботи) 27.12.2024 р.
- Вихідні дані до проекту (роботи) ВБН В.2.2-33-2007. Проектування телекомунікацій; RFC 4594. «Configuration Guidelines for DiffServ Service Classes», RFC 3439. «Some Internet Architectural Guidelines and Philosophy», NS-3. Програмне забезпечення для моделювання телекомунікаційних мереж, Python. Інструмент для розробки та реалізації нейромережових алгоритмів, TensorFlow та PyTorch. Фреймворки для розробки та навчання нейронних мереж, Стандарти ITU-T E.800. Параметри якості обслуговування (QoS) у телекомунікаційних мережах.
- Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити): Огляд сучасних підходів до побудови розподілених корпоративних мереж. Розгляд стандартів і протоколів, що використовуються в розподілених мережах. Характеристика обладнання для розподіленої корпоративної мережі. Огляд заходів і методів організації інформаційної безпеки в розподілених корпоративних мережах. Розробка логічної структури корпоративної мережі. Оцінка результатів моделювання взаємодії мережових компонентів та аналіз результатів моделювання.
- Перелік графічного матеріалу (з точним зазначенням обов'язкових плакатів):

- 1) Титульний слайд
 - 2) Мета роботи
 - 3) Сучасний стан розвитку бездротових мереж
 - 4) Принцип роботи нейромережевих алгоритмів
 - 5) Застосування нейромережевого алгоритму для підвищення якості обслуговування абонентів безпроводових мереж
 - 6) Практична реалізація безпроводової мережі на основі нейромережевого алгоритму
 - 7) Архітектура нейромережі та процес навчання
 - 8) Формування вибірок та масштабування
 - 9) Висновки
6. Дата видачі завдання 26.09.2024 р.

КАЛЕНДАРНИЙ ПЛАН

Пор. №	Назва етапів магістерської роботи	Термін виконання етапів роботи			Примітка (плакати)
1	Сучасний стан розвитку бездротових мереж	13.10.24		15%	Пл. 1, 2
2	Застосування нейромережевих технологій у телекомунікаційних системах та мережах	27.10.24	I	30%	Пл. 3
3	Реалізація безпроводової мережі на основі застосування нейромережевого алгоритму	10.11.24		40%	Пл. 4
4	Застосування нейромережевого алгоритму для підвищення якості обслуговування абонентів безпроводових мереж	17.11.24		50 %	Пл. 5
5	Практична реалізація безпроводової мережі на основі нейромережевого алгоритму	24.11.24	II	60%	Пл. 6
6	Практична інтеграція нейромережі в телекомунікаційну інфраструктуру. Оцінка результатів досліджень	08.12.24		90%	Пл. 7,8
7	Оформлення магістерської роботи	27.12.24	III	100%	Пл. 9

Магістрант _____ Зіберов П.В.

Керівник роботи _____ Індик С.В.

ЗМІСТ

ПЕРЕЛІК СКОРОЧЕНЬ, УМОВНИХ ПОЗНАЧЕНЬ.....	6
ВСТУП.....	8
1. СУЧАСНИЙ СТАН РОЗВИТКУ БЕЗДРОТОВИХ МЕРЕЖ	10
1.1 Класифікація мереж зв'язку.....	10
1.2 Вимоги до безпроводових мереж зв'язку.....	11
1.3 Переваги використання безпроводових мереж зв'язку.....	13
1.4 Сучасні тенденції розвитку телекомунікаційних систем та мереж	14
2. ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖЕВИХ ТЕХНОЛОГІЙ У ТЕЛЕКОМУНІКАЦІЙНИХ СИСТЕМАХ ТА МЕРЕЖАХ.....	17
2.1 Принцип роботи нейромережових алгоритмів.....	18
2.2 Основні компоненти нейронної мережі:	18
2.3 Архітектури нейронних мереж.....	27
3 РЕАЛІЗАЦІЯ БЕЗПРОВОДОВОЇ МЕРЕЖІ НА ОСНОВІ ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖЕВОГО АЛГОРИТМУ	31
3.1 Принципи роботи когнітивних радіосистем.....	31
3.2 Характеристика стандарту IEEE 802.22	34
3.3 Застосування нейромережового алгоритму для підвищення якості обслуговування абонентів безпроводових мереж	35
4 ПРАКТИЧНА РЕАЛІЗАЦІЯ БЕЗПРОВОДОВОЇ МЕРЕЖІ НА ОСНОВІ НЕЙРОМЕРЕЖЕВОГО АЛГОРИТМУ	38
4.1. Збір та підготовка даних.....	39
4.2. Структура та формат даних, попередня обробка.....	41
4.3 Архітектура нейромережі та процес навчання	46
4.4 Процес навчання	49
4.4.1 Налаштування гіперпараметрів нейромережі.....	49
4.4.2 Формування вибірок та масштабування.....	50

4.4.3 Параметри навчання нейромережі.....	51
4.4.4 Навчання за допомогою віконного підходу (window method).....	52
4.4.5 Виконання навчання.....	53
4.5 Результати навчання та перевірки.....	55
4.5.1 Тренувальна й валідаційна похибка	55
4.5.2 Оцінка на тестовому наборі	56
4.6 Практична інтеграція нейромережі в телекомунікаційну інфраструктуру	59
ЗАГАЛЬНІ ВИСНОВКИ.....	62
Список використаних джерел	63
Додаток А — Розділ 1 (Англійська версія)	66
Додаток Б — Уніфікація та об'єднання CSV-файлів із різних джерел	73
Додаток В — Код розподілу вибірок	76
Додаток Г — Код навчання нейромережі на підготовлених даних	79
Додаток Д — Вивід в консоль процесу навчання	82
Додаток Е — Код визначення показників MSE, MAE, MAPE, R^2	85
Додаток Є — Презентаційний матеріал	87

ПЕРЕЛІК СКОРОЧЕНЬ, УМОВНИХ ПОЗНАЧЕНЬ

5G — Технологія мобільного зв'язку п'ятого покоління

CellID — Унікальний ідентифікатор вежі

CNN — Згорткові нейронні мережі

DDoS (Distributed Denial of Service) — розподілена атака на відмову в обслуговуванні

DSA — Динамічне управління спектром

GANs — Генеративно—змагальні мережі

IoT — (Internet of Things). Інтернет речей, концепція мережевого підключення фізичних пристроїв

LAC (Location Area Code) — Ідентифікатор території, що покривається мережею

LAN — Локальна мережа

Latitude — Географічна широта (у десяткових градусах)

Longitude — Географічна довгота (у десяткових градусах)

LTE — (Long-Term Evolution). Технологія бездротового зв'язку четвертого покоління (4G)

LSTM — Рекурсивно нейронна мережа

MAN — Регіональна мережа

MCC (Mobile Country Code) — Код країни мобільного оператора

MLP — Багатошаровий перцептрон

MNC (Mobile Network Code) — Код мобільного оператора в країні

NS-3 — Симулятор мереж

OFDM — Orthogonal Frequency Division Multiplexing

PU — Первинний користувач

QoS — Якість обслуговування

Range — Радіус дії вежі (у метрах)

ReLU — Rectified Linear Unit

RNN — Рекурентні нейронні мережі

Samples — Кількість разів, коли дані про цю вежу були зареєстровані

SDN — Програмно-конфігурована мережа

WPA3 — (Wi-Fi Protected Access 3). Протокол забезпечення безпеки бездротових мереж

WRAN — Бездротова регіональна мережа

Wi-Fi — Технологія бездротової передачі даних за стандартами IEEE 802.11

KPC — Когнітивна радіосистема

ВСТУП

Сучасні телекомунікаційні мережі відіграють фундаментальну роль у побудові інформаційного суспільства, забезпечуючи високу швидкість передачі даних, мобільність користувачів та зручність у використанні. Зростання обсягів інформації, що передається через ці мережі, створює серйозні виклики для інфраструктури, вимагаючи нових підходів до управління ресурсами та підвищення ефективності. Актуальність цієї теми обумовлена необхідністю розробки інноваційних рішень, здатних відповідати зростаючим вимогам сучасного суспільства та економіки.

Інтеграція штучного інтелекту, зокрема нейромережевих алгоритмів, у телекомунікаційні мережі відкриває нові можливості для адаптивного управління ресурсами. Використання таких алгоритмів дозволяє прогнозувати навантаження, оптимізувати маршрутизацію даних, знижувати затримки передачі та підвищувати загальну енергоефективність мереж. Особливу цінність мають системи, які динамічно адаптуються до змінних умов, забезпечуючи стабільну якість обслуговування навіть за умов перевантаження.

Аналіз сучасного стану розвитку телекомунікаційних мереж вказує на недостатню ефективність існуючих рішень у контексті забезпечення масштабованості, мобільності та інтеграції нових технологій, таких як Інтернет речей (IoT). У цьому аспекті вивчення досвіду провідних компаній, таких як Huawei, Ericsson, та аналіз патентної бази стають важливими для формування нових підходів.

Метою цієї роботи є розробка нейромережевої системи управління телекомунікаційними ресурсами, яка здатна адаптуватися до умов змінного навантаження та специфіки переданих даних. Для досягнення цієї мети поставлено наступні задачі:

1. Провести аналіз сучасного стану розвитку бездротових мереж.

2. Вивчити принципи роботи нейромережевих алгоритмів та їх застосування у телекомунікаційних системах.
3. Розробити прототип нейромережевої системи для адаптивного управління ресурсами.
4. Провести тестування і аналіз ефективності запропонованого рішення.

Методи досліджень включають аналіз наукової та технічної літератури, патентний пошук, моделювання роботи нейромереж та експериментальну перевірку запропонованих алгоритмів. Основні проектні рішення базуються на використанні сучасних стандартів телекомунікацій, таких як 5G, та інтеграції технологій штучного інтелекту для підвищення ефективності роботи мереж. Сучасні умови висувають значно вищі вимоги до систем зв'язку. Збільшення кількості підключених пристроїв, зростання трафіку, необхідність ефективного управління ресурсами та забезпечення високої якості обслуговування стали ключовими викликами для індустрії. У цьому контексті використання нейромережевих алгоритмів дозволяє здійснювати ефективний аналіз і прогнозування навантаження на мережі, оптимізувати маршрутизацію, знижувати затримки передачі даних і підвищувати енергоефективність. Впровадження цих алгоритмів відкриває нові можливості для адаптивного управління мережевими ресурсами, що є необхідним для задоволення потреб користувачів.

Метою даної роботи є глибокий аналіз сучасного стану розвитку бездротових мереж, дослідження їхніх можливостей і викликів, а також інтеграція нейромережевих рішень у практичні системи для підвищення якості обслуговування абонентів. Практична частина передбачає розробку прототипу нейромережевої системи, яка здатна адаптуватися до змін у навантаженні та специфіці даних у реальному часі.

1. СУЧАСНИЙ СТАН РОЗВИТКУ БЕЗДРОТОВИХ МЕРЕЖ

1.1 Класифікація мереж зв'язку




Рисунок 1 — Графічне зображення зв'язку [1]

Мережі зв'язку є невід'ємною частиною сучасного інформаційного суспільства, забезпечуючи передачу даних між пристроями, людьми та організаціями. Для їх аналізу та проектування важливо розуміти класифікацію таких мереж за різними характеристиками. Це дозволяє враховувати особливості функціонування мереж і адаптувати їх до специфічних потреб.

Один із ключових підходів до класифікації мереж базується на їх територіальному охопленні. Локальні мережі (LAN) забезпечують зв'язок у межах невеликих територій, таких як офіс або будівля. Вони характеризуються високою швидкістю передачі даних і невеликими затримками. Наприклад, використання стандарту Ethernet у локальних мережах дозволяє досягати швидкості до 10 Гбіт/с, що є достатнім для більшості офісних завдань [2].

Регіональні мережі (MAN) мають більший масштаб, охоплюючи цілі міста чи регіони. Такі мережі є важливими для об'єднання офісів компаній або забезпечення зв'язку між установами. У свою чергу, глобальні мережі (WAN), наприклад, Інтернет, забезпечують зв'язок між країнами та континентами. WAN використовує розгалужену інфраструктуру, включаючи супутники, оптоволоконні кабелі та наземні ретранслятори [3].

Ще один підхід до класифікації мереж ґрунтується на типі середовища передачі даних. Провідні мережі передбачають використання фізичних середовищ, таких як мідні кабелі або оптоволоконні лінії, що забезпечує високу надійність і захищеність від перешкод. У той же час, безпроводові мережі, які використовують радіохвилі, дозволяють створювати мобільні рішення. Особливо актуальними є технології LTE та 5G, які надають можливість працювати з великими обсягами даних навіть у місцях без розвиненої інфраструктури [4].

Важливим аспектом класифікації є і топологія мережі. Наприклад, сітчасті (Mesh) мережі забезпечують високу стійкість до збоїв, адже кожен пристрій може бути пов'язаний із кількома іншими. Це дозволяє створювати надійні телекомунікаційні системи навіть за умов пошкодження окремих ланок мережі [4].

1.2 Вимоги до безпроводових мереж зв'язку

Розвиток безпроводових мереж зв'язку став невід'ємною частиною сучасного цифрового світу. Вони забезпечують мобільність користувачів і доступ до інформації в будь-якому місці. Однак для забезпечення їхньої ефективності та надійності необхідно дотримуватися ряду вимог, що охоплюють різні аспекти, від технологічних параметрів до безпеки передачі даних.

1. Надійність і стабільність зв'язку

Безпроводові мережі повинні забезпечувати високий рівень надійності навіть за умов слабого сигналу чи перешкод. Це досягається завдяки використанню

сучасних технологій модуляції та адаптації частоти. Наприклад, технологія 5G використовує механізми множинного доступу (MIMO), які значно покращують стабільність зв'язку навіть у складних середовищах [6].

2. Пропускна здатність

Для підтримки сучасних сервісів, таких як потокове відео у форматі 4K чи інтернет речей (IoT), мережі повинні забезпечувати високу пропускну здатність. Стандарти, як-от IEEE 802.11ax (Wi-Fi 6), розроблені з урахуванням зростаючих вимог до обсягу переданих даних і забезпечують швидкість до 9,6 Гбіт/с [7].

3. Енергоефективність

Зважаючи на обмежені ресурси мобільних пристроїв, безпроводові мережі повинні мінімізувати споживання енергії. Наприклад, технології вузькосмугового зв'язку для IoT, такі як NB-IoT, оптимізовані для енергоефективності, що дозволяє пристроям працювати від батареї протягом багатьох років [8].

4. Захист даних і кібербезпека

Одним із найважливіших аспектів безпроводових мереж є захист даних. Для запобігання несанкціонованому доступу та забезпечення конфіденційності інформації використовуються шифрувальні протоколи, такі як WPA3. Важливим є також виявлення та протидія кібератакам, які можуть паралізувати роботу мереж [9].

5. Мобільність і масштабованість

Мережі повинні підтримувати мобільність користувачів без втрати якості зв'язку під час переміщення. Це особливо актуально для мереж 5G, які забезпечують передачу даних навіть на швидкості до 500 км/год, наприклад, у транспортних системах [10]. Крім того, мережі мають бути здатними до масштабування для підключення мільйонів пристроїв у межах одного вузла, що критично важливо для розгортання IoT-екосистем.

6. Мінімізація затримок

Затримка передачі даних є ключовим параметром для багатьох додатків, включно з автономним транспортом і хірургічними роботами. Технології 5G здатні

забезпечувати затримку менше 1 мс, що є значним проривом порівняно з попередніми стандартами [11].

1.3 Переваги використання безпроводових мереж зв'язку

Безпроводові мережі зв'язку стають дедалі популярнішими завдяки своїм численним перевагам, що дозволяють забезпечити ефективне й зручне передавання даних у різноманітних умовах. Нижче наведено основні переваги таких мереж.

Гнучкість та мобільність

Одна з найважливіших переваг безпроводових мереж — це можливість забезпечити мобільний доступ до мережі. Користувачі можуть підключатися до мережі практично з будь-якого місця, що особливо важливо для сучасного способу життя, орієнтованого на мобільність [12]. Така гнучкість сприяє більш ефективному використанню ресурсів, зокрема в корпоративному середовищі та серед індивідуальних користувачів.

Економія коштів на інфраструктуру

Використання безпроводових мереж дозволяє уникнути необхідності прокладання кабелів, що може бути особливо складним і дорогим у важкодоступних регіонах. Наприклад, безпроводові технології є ідеальним рішенням для віддалених сільських районів, де побудова традиційної інфраструктури може бути економічно недоцільною [13].

Простота встановлення та масштабування

Безпроводові мережі легко встановлюються, що значно зменшує час розгортання мережі. До того ж, масштабування такої мережі є значно простішим порівняно з дротовими рішеннями: додавання нових користувачів не потребує значних змін у фізичній інфраструктурі [14].

Забезпечення зв'язку в надзвичайних ситуаціях

Безпроводові мережі грають ключову роль у забезпеченні зв'язку в умовах стихійних лих чи інших надзвичайних ситуацій. Відсутність залежності від фізичних ліній зв'язку робить такі мережі більш стійкими до пошкоджень і забезпечує оперативне відновлення роботи систем [15].

Підтримка сучасних технологій

Безпроводові мережі є основою для впровадження інноваційних технологій, таких як Інтернет речей (IoT), розумні міста та автономні транспортні засоби. Наприклад, стандарт 5G забезпечує високу швидкість передачі даних, низькі затримки та можливість обробки великої кількості одночасних підключень, що робить його ключовим для розвитку цих напрямів [16].

Екологічність

Ще однією перевагою безпроводових мереж є їхній менший екологічний вплив у порівнянні з дротовими рішеннями. Відсутність потреби у виробництві й прокладанні кабелів дозволяє зменшити використання матеріалів і знизити вплив на навколишнє середовище [17].

1.4 Сучасні тенденції розвитку телекомунікаційних систем та мереж

Сучасний розвиток телекомунікаційних систем та мереж зв'язку характеризується стрімким впровадженням інноваційних технологій, спрямованих на задоволення зростаючих потреб користувачів у швидкості, надійності та якості передачі даних. Основними тенденціями розвитку є наступні:

Впровадження технологій 5G.

Однією з ключових тенденцій є активне розгортання мереж п'ятого покоління (5G), які забезпечують високі швидкості передачі даних, знижену затримку та підвищену пропускну здатність. Це відкриває нові можливості для таких сфер, як Інтернет речей (IoT), автономний транспорт, телемедицина та індустрія розваг [19].

Наприклад, Україна активно готується до впровадження технології 5G. У травні 2024 року відбувся перший тестовий запуск 5G-зв'язку: інноваційний центр "Промприлад" в Івано-Франківську, офіс Vodafone у Києві та офіс Nokia в Гельсінкі провели відеозв'язок за допомогою 5G, підтвердивши працездатність технології. [25]

У листопаді 2024 року уряд України ухвалив постанову про запуск пілотного проєкту 5G у трьох містах. Протягом двох років планується тестування обладнання та перевірка сумісності мереж 5G з військовими технологіями, що є важливим кроком до повноцінного запуску 5G в Україні до 2030 року. [26]

Конвергенція мереж зв'язку.

Спостерігається інтеграція фіксованих і мобільних мереж для забезпечення безперервного доступу до інтернету незалежно від місця перебування користувачів. Це дозволяє створювати єдину інфраструктуру для ефективного управління ресурсами мережі [19].

Зростання популярності хмарних технологій

Розширюється використання хмарних обчислень у телекомунікаціях, що дозволяє зменшити витрати на обладнання та забезпечити гнучкість у наданні послуг. Хмарні рішення також сприяють швидшій обробці даних та забезпеченню надійного зберігання [20].

Інтернет речей (IoT)

Масове підключення пристроїв до мережі стало можливим завдяки вдосконаленню телекомунікаційної інфраструктури. IoT трансформує різні галузі, зокрема розумні будинки, логістику, виробництво та енергетику [21]. Інтернет речей (IoT) знаходить дедалі ширше застосування в Україні, особливо в аграрному секторі. Використання IoT-технологій у сільському господарстві дозволяє підвищити врожайність через постійний моніторинг умов довкілля, оптимізувати управління ресурсами та зменшити витрати. [27]

Крім того, IoT-технології впроваджуються в українських містах для створення "розумних" інфраструктур. Це включає автоматизацію управління

енергоспоживанням, транспортом та іншими міськими системами, що сприяє підвищенню ефективності та зменшенню витрат. [28]

Розвиток штучного інтелекту та машинного навчання

Інтелектуальні алгоритми використовуються для оптимізації роботи мереж, передбачення навантаження та виявлення збоїв. Це сприяє підвищенню надійності телекомунікаційних систем і поліпшенню якості обслуговування користувачів [22].

Впровадження віртуалізації та програмно-визначених мереж (SDN)

Програмно-визначені мережі та мережеві функції віртуалізації (NFV) забезпечують гнучкість у керуванні інфраструктурою, що дозволяє швидко адаптуватися до змін попиту та знижувати витрати на підтримку систем [23].

Екологічна стійкість

Важливим трендом є зменшення енергоспоживання телекомунікаційного обладнання та впровадження екологічно дружніх рішень, таких як використання відновлюваних джерел енергії та розробка енергоефективних технологій [24].

Виклики та перспективи

Попри активні кроки у впровадженні 5G та IoT, Україна стикається з низкою викликів, зокрема, необхідністю значних інвестицій у розвиток інфраструктури, забезпечення кібербезпеки та підготовки кваліфікованих кадрів. Водночас, успішне впровадження цих технологій відкриває широкі перспективи для економічного розвитку, підвищення конкурентоспроможності та покращення якості життя громадян.

2. ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖЕВИХ ТЕХНОЛОГІЙ У ТЕЛЕКОМУНІКАЦІЙНИХ СИСТЕМАХ ТА МЕРЕЖАХ

Сучасні телекомунікаційні системи характеризуються постійним зростанням обсягу переданих даних, збільшенням кількості підключених пристроїв та ускладненням топології мереж. Для забезпечення стабільної роботи та високої якості обслуговування абонентів виникає необхідність у впровадженні інноваційних технологій, здатних ефективно вирішувати задачі прогнозування навантаження на мережу, оптимізації розподілу ресурсів і визначення пріоритетності обслуговування.

Нейромережеві алгоритми, завдяки своїй здатності до навчання та адаптації, стають незамінним інструментом для вирішення цих завдань. Вони дозволяють моделювати складні залежності між параметрами системи, аналізувати великі обсяги даних у реальному часі та автоматично коригувати стратегії управління мережею залежно від змін у її стані. Особливо перспективним є їх застосування для прогнозування пікових навантажень, що дозволяє заздалегідь готувати систему до роботи в умовах підвищеного трафіку, мінімізуючи затримки та втрати даних.

Крім того, нейромережі ефективно використовуються для впровадження динамічного підходу до визначення пріоритетності обслуговування абонентів. Вони враховують такі параметри, як тип трафіку, критичність переданих даних, стан мережі та історичні дані про поведінку користувачів, що дозволяє забезпечити оптимальний розподіл ресурсів і підвищити якість обслуговування.

2.1 Принцип роботи нейромережових алгоритмів

Визначення нейронних мереж

Нейронна мережа — це математична модель, схожа на будовою та функціонуванням біологічних нервових систем, схожу на роботу людського мозку. Вона складається з набору штучних нейронів, які з'єднанні між собою і здатні обробляти інформацію через передачу даних. Метою нейронних мереж є розв'язання важких завдань шляхом навчання на готових даних, що забезпечує високу адаптивність до зміни умов.

Основні властивості нейронних мереж:

1. **Самонавчання:** здатність покращувати результати шляхом аналізу великої кількості даних завантажених в нейромережу.
2. **Узагальнення:** здатність робити прогнози або приймати рішення щодо нових раніше невідомих ситуацій.
3. **Робота з багатовимірними даними:** обробка великих обсягів інформації з різних джерел (ефективність залежить від якості навчання системи).

2.2 Основні компоненти нейронної мережі:

Штучний нейрон - є основним базисним елементом мережі. Він приймає на вхід сигнали, перетворює їх на вагові коефіцієнти, від 0 до 1, підсумовує та пропускає через активаційну функцію, яка визначає, чи буде сигнал переданий далі до наступних нейронів в нейромережі.

Формула активації:

$$y = f(\sum_{i=1}^n w_i x_i + b) \quad (2.1)$$

де x_i — вхідні сигнали,
 w_i — вагові коефіцієнти,
 b — зміщення (bias),
 f — активаційна функція.

Шари нейронів

Нейронна мережа складається з трьох типів шарів:




Рисунок 2.1 — Основні компоненти нейронної мережі.

Вхідний шар є початковим етапом роботи нейронної мережі. Його основне завдання — прийняти початкові дані для подальшої обробки. Кожен нейрон у цьому шарі відповідає за один параметр вхідного набору даних.

Наприклад, якщо вхідні дані описують клієнтів мобільної мережі і включають такі характеристики, як:

1. кількість використаного трафіку,
2. час активності,
3. кількість здійснених дзвінків,

то кожна з цих характеристик буде передана як окремий вхідний нейрон.

Кількість нейронів у вхідному шарі завжди відповідає кількості параметрів вхідних даних. Сам вхідний шар не виконує обчислення — він лише передає інформацію до прихованих шарів.

Приховані шари — це ключова частина нейронної мережі, де відбувається основна обробка інформації. Приховані шари складаються з нейронів, які виконують складні математичні перетворення вхідних даних.

Основні функції прихованих шарів:

1. Виявлення зв'язків і залежностей між даними. Наприклад, у телекомунікаційній мережі приховані шари можуть визначати, як обсяг використаного трафіку впливає на ймовірність перевантаження системи.

2. Зміна масштабів даних. Дані можуть бути нормалізовані або приведені до потрібного діапазону для забезпечення стабільності обчислень.

3. Фільтрація інформації. Зайві або нерелевантні параметри можуть автоматично "ігноруватися" мережею шляхом зменшення ваг їх значущості.

Структура прихованих шарів:

Кожен нейрон у прихованих шарах отримує на вхід сигнали від усіх нейронів попереднього шару.

Вхідні значення помножуються на вагові коефіцієнти (weights), додається зміщення (bias), і результат передається через активаційну функцію, яка вирішує, чи передавати сигнал далі.

У задачі прогнозування навантаження приховані шари можуть обчислювати, як час доби, день тижня та кількість активних користувачів у мережі впливають на пікові навантаження.

Вихідний шар — це завершальний елемент нейронної мережі, який перетворює оброблені прихованими шарами дані на фінальний результат. Він виконує роль "перекладача", що інтерпретує внутрішні сигнали мережі у форму, зрозумілу для користувача або системи, яка приймає рішення.

У цьому шарі відбувається останній етап обчислень, під час якого дані передаються через активаційну функцію. Наприклад, у задачі прогнозування числового значення (такої як навантаження на мережу в конкретний момент часу)

функція може бути лінійною, дозволяючи отримати безпосереднє значення. У випадку, коли мережа використовується для класифікації, активаційна функція визначає ймовірність належності даних до певної категорії.

Для задач, пов'язаних із телекомунікаційними мережами, вихідний шар може видавати різні типи результатів. Якщо система аналізує трафік, результатом роботи мережі може бути числовий показник очікуваного навантаження, наприклад, кількість активних користувачів у певній зоні. У разі прогнозування перевантаження, вихідний шар може повертати сигнал про необхідність змін у маршрутизації або зміну частотного діапазону.

Особливість вихідного шару в його здатності працювати з високорівневими абстракціями. Дані, що проходять через безліч прихованих шарів і активаційних функцій, втрачають початковий вигляд, але набувають структури, яка дозволяє нейромережі зробити точний і логічний висновок. Це особливо важливо в умовах, коли потрібно швидко реагувати на зміни, як-от у реальному часі оптимізувати ресурси базової станції або визначати пріоритетність обслуговування трафіку різних користувачів.

Таким чином, вихідний шар є ключовим вузлом, де інформація з прихованих шарів набуває остаточного вигляду, що може бути використаний для практичних задач, таких як управління телекомунікаційною мережею, прогнозування навантаження чи розподіл ресурсів. Його значення визначається точністю інтерпретації сигналів і здатністю передати результат у зрозумілій формі.

Якщо казати про активаційні функції, які використовуються у вихідному шарі, вони відповідають за перетворення вихідних сигналів у форму, яка може бути інтерпретована як результат. Вона виконує два основних завдання:

1. Обмеження діапазону значень: наприклад, до ймовірності (0–1) у задачах класифікації.
2. Відповідність типу задачі: забезпечує потрібний формат результату (число, ймовірність, категорія тощо).

Найпоширеніші функції:

1. Лінійна функція (Linear Activation) функція є однією з найпростіших і найрозуміліших функцій, яка використовується у вихідному шарі нейронних мереж. Вона передає вихідне значення без змін, тобто функція має вигляд:




Рисунок 2.2 — Вигляд лінійної функції

І позначається як:

$$f(x) = x \quad (2.2)$$

Якщо виділяти особливості лінійної функції, то можна виділити:

Простота обчислень: Оскільки функція передає значення без змін, це знижує складність обчислень. Вона ідеально підходить для задач, де результат повинен бути числовим значенням.

Відсутність обмеження діапазону: Лінійна функція дозволяє отримувати результати у будь-якому числовому діапазоні (як позитивні, так і негативні

значення). Це важливо для задач, де вихід може приймати широкий спектр значень, наприклад, прогнозування показників мережі.

Використовується здебільшого у задачах регресії, де нейронна мережа прогнозує конкретні числові результати, такі як:

1. Прогнозоване навантаження на базову станцію.
2. Очікувана затримка передачі даних у мілісекундах.
3. Прогнозована кількість користувачів у певному регіоні.

Лімітуючий фактор:

Основний недолік лінійної функції полягає у тому, що вона не враховує нелінійності у даних. Це означає, що мережа з лінійною функцією не може моделювати складні залежності між вхідними даними.

Sigmoid є однією з найпопулярніших активаційних функцій, що використовується у нейронних мережах, особливо в задачах класифікації. Вона перетворює довільне вхідне значення x у діапазон $(0,1)$, що ідеально підходить для моделювання ймовірностей.




Рисунок 2.3 — Графічне позначення Sigmoid активаційної функції

Математично її позначають так:

$$f(x) = \frac{1}{1+e^{-x}}, \quad (2.3)$$

де:

x — вхідне значення,

e — математична константа (основа натурального логарифма, приблизно 2.7182).

Основні переваги властивості:

1. Діапазон значень завжди $[0,1]$
2. Гладкість, так як Sigmoid є диференційованою функцією, що робить її придатною для задач оптимізації через градієнтний спуск.
3. Підтримка нелінійності, що дозволяє нейронній мережі моделювати складні залежності
4. Вразливість до насичення, що може викликати «згасаючий градієнт»

Наприклад, цю функцію можна застосувати в бінарній класифікації, чи навантажена базова станція [< 0.5]

Softmax — це активаційна функція, яка перетворює набір чисел у ймовірності, пропорційні експоненційним значенням цих чисел. Вона зазвичай використовується у вихідному шарі нейронних мереж для задач багатокласової класифікації.




Рисунок 2.4 — Візуалізація активаційної функції softmax

Математичний вираз:

$$f(z_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (2.4)$$

де:

z_i – значення i -го елемента вхідного шару,

n – кількість елементів у векторі,

e – експонента (основа натурального логорифма)

n – кількість елементів у вхідному векторі z

$\sum_{j=1}^n e^{z_j}$ – сума експонент усіх елементів вхідного вектора z , що використовується для нормалізації результатів.

Якщо, казати про особливості, то їх можна виразити як:

1. Ймовірнісний вихід:

$$\sum_{i=1}^n f(z_i) = 1 \quad (2.5)$$

Softmax перетворює вхідний вектор у набір ймовірностей. Кожне значення знаходиться в діапазоні $(0, 1)$ і їх сума завжди дорівнює 1.

2. Пропорційність експонентам - Значення вихідних ймовірностей залежить від відносних величин z_i . Чим більше z_i , тим більша ймовірність, пов'язана з цим значенням.
3. Чутливість до масштабів: Якщо значення вхідного вектора дуже великі або дуже малі, це може призвести до числової нестабільності. Для уникнення цього часто застосовують нормалізацію, наприклад:

$$z'_i = z_i - \max(z) \quad (2.6)$$

щоб найбільше значення вектора стало нульовим.

4. Багатокласова класифікація: в задачах, де потрібно класифікувати вхідний сигнал на один із кількох можливих класів.

Варіанти застосування в телекомунікації:

Наприклад, класифікація базової станції на 3 стани: "низьке навантаження", "середнє навантаження", "перевантаження".

Вхідний вектор $z=[2.0,1.0,0.1]$, після застосування Softmax може дати ймовірності: $[0.7,0.2,0.1]$. Це означає, що стан із низьким навантаженням (ймовірність 0.7) є найімовірнішим.

ReLU (Rectified Linear Unit) — це одна з найпоширеніших активаційних функцій у нейронних мережах. Її популярність пояснюється простотою, ефективністю та здатністю вирішувати низку проблем, які виникають із більш складними функціями, такими як Sigmoid чи Tanh.




Рисунок 2.5 — Візуальне відображення ReLU (Rectified Linear Unit)

Формула функції ReLU має простий вигляд:

$$f(x) = \max(0, x) \quad (2.7)$$

Іншими словами, якщо вхідне значення x є від'ємним, то функція повертає 0. Якщо x є додатним або дорівнює нулю, результатом буде саме x .

Функція ReLU "обрізає" всі від'ємні значення, зберігаючи лише додатні. Це робить її ідеальною для багатьох практичних задач, оскільки вона дозволяє мережі зосередитися лише на корисній інформації, ігноруючи значення, які не мають позитивного впливу.

Якщо казати за ефективність ReLU, то можна виділити: простоту обчислень, усунення насичення, швидке навчання, але це, виділяє багато недоліків: Мертві нейрони, чутливість до великих значень.

Навіть якщо, казати про недоліки, то ReLU стала стандартом у сучасних нейронних мережах завдяки своїй простоті, швидкості обчислень і ефективності у великих моделях. Вона є оптимальним вибором для задач, де важливо обробляти лише значущі (додатні) дані, і стала невід'ємною частиною багатьох практичних реалізацій у сфері телекомунікацій, комп'ютерного зору та обробки даних.

2.3 Архітектури нейронних мереж

Архітектура нейронної мережі визначає її будову, способи з'єднання між нейронами та методи обробки інформації. Вибір архітектури залежить від характеру задачі, яку потрібно вирішити, обсягу вхідних даних та необхідного рівня обчислювальної потужності. У сучасних телекомунікаційних системах використовуються різні типи архітектур, кожна з яких має свої особливості та переваги.

Перцептрон — це найпростіша модель штучної нейронної мережі, яка складається з одного шару нейронів. Вхідні дані зважуються та передаються на активаційну функцію, результат якої використовується для класифікації або прийняття рішень. Перцептрони ефективні для розв'язання лінійно розділюваних задач.

Багатошаровий перцептрон (MLP)

Багатошарові перцептрони містять один або більше прихованих шарів між вхідним та вихідним шарами. Ці моделі здатні вирішувати складніші задачі, використовуючи нелінійні активаційні функції. MLP широко застосовується для задач класифікації, регресії та прогнозування.

Згорткові нейронні мережі (Convolutional Neural Networks, CNN)

Згорткові нейронні мережі використовуються переважно для роботи із зображеннями та відео. Вони складаються з згорткових шарів, які витягують характерні ознаки, таких як краї, текстури чи форми. CNN також застосовуються у телекомунікаційних системах для аналізу візуальних даних, наприклад, при виявленні несправностей на обладнанні.

Рекурентні нейронні мережі (Recurrent Neural Networks, RNN)

RNN призначені для обробки послідовних даних, таких як текст, аудіо або серії вимірювань у часі. Вони мають механізм зворотного зв'язку, що дозволяє зберігати інформацію про попередні стани. Це робить RNN незамінними для задач прогнозування в телекомунікаційних мережах, наприклад, для оцінки навантаження на мережу.

Архітектури на основі механізмів уваги (Attention та Transformers)

Механізм уваги дозволяє моделі акцентувати увагу на найбільш важливих частинах вхідних даних. Transformers є одними з найбільш популярних архітектур такого типу і використовуються у задачах обробки природної мови (NLP), а також в аналізі складних мережевих структур.

Генеративно-змагальні мережі (Generative Adversarial Networks, GANs)

Ці мережі складаються з двох частин: генератора та дискримінатора. Вони працюють у тандемі для створення нових даних, схожих на вихідний набір. У

телекомунікаціях GANs використовуються для моделювання сигналів, створення тестових даних або покращення якості зображень.

Глибокі підкріплювальні мережі (Deep Reinforcement Learning)

Такі мережі поєднують глибокі нейронні мережі та методи підкріплення для навчання на основі винагород. У телекомунікаціях вони застосовуються для оптимізації мережевих ресурсів та управління навантаженням.

Кожна з цих архітектур має свої переваги та обмеження, тому їх вибір залежить від конкретної задачі, що вирішується. Застосування сучасних архітектур нейронних мереж у телекомунікаціях дозволяє суттєво підвищити якість обслуговування абонентів завдяки оптимізації процесів, прогнозуванню та аналізу даних.

2.4 Застосування нейромережевих алгоритмів у телекомунікаційних системах

Нейромережеві алгоритми відіграють ключову роль у сучасних телекомунікаційних системах, забезпечуючи підвищення якості обслуговування, ефективність управління трафіком та безпеку мереж. Їх застосування охоплює широкий спектр завдань, від моніторингу та аналізу мережевих параметрів до виявлення аномалій та оптимізації ресурсів.

Характеристика нейромережевих алгоритмів

Основними характеристиками нейромережевих алгоритмів є здатність до навчання, адаптивність, стійкість до шумів та можливість обробки великої кількості параметрів одночасно. Це робить їх особливо корисними в телекомунікаційних системах, де необхідно аналізувати великі обсяги даних у реальному часі.

Застосування нейромережевих алгоритмів у телекомунікаційних системах

1. Моніторинг та аналіз мережевого трафіку: Нейронні мережі використовуються для аналізу трафіку з метою виявлення аномалій,

прогнозування навантаження та оптимізації розподілу ресурсів. Наприклад, у роботі Хлапоніна Ю.І. та співавторів розглянуто застосування нейронних мереж у статистичній системі аналізу і моніторингу телекомунікаційних мереж [29]

2. **Виявлення кібератак та забезпечення безпеки:** Нейромережеві методи застосовуються для виявлення несанкціонованого доступу та інших загроз. Корченко О. та співавтори досліджували сучасні нейромережеві методи оцінки параметрів безпеки ресурсів інформаційних систем [30]
3. **Оптимізація управління мережевими ресурсами:** Нейронні мережі допомагають у прийнятті рішень щодо маршрутизації та розподілу навантаження, що підвищує ефективність роботи мережі. Зокрема, у дисертації розглянуто моделі та алгоритми підвищення якості обслуговування у програмно-конфігурованих телекомунікаційних мережах [31]

Українські та зарубіжні варіації впровадження

В Україні активно досліджуються та впроваджуються нейромережеві технології в телекомунікаційних системах. Наприклад, у Вінницькому національному технічному університеті вивчається використання нейронних мереж для виявлення шахрайства у телекомунікаційних мережах.

Зарубіжні компанії та наукові установи також активно впроваджують нейромережеві алгоритми для покращення якості обслуговування. Зокрема, у статті розглядається підхід до застосування нейронних мереж в телекомунікаційних системах

3 РЕАЛІЗАЦІЯ БЕЗПРОВОДОВОЇ МЕРЕЖІ НА ОСНОВІ ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖЕВОГО АЛГОРИТМ

3.1 Принципи роботи когнітивних радіосистем

Когнітивні радіосистеми (КРС) — це телекомунікаційні системи нового покоління, які забезпечують динамічне, ефективне і адаптивне використання радіочастотного спектра. Їхній принцип роботи базується на поєднанні інтелектуальних алгоритмів, постійного моніторингу радіосередовища та здатності до самонавчання. Детальніше розглянемо, як працюють когнітивні радіосистеми.

Моніторинг та аналіз радіочастотного спектра

Когнітивна система розпочинає свою роботу зі спостереження за радіочастотним середовищем. Для цього використовуються спеціалізовані сенсори, які аналізують такі параметри сигналу, як потужність, ширина смуги частот, тип модуляції, а також наявність шумів чи інтерференції. Збір даних виконується у реальному часі, що дозволяє системі отримувати актуальну інформацію про доступний спектр.

Один із ключових аспектів цього процесу — визначення частот, зайнятих первинними користувачами (Primary Users, PU), і вільних частотних діапазонів.

Для цього застосовуються різні алгоритми:

1. **Енергетичне детектування.** Цей метод базується на вимірюванні рівня потужності сигналу. Якщо потужність перевищує встановлений поріг, частота вважається зайнятою.

2. **Аналіз спектральних характеристик.** Система порівнює сигнали із заздалегідь визначеними шаблонами, що дозволяє ідентифікувати тип користувача та характер сигналу.

3. Циклостатистичний аналіз. Використовується для розпізнавання сигналів на основі їхньої періодичності. Це дозволяє виявляти навіть слабкі сигнали, які не завжди видно при енергетичному детектуванні.

Результатом такого моніторингу є карта спектра, яка показує зайняті й вільні частотні діапазони, а також їхню доступність у певний момент часу.

Динамічний доступ до спектра

На основі отриманих даних когнітивна система приймає рішення про використання частотного ресурсу. Головною особливістю КРС є здатність до динамічного доступу до спектра. Це означає, що система може тимчасово використовувати вільні частоти без створення перешкод для основних користувачів.

У разі повернення первинного користувача когнітивна система звільняє зайнятий спектр і перемикається на іншу частоту. Такий підхід дозволяє максимально ефективно використовувати радіочастотний ресурс, мінімізуючи ризик виникнення конфліктів між користувачами.

Адаптація до змін середовища

Адаптивність є ключовим принципом роботи КРС. Система може змінювати свої параметри залежно від умов роботи. Наприклад:

1. Якщо зростає рівень шуму або інтерференції, система збільшує потужність передавача або змінює частоту передачі.
2. У разі появи фізичних перешкод (наприклад, стін чи інших об'єктів) система коригує напрямок передачі сигналу за допомогою адаптивних антен.
3. У складних погодних умовах (дощ, сніг, туман) когнітивна система обирає оптимальний режим роботи, щоб уникнути втрати сигналу.

Використання адаптивних алгоритмів дає змогу підтримувати високу якість передачі даних навіть у складних умовах.

Інтелектуальне управління

Когнітивні радіосистеми широко використовують алгоритми машинного навчання та штучного інтелекту. Вони допомагають системі:

1. Прогнозувати поведінку радіочастотного середовища. Наприклад, система може передбачити, які частоти будуть вільними через певний проміжок часу.
2. Виявляти закономірності у використанні спектра. Це дозволяє оптимізувати передачу даних і зменшити затримки.
3. Підвищувати ефективність прийняття рішень. Алгоритми машинного навчання забезпечують швидку адаптацію до змінних умов без необхідності ручного втручання.

Самонавчання є важливою складовою роботи КРС. Завдяки аналізу минулих сценаріїв система покращує свої алгоритми, що з часом підвищує її ефективність.

Забезпечення безпеки

Когнітивні радіосистеми повинні забезпечувати високий рівень безпеки, оскільки їхня робота може бути пов'язана з ризиком зовнішніх втручань. Для цього використовуються:

1. Методи шифрування даних, які захищають інформацію від перехоплення.
2. Алгоритми автентифікації користувачів, що запобігають несанкціонованому доступу до системи.
3. Захист від атак на радіочастотне середовище, таких як заглушення або імітація сигналу.

Енергоефективність

Сучасні КРС проектуються з урахуванням необхідності зменшення енергоспоживання. Для цього реалізуються такі підходи:

1. Передавачі активуються тільки в моменти передачі даних.
2. Оптимізуються параметри передачі, щоб мінімізувати витрати енергії.
3. Використовуються енергоефективні компоненти обладнання.

Когнітивні радіосистеми є революційним кроком у розвитку телекомунікацій. Їхня здатність до адаптації, самонавчання і раціонального використання спектра дозволяє забезпечувати високу якість обслуговування абонентів, навіть за умов обмеженості радіочастотного ресурсу. Завдяки інтелектуальним технологіям ці системи відкривають нові можливості для розвитку безпроводових мереж і підвищення їхньої ефективності.

3.2 Характеристика стандарту IEEE 802.22

Стандарт IEEE 802.22 був розроблений для впровадження бездротових регіональних мереж (Wireless Regional Area Network, WRAN), які працюють у спектрі телевізійного мовлення (TVWS – Television White Space). Основною метою цього стандарту є забезпечення доступу до широкопasmового зв'язку у сільській місцевості та віддалених регіонах, де використання традиційної інфраструктури обмежене або економічно не вигідне.

Основні характеристики стандарту IEEE 802.22

1. Використання TVWS спектру. Стандарт використовує невикористані частоти телевізійного мовлення в діапазоні від 54 до 862 МГц, що забезпечує значну дальність передачі сигналу та проникнення через перешкоди. Завдяки цьому, один базовий вузол здатний покривати площу до 10 000 км².

2. Динамічне управління спектром (Dynamic Spectrum Access, DSA) IEEE 802.22 інтегрує технології когнітивного радіо для виявлення доступного спектру та уникнення перешкод іншим користувачам. Це дозволяє ефективно використовувати ресурси радіочастотного спектру без конфліктів із телевізійними каналами або іншими WRAN-системами.

3. Висока пропускна здатність. WRAN на основі стандарту IEEE 802.22 забезпечує пропускну здатність до 22 Мбіт/с на канал. Це достатньо для забезпечення послуг широкопasmового доступу, таких як VoIP, передача даних і потокове відео.

4. Захист від перешкод. Завдяки використанню передових технологій модуляції, таких як OFDM (Orthogonal Frequency Division Multiplexing), та механізмів виявлення первинних користувачів, стандарт гарантує мінімізацію впливу перешкод на роботу мережі.

5. Архітектура мережі. IEEE 802.22 підтримує топологію "точка-багатоточок", де базова станція керує всіма клієнтськими пристроями. Це спрощує

управління мережею та забезпечує централізований контроль за доступом до спектру.

Переваги застосування

Використання IEEE 802.22 дозволяє значно зменшити цифровий розрив між міськими та сільськими районами, сприяючи соціально-економічному розвитку. Крім того, впровадження цього стандарту відкриває нові можливості для операторів телекомунікацій, дозволяючи оптимізувати використання існуючих спектральних ресурсів.

Недоліки та виклики

Попри всі переваги, стандарт має певні обмеження. Найбільшими викликами є складність реалізації механізмів когнітивного радіо, обмежена кількість доступного спектру у деяких регіонах, а також необхідність дотримання суворих регуляторних вимог.

Узагальнюючи, IEEE 802.22 є перспективним рішенням для побудови широкосмугових мереж нового покоління, що базуються на інноваційних підходах до управління спектром та забезпечення високої якості обслуговування абонентів.

3.3 Застосування нейромережевого алгоритму для підвищення якості обслуговування абонентів безпроводових мереж

У сучасних телекомунікаційних мережах безпроводовий зв'язок став невід'ємною частиною життя людини та бізнесу. Швидкий розвиток трансмісії даних зумовив необхідність у нових підходах до управління ресурсами та забезпечення якісного обслуговування (якість обслуговування – QoS). Нейромережеві алгоритми стали одним із найперспективніших інструментів для розв'язання цих завдань.

Нейромережі та їх роль у безпроводових мережах.

Завдяки здатності до навчання та пошуку похованих закономірностей, нейромережі стають державним адаптивним елементом для безпроводових мереж. Особливості нейронних мереж полягають у можливості складного аналізу вхідних даних, таких як параметри трафіку, стан каналів та вимоги користувачів.

Передові приклади вказують на успішне застосування нейромереж для розподілу ресурсів, адаптації мережі до змінних умов та підвищення QoS. Зокрема, використання таких підходів показало високу ефективність у прогнозуванні трафіку та мінімізації затримок.

Приклади реального застосування.

1. Управління трафіком у SDN. Програмно-конфігуровані мережі застосовують нейромережеві моделі для адаптивного управління трафіком. У роботі [1] запропоновано моделі та алгоритми, що розподіляють ресурси з урахуванням QoS.

2. Прогнозування трафіку. Застосування нейронних мереж у прогнозуванні трафіку розглядається як один з найбільш перспективних інструментів для оптимізації роботи безпроводових мереж. Нейромережі можуть аналізувати розподіл трафіку, виявляти закономірності та прогнозувати можливі навантаження конкретних каналів. Це дозволяє оптимізувати розподіл ресурсів та знижувати затримки, що виникають під час пікового навантаження.

Додатково, використання рекурсійних нейронних мереж (наприклад, LSTM) дозволяє прогнозувати нетривалі навантаження, що сприяє оптимізації мережевих сесій. Використання нейронних мереж у подібних задачах доводить досконале управління мережевими ресурсами та зниження непродуктивних витрат.

3. Оптимізація розподілу частотного спектра. У системах безпроводового зв'язку, таких як LTE та 5G, оптимізація розподілу частотного спектра є критично важливою. Нейромережі дозволяють аналізувати стан мережі в реальному часі та адаптивно перерозподіляти частоти між базовими станціями залежно від поточного навантаження та вимог користувачів. Це сприяє підвищенню загальної ефективності використання спектра та зниженню ймовірності конфліктів між абонентами.

4. Покращення енергоефективності. Застосування нейронних мереж також довело свою ефективність у задачах енергоефективності безпроводових мереж. Алгоритми на основі глибокого навчання здатні прогнозувати навантаження на мережу та відповідно коригувати потужність передавачів базових станцій. Це дозволяє зменшити споживання енергії без шкоди для якості обслуговування.

5. Управління мобільністю користувачів. Нейромережі можуть ефективно використовуватися для управління мобільністю абонентів, зокрема при виконанні "handover" між базовими станціями. Алгоритми прогнозування здатні враховувати швидкість, напрямок руху користувача та якість сигналу для мінімізації перерв у з'єднанні. У роботах [2] описано приклади успішного впровадження таких систем у мережах 5G.

6. Виявлення та запобігання мережевим атакам. Нейронні мережі широко застосовуються для виявлення аномалій у мережевому трафіку, що може свідчити про атаки, такі як DDoS або спроби несанкціонованого доступу. Глибокі нейромережі дозволяють аналізувати великий обсяг даних у реальному часі, швидко ідентифікуючи потенційні загрози. Такий підхід значно підвищує безпеку телекомунікаційних систем.

4 ПРАКТИЧНА РЕАЛІЗАЦІЯ БЕЗПРОВОДОВОЇ МЕРЕЖІ НА ОСНОВІ НЕЙРОМЕРЕЖЕВОГО АЛГОРИТМУ

Однією з головних проблем є нерівномірний розподіл навантаження між базовими станціями, що призводить до зниження якості обслуговування користувачів. Традиційні алгоритми маршрутизації та управління ресурсами, які базуються на детермінованих підходах, мають обмежену ефективність у таких умовах. Відповідно, виникає необхідність у впровадженні гнучких і адаптивних систем управління, здатних враховувати змінні умови мережі в режимі реального часу.

У рамках роботи було прийнято рішення використовувати нейромережеві алгоритми для прогнозування навантаження на мережу та розподілу пріоритетів між абонентами. Нейромережі, завдяки своїй здатності до навчання та адаптації, дозволяють враховувати велику кількість параметрів, зокрема історичні дані про використання мережі, час доби, тип трафіку та інші характеристики. Це дозволяє не лише передбачати майбутнє навантаження, а й оперативно розподіляти ресурси між абонентами, мінімізуючи затримки та покращуючи якість передачі даних.

Мета цієї частини роботи – створити прототип нейромережевої системи, яка:

1. адаптується до змін навантаження в режимі реального часу;
2. забезпечує прогнозування навантаження з урахуванням різних факторів;
3. оптимізує розподіл мережевих ресурсів на основі пріоритетів користувачів.

Запропонований підхід базується на використанні когнітивних радіосистем, що дозволяє застосовувати стандарти, такі як IEEE 802.22, для управління спектром. Це забезпечує не лише ефективність роботи мережі, а й відповідність сучасним технологічним вимогам.

4.1. Збір та підготовка даних

4.1.1. Джерела даних

Одним із ключових етапів проєкту є збір даних, необхідних для навчання та валідації нейромережевого алгоритму. З міркувань безпеки, та конфіденційності ми використовуємо такі джерела:

Симуляція мережі за допомогою NS-3. Дає нам детальну інформацію щодо трафіку (кількість активних абонентів, типи трафіку, швидкість передавання). Його структура виглядає так:

1. Часовий інтервал (timestamp): Показує, коли були зафіксовані дані.
2. ID абонента (user ID): Унікальний ідентифікатор користувача.
3. Тип трафіку (traffic type): Наприклад, VoIP, веб-трафік, потокове відео.
4. Швидкість передавання (data rate): Вимірюється у Mbps або Kbps.
5. Рівень затримки (latency): Вимірюється у мілісекундах.
6. Втрати пакетів (packet loss): У відсотках.
7. Рівень завантаження базової станції (base station load): У відсотках.
8. Місце розташування (optional): Координати або зона обслуговування.

Симуляція була виконана протягом 24 годин, результати обчислень представлені в таблиці 4.1.

Таблиця 4.1 — Приклад симуляції даних за допомогою NS-3

Timestamp	User ID	Traffic Type	Data Rate (Mbps)	Latency (ms)	Packet Loss (%)	Base Station Load (%)
00:00:01	1001	VoIP	0.64	25	0.5	45
00:00:02	1002	Streaming	5.3	20	1.2	50
00:00:03	1003	Web	1.2	18	3	60
00:00:04	1004	VoIP	0.62	22	0.6	41
00:00:05	1005	Streaming	4.8	27	1.5	54

Публічні датасети

OpenCellID. Найбільша відкрита база даних, що містить інформацію про мобільні вежі по всьому світу, включаючи координати веж, MCC (Mobile Country Code), MNC (Mobile Network Code), LAC (Location Area Code), і CellID. Він допоможе нам зібрати дані, для перемикання між базовими станціями та доступом. Щоб отримати дані потрібна реєстрація, та їх можна отримати в форматі JSON, для наглядності, вони були перетворені в табличний варіант (таблиця 4.2).

Таблиця 4.2 — Частина зібраних даних з OpenCellID

CellID	LAC	MCC	MNC	Latitude	Longitude	Range (м)	Samples
12345	101	250	1	50.4501	30.5234	1500	12
51715	125	310	2	40.7128	-74.0060	2000	51
16572	151	256	3	52.5200	13.4050	1200	21

Опис полів:

1. CellID — Унікальний ідентифікатор вежі (Cell ID).

2. LAC (Location Area Code) — Ідентифікатор території, що покривається мережею.
3. MCC (Mobile Country Code) — Код країни мобільного оператора.
4. MNC (Mobile Network Code) — Код мобільного оператора в країні.
5. Latitude — Географічна широта (у десяткових градусах).
6. Longitude — Географічна довгота (у десяткових градусах).
7. Range — Радіус дії вежі (у метрах).
8. Samples — Кількість разів, коли дані про цю вежу були зареєстровані.

Teralytics Mobility Data збираються від мобільних операторів та ретельно анонімізуються й агрегуються, щоб забезпечити дотримання законів про конфіденційність. Ці дані відображають маршрути пересування користувачів, включаючи часові мітки, які фіксують моменти виходу і прибуття, а також пункти відправлення та призначення. Інформація охоплює різні типи транспорту, такі як автомобілі, громадський транспорт чи навіть пішохідний рух. Окрім цього, у наборі даних зазначаються показники інтенсивності мобільності, зокрема кількість подорожей і середня швидкість руху.

Ці дані широко використовуються для планування міської інфраструктури, аналізу туристичних потоків та оптимізації роботи громадського транспорту. Також вони допомагають краще зрозуміти поведінку користувачів у періоди криз, наприклад, під час пандемій, коли мобільність населення суттєво змінюється.

4.2. Структура та формат даних, попередня обробка

4.2.1. Загальна структура даних

Для побудови нейромережевої системи, здатної здійснювати прогнозування навантаження та управління ресурсами, необхідно опрацювати декілька різнорідних джерел, які відрізняються своїм форматом, обсягом та типом інформації. Основними складовими є результати симуляції у середовищі NS-3 та публічні датасети, зокрема OpenCellID і Teralytics.

Симуляційні дані з NS-3 являють собою табличний формат, у якому кожний запис відповідає конкретному часовому інтервалу і містить відомості про ID абонента, тип трафіку, швидкість передавання даних, затримку, втрати пакетів та завантаження базової станції. Записи робляться з часовим інтервалом у 1 секунду, що дозволяє детально відстежувати динаміку навантаження упродовж доби. Саме така висока роздільна здатність дає змогу спостерігати короточасні пікові навантаження, визначати залежність типів трафіку від часу доби та виявляти закономірності у поведінці абонентів. Іншим важливим аспектом симуляції є можливість масштабування: дослідник може змінювати кількість абонентів або базових станцій, варіювати протоколи та типи сервісів, і таким чином наближатися до реалістичних сценаріїв роботи бездротових мереж. Це створює гнучку платформу для тестування різноманітних підходів до управління ресурсами, у тому числі й методів на основі штучного інтелекту.

Публічні датасети, такі як OpenCellID, містять інформацію про мобільні вежі, їх географічне розміщення (широта та довгота), а також технічні параметри: MCC (Mobile Country Code), MNC (Mobile Network Code), LAC (Location Area Code) і CellID. Ці дані зазвичай надаються у форматах CSV або JSON і періодично оновлюються, що дозволяє фіксувати динаміку змін у розгортанні мереж. Окрім цього, у випадку Teralytics можна отримати агреговану та анонімізовану інформацію про інтенсивність пересування абонентів у різних регіонах, а також показники мобільності (кількість здійснених поїздок, середня швидкість руху тощо). Оскільки обсяг таких даних може бути дуже великим, важливим кроком є фільтрація та попередня обробка, завдяки якій вдається виокремити дійсно корисні фрагменти: наприклад, визначити кількість активних користувачів у певний момент часу або виділити окремі географічні зони для дослідження.

Поєднання результатів симуляції у NS-3 з відкритими наборами даних дає змогу моделювати роботу мережі в умовах, близьких до реальних. Симуляційні сценарії забезпечують деталізовану статистику про роботу мережевих протоколів і дозволяють гнучко змінювати параметри, а публічні дані підтверджують або коригують результати досліджень на основі фактичної геолокації базових станцій та реальної поведінки абонентів. Такий підхід формує міцний фундамент для навчання та валідації нейромережевих алгоритмів, оскільки охоплює широкий спектр впливових чинників – від фізичної топології мережі до статистичних особливостей користувацького трафіку.

4.2.2 Формати збереження та приклади записів

У ході роботи з різними джерелами дані було приведено до спільного табличного формату (CSV) з таким базовим переліком полів:

1. **Timestamp** (часова позначка) для синхронізації подій у мережі та обчислення часових інтервалів.

Формат: YYYY-MM-DD HH:MM:SS або секундний відлік від початку симуляції.

2. **User ID** (унікальний ідентифікатор користувача) Дозволяє відстежувати поведінку конкретного абонента (тип трафіку, швидкість передачі даних тощо).

Формат: числове значення (наприклад, 1001, 1002 тощо).

3. **Traffic Type** (тип трафіку) Використовується для визначення пріоритету при маршрутизації та управлінні ресурсами.

Формат: текстове поле («VoIP», «Streaming», «Web» тощо).

4. **Data Rate** (швидкість передавання) Важливий показник, що впливає на пропускну здатність мережі.

Формат: числове значення в Mbps (або Kbps).

5. **Latency (затримка)** Визначає якість обслуговування (QoS), особливо для чутливих до затримки сервісів (VoIP, онлайн-ігри тощо).

Формат: числове значення у мілісекундах (ms).

6. **Packet Loss (%)** (втрати пакетів) Великий відсоток вказує на проблеми з якістю каналу або перевантаження мережі.

Формат: числове значення у відсотках.

7. **Base Station Load (%)** (завантаження базової станції) Дозволяє визначити, наскільки базова станція близька до пропускнуої межі.

Формат: числове значення у відсотках.

8. **Location (Latitude, Longitude)** Застосовується для дослідження просторових особливостей мережі та оптимальної маршрутизації.

Формат: два десяткові числа, що вказують географічну широту та довготу.

4.2.3. Попередня обробка та фільтрація

В додатку Б приведений Python код з використання бібліотек pandas, який дає змогу автоматизувати процес уніфікації та об'єднання CSV-файлів із різних джерел у межах попередньої обробки даних. Код виконує такі основні кроки:

1. Збір файлів: Зчитує всі CSV-файли з визначеної директорії.
2. Уніфікація полів: Перевіряє, чи містить кожний файлу всі необхідні стовпці (наприклад, Timestamp, User ID, Traffic Type). Якщо деякі поля відсутні, вони автоматично додаються зі значеннями None.
3. Об'єднання даних: Використовує `pandas.concat()` для формування єдиного датафрейму, в якому зібрані всі записи зі знайдених файлів.
4. Видалення дублікатів: Застосовує метод `drop_duplicates()`, щоб уникнути повторних рядків, які можуть з'являтися у кількох CSV-файлах.
5. Збереження підсумку: Записує отриманий об'єднаний набір даних до нового файлу `merged_data.csv`.

Завдяки такому підходу спрощується та прискорюється процес підготовки вхідних даних перед подальшою обробкою у нейромережових моделях. Замінюючи відсутні поля, ми уніфікуємо структуру CSV-файлів, що особливо корисно, коли дані надходять з різних джерел і можуть мати різну кількість стовпців. Крім того,

об'єднання у єдиний файл спрощує аналіз і дає змогу централізовано застосовувати операції очищення, нормалізації та валідації.

4.2.4. Форма представлення вхідних даних для нейромережі

У межах цієї роботи основною метою є прогноз середнього навантаження на наступний інтервал часу. Для досягнення цієї мети формується вектор вхідних ознак, який містить ключові характеристики мережі. Наведені нижче параметри (ознаки) відображають поточний стан мережі та дають змогу моделі передбачити, яким буде навантаження через певний період:

1. Кількість активних абонентів у момент часу t . Відображає кількість користувачів, які одночасно генерують трафік. Збільшення цього показника зазвичай призводить до зростання загального навантаження, оскільки ресурси мережі розподіляються між більшою кількістю абонентів.

2. Середня швидкість передачі (Data Rate). Вимірюється у Мбіт/с (або Кбіт/с) і дає можливість зрозуміти, наскільки інтенсивно використовується пропускна здатність каналу за певний часовий інтервал. Якщо середній Data Rate високий, це може свідчити про значне навантаження на мережу.

3. Середній відсоток втрат пакетів (Packet Loss). Дає інформацію про якість каналу зв'язку. Значні втрати пакетів зазвичай спостерігаються за умов перевантаження або низької якості радіосигналу. Зростання цього показника нерідко передуює погіршенню пропускної здатності.

4. Середнє завантаження базової станції (Base Station Load). Вказує, наскільки використовуються потужності базової станції на поточний момент (у відсотках). Якщо показник наближається до 100%, система може бути на межі перевантаження, і прогнозований стан навантаження має ще більш суттєве значення для динамічного управління ресурсами.

5. Час доби або день тижня. Дає змогу фіксувати характерні добові й тижневі патерни. Наприклад, у деяких системах пік навантаження спостерігається вранці та

ввечері, тоді як у робочі години можливі «провали» або, навпаки, зростання залежно від типу користувачів.

6. Тип трафіку, закодований у вигляді one-hot векторів. Оскільки різні види сервісів (наприклад, голосовий зв'язок, потокове відео, передавання файлів) мають різні вимоги до пропускної здатності та затримки, важливо додатково вказувати, який тип трафіку переважає. Така інформація заноситься у вигляді кількох бінарних полів, де кожне з них відповідає конкретному сервісу.

Формуючи ці шість ознак, отримуємо вектор:

$$x(t) = [x_1(t), x_2(t), x_3(t), x_4(t), x_5(t), x_6(t)], \quad (4.1)$$

де кожен елемент відповідає одній зі згаданих характеристик. Якщо ознака «тип трафіку» сама є вектором, вона входить до $x(t)$ у розгорнутому вигляді та збільшує його розмірність. На основі цього вектора нейромережа генерує числове значення:

$$y(t + \Delta t), \quad (4.2)$$

що відповідає **прогнозованому середньому навантаженню** (наприклад, у відсотках від максимальної пропускної здатності) на наступний часовий інтервал Δt . Таке передбачення дає змогу операторам мережі заздалегідь реагувати на можливе зростання навантаження, оптимізувати розподіл каналів та покращувати якість обслуговування користувачів.

4.3 Архітектура нейромережі та процес навчання

У межах даного проєкту основне завдання полягає в прогнозуванні середнього навантаження на наступний часовий інтервал. Оскільки подібний тип задачі має яскраво виражену часову складову (наявність історії навантаження,

залежність майбутнього стану від попередніх), доцільно застосовувати нейронну мережу, яка здатна враховувати послідовність подій. Найбільш підходящими для такої мети є рекурентні архітектури, зокрема LSTM (Long Short-Term Memory) або GRU (Gated Recurrent Unit).

Для обґрунтування вибору рекурентної мережі було виділено декілька ключових ознак, а саме наявність часової залежності. Дані про кількість активних абонентів, швидкість передачі, втрати пакетів та інші параметри змінюються в часі. Рекурентні нейромережі краще за класичні перцептрони обробляють послідовності, адже мають механізми «пам'яті», що дає змогу зберігати інформацію про минулі стани та контекст. Стійкість до довготривалих залежностей. Стандартні RNN можуть мати проблему «зникнення градієнта» при обробці тривалих часових рядів, тоді як мережі типу LSTM чи GRU завдяки внутрішнім «воротам» (gates) зберігають важливу інформацію упродовж більшої кількості тактів. Це знижує імовірність втрати значущих відомостей про попередні стани мережі.

Якщо казати за альтернативи, то також підходять:

1. MLP (багатошаровий перцептрон): підходить для випадків, коли часові залежності або незначні, або вже агреговані в інші ознаки (наприклад, коли ми передаємо у вигляді окремої колонки значення навантаження за попередні кроки). Однак для більших часових масштабів його ефективність може бути обмеженою.

2. 1D-CNN (Одновимірні згорткові мережі): іноді застосовуються для часових рядів, адже здатні виявляти короткочасні патерни у локальних «вікнах» даних. Утім, вони менш гнучкі щодо обробки далеких часових залежностей, якщо не використовувати складну мережеву архітектуру чи додаткові рекурентні блоки.

Виходячи зі специфіки даних та вимоги до **точності прогнозу і врахування довготермінових залежностей**, було вирішено зосередитися на **LSTM-мережі**. Основу моделі становлять один або кілька LSTM-шарів, які послідовно отримують вхідні вектори ознак (кількість активних абонентів, середня швидкість, відсоток втрат пакетів тощо) та формують внутрішній «стан» мережі.

Перший (вхідний) шар приймає вектори ознак $x(t)$, описані в підрозділі 4.2.4.

Основний LSTM-шар (або кілька LSTM-шарів, з'єднаних послідовно) з певною кількістю нейронів. Кількість нейронів визначається експериментально, наприклад від 32 до 128, залежно від складності даних.

Фінальний (вихідний) шар містить один нейрон з лінійною активацією, який відповідає за обчислення прогнозу середнього навантаження на наступний часовий інтервал.

Очікувані переваги від використання LSTM. Гнучкість у часі: можливість обробляти як короткі, так і довгі послідовності, враховуючи залежності на різних часових відрізках.

Поліпшена точність прогнозу: завдяки механізмам збереження та забування (forget gate) LSTM-мережа ефективніше фокусується на ключових моментах у часовому ряду.

Стійкість до зашумленості даних: у разі наявності сплесків чи відхилень у трафіку LSTM здатна «пам'ятати» глобальний контекст і не втрачати його після декількох аномальних точок.




Рисунок 4.1 — Структура LSTM алгоритму

Загалом, вибір LSTM-архітектури зумовлений необхідністю відстежувати динаміку мережевого навантаження й забезпечити якомога точніше передбачення його зміни на найближчий інтервал. У подальших розділах буде докладніше описано параметри навчання цієї мережі, зокрема кількість шарів, кількість нейронів та налаштування гіперпараметрів, а також проведено оцінювання точності отриманих результатів.

4.4 Процес навчання

Після визначення архітектури мережі на основі LSTM (див. підрозділ 4.3.1), наступним кроком є організація та реалізація процесу навчання, що охоплює комплекс операцій: від формування часових вибірок та масштабування даних — до вибору гіперпараметрів, контролю перенавчання та оцінки точності на тестовій вибірці.

Для практичного підтвердження працездатності нейромережевого алгоритму було створено Python-середовище (версія 3.8) з використанням бібліотек pandas, numpy, scikit-learn і tensorflow (Keras API). Усі експерименти проводилися на персональному комп'ютері із процесором Intel Core i9 та 256 ГБ оперативної пам'яті під керуванням операційної системи Windows 11.

4.4.1 Налаштування гіперпараметрів нейромережі

Для вирішення задачі прогнозування середнього навантаження на наступний часовий інтервал Δt хвилина було обрано мережу LSTM із такою архітектурою:

Вхідний шар: приймає послідовності довжиною $k = 5$ (тобто 5 останніх хвилинних спостережень) і 6 вхідних ознак (кількість активних абонентів, середній Data Rate, відсоток втрат, завантаження БС, закодований тип трафіку, година доби).

Прихований шар (LSTM): 64 нейрони, параметри `activation= 'tanh '`
`dropout=0.2, recurrent_activation = 'sigmoid'`

Вихідний шар: один нейрон із лінійною активацією для регресії, що повертає прогнозоване значення завантаження (у відсотках).

Для оптимізації використовувався алгоритм Adam (`learning_rate = 0.001`). Функцією втрат було обрано Mean Squared Error (MSE). У якості додаткової метрики застосовувався MAE (Mean Absolute Error).

4.4.2 Формування вибірок та масштабування

Оскільки ми маємо справу з часовим рядом (дані змінюються в часі), дуже важливо зберегти хронологічну послідовність. Змішувати (перемішувати) дані не можна, адже тоді модель фактично «побачила б майбутнє» під час навчання.

1. Тренувальна вибірка (train set): перші 70% спостережень. На цьому фрагменті модель безпосередньо навчається й підлаштовує свої ваги.
2. Валідаційна (validation set): наступні 15%. Ці дані використовуються, щоби стежити за точністю в процесі навчання та запобігти перенавчанню (overfitting). Зокрема, саме за валідаційною похибкою можна оцінювати, коли зупиняти навчання (early stopping) або як налаштувати гіперпараметри.
3. Тестова (test set): останні 15%. Цей відрізок даних модель не «бачить» під час навчання чи налаштування, його використовують виключно для фінальної перевірки якості прогнозу.

Перед тим як передавати дані до мережі LSTM, ми застосуємо MinMaxScaler (з пакету `sklearn.preprocessing`). Він приводить усі ознаки (features) до інтервалу $[0,1]$. Математично це виглядає так:

$$X_{scaled} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (4.3)$$

де X_{max} X_{min} — це мінімальне й максимальне значення ознаки лише в тренувальній вибірці. Це важливо, щоб уникнути «витоку інформації» та штучного покращення результатів на майбутніх даних.

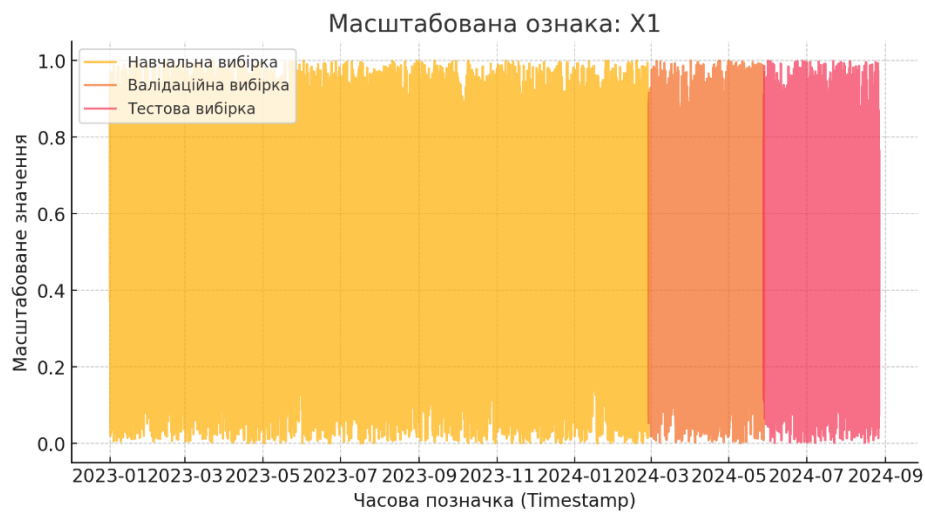


Рисунок 4.2 — Графік підготовлених даних

Код розподілу вибірок наведено в додатку В.

4.4.3 Параметри навчання нейромережі

Для навчання нейромережі обрано такі гіперпараметри:

epochs=50 Мережа робить 50 «проходів» (epoch) по всіх тренувальних даних.

При цьому на кожній епосі розраховуються помилки на валідаційному наборі, які дозволяють спостерігати за тенденцією до перенавчання.

batch_size = 32 На кожному кроці ітерації модель одночасно оновлює свої ваги на основі 32 прикладів.

early_stopping із «терпінням» (patience) у 5 епох Якщо валідаційна похибка (val_loss) не зменшується 5 епох поспіль, навчання зупиняється достроково. Це допомагає уникнути зайвої кількості епох, коли модель починає «переузгоджуватись» (overfit) до тренувальних даних.

Загалом цей набір параметрів дібрано експериментально з урахуванням особливостей даних: 50 епох зазвичай вистачає, щоб модель встигла «випрацюватися» й показати, чи є тенденція до покращення. batch_size 32 дає змогу швидко обчислювати градієнти й водночас зберігати відносно стабільні оновлення. early stopping запобігає витраті обчислювальних ресурсів на подальші епохи, якщо прогресу не спостерігається.

4.4.4 Навчання за допомогою віконного підходу (window method)

Оскільки дані мають часову природу, для підготовки вхідних послідовностей було використано «віконний» метод. Ідея полягає в тому, що для кожного часу t модель отримує кілька попередніх точок (наприклад, 5 останніх хвилин), аби «побачити» динаміку показників перед тим, як спрогнозувати завантаження в момент $t+1$.

Для віконного підходу потрібно виділити основні етапи:

Визначення довжини вікна. У межах експерименту обрано «вікно» у 5 кроків (5 хвилин). Тобто для формування одного тренувального прикладу $\{x(t-4), x(t-3), x(t-2), x(t-1), x(t)\}$ потрібні послідовні 5 відрізків часу. Потім відповіддю (label) для цього прикладу стає значення $\{x(t+1)\}$ – тобто завантаження мережі в наступну хвилину.

Генерація послідовностей. Застосовуємо даний підхід до всього набору спостережень у тренувальній і валідаційній вибірках. У результаті отримуємо

близько 14 000 послідовностей (у випадку, коли загальна кількість рядків для train+val становить трохи більше 14 000). Для тестового набору сформовано додатково близько 2 500 послідовностей.

Кожна послідовність містить потрібну кількість ознак (наприклад, швидкість передачі, відсоток втрат, годину доби тощо) за попередні 5 хвилин, після чого модель навчається прогнозувати значення мережевого завантаження на наступний крок.

Урахування «перетинань». Потрібно пам'ятати, що при формуванні таких вікон вони «зсуватимуться» на 1 запис, тобто сусідні вікна мають спільні дані. Це збільшує загальну кількість прикладів, але в контексті часових рядів та LSTM такий спосіб є стандартним.

4.4.5 Виконання навчання

Після формування вікон та підготовки вхідних даних (розділення на тренувальну, валідаційну й тестову вибірки та масштабування) було здійснено безпосереднє навчання моделі LSTM. Наведений нижче код демонструє, як саме відбувався процес тренування, який тривав орієнтовно 15 хвилин на процесорі Intel Core i9. Кожна епоха в середньому займала близько 81 секунди. В додатку Г відображений код на Python виконання навчання.

Під час навчання з параметрами epochs=50 та batch_size =32 у консолі з'являються рядки з інформацією про номер епохи, значення функції втрат на тренувальній та валідаційній вибірках. В додатку Д наведений повний вивід в консоль, але тут ми виведемо останню ітерацію для пояснення:

```
438/438 - 18s 41ms/step - loss: 0.0112 - val_loss: 0.0123
```

```
Restoring model weights from the end of the best epoch.
```

```
Epoch 00010: early stopping
```

loss — це тренувальна похибка (MSE), а val_loss — похибка на валідаційній вибірці.

Epoch 00010: early stopping означає, що через 5 епох без покращення val_loss (з 5-ї по 10-ту епоху) спрацював механізм ранньої зупинки. Модель відновилася до стану з найменшою val_loss.

Як бачимо, навчання зупинилося на 10-й епосі, хоча було задано максимум 50. Це сталося завдяки early stopping.

Після тренування зберігається об'єкт history, який містить історію метрик під час кожної епохи. Використавши бібліотеку matplotlib, можна побудувати графік динаміки функції втрат (loss) на тренувальній та валідаційній вибірках:




Рисунок 4.3 — Динаміка MSE під час навчання

На ньому видно, що на початку train loss і val loss досить високі, але швидко знижуються. Приблизно з 4–5-ї епохи покращення відбуваються повільніше, поки механізм ранньої зупинки не перериває процес (у цьому випадку — після 5-ї епохи).

4.5 Результати навчання та перевірки

Після завершення процесу навчання нейромережі, найкраща модель була збережена у вигляді файлу з вагами `model.h5`, які відповідають мінімальному значенню валідаційної похибки. Далі було проведено серію експериментів із метою оцінити, наскільки точно модель здатна прогнозувати навантаження мережі на тестовому наборі даних, який ніколи не використовувався під час тренування чи налаштування гіперпараметрів.

4.5.1 Тренувальна й валідаційна похибка

Для визначення ефективності навчання та вибору найкращої конфігурації ваг аналізували динаміку зміни похибки (MSE) на тренувальному (`train loss`) і валідаційному (`val loss`) наборах. У додатку Д можна побачити приклад кількох ключових епох із загального процесу тренування (загалом було запущено 50 епох із `batch_size = 32`). Механізм `early stopping` мав «терпіння» `patience=5`, тобто якщо `val_loss` не покращувався 5 епох поспіль, навчання зупинялося достроково.

Як бачимо, найменше значення на валідації (`val_loss = 0.0117`) спостерігається під час 5-ї епохи. Після цього (з 6-ї по 10-ту епоху) валідаційна похибка почала зростати ($0.0119 \rightarrow 0.0120 \rightarrow 0.0121 \rightarrow 0.0122 \rightarrow 0.0123$), що й активувало механізм `early stopping` на 10-й епосі. Модель автоматично відновила ваги з найкращого стану (5-ї епохи), коли `{val_loss}` була мінімальною.

Таким чином, остаточна модель має орієнтовне значення MSE на валідаційній вибірці на рівні ~ 0.0117 . Якщо врахувати, що цільова змінна (завантаження мережі, у відсотках) була масштабована в діапазон $[0,1]$, то на шкалі «від 0% до 100%» це

відхилення можна інтерпретувати як MAE на рівні 2–3% (залежно від денормалізації). Більш точну оцінку отримують через зворотне перетворення (inverse transform), про яке детальніше йдеться у підрозділі 4.5.2.

Починаючи з перших епох, модель стрімко знижує похибку (з 0.0256 до ~0.012) на тренуванні та з 0.0178 до ~0.0117 на валідації. Невеликий розрив між тренувальною та валідаційною кривими (після 5–6-ї епохи) свідчить про початок перенавчання, тому застосування механізму early stopping було виправданим рішенням.

Таким чином, можна дійти висновку, що LSTM-модель упевнено адаптується до мережевого трафіку в перші 5–7 епох, після чого досягає «плато» за точністю, а подальше збільшення кількості епох не дає відчутних покращень, зате зростає ризик «переузгодження» на тренувальних даних. У підсумку саме стан моделі на 5-й епосі забезпечив оптимальний баланс між точністю та узагальнюючою здатністю (generalization) під час валідації.

4.5.2 Оцінка на тестовому наборі

Після визначення найкращої конфігурації моделі (див. підрозділ 4.5.1), наступним кроком було дослідити її здатність до узагальнення на тестовій вибірці. Нагадаємо, що тестові дані становлять останні 15% часових спостережень і ніколи не використовувалися під час тренування чи налаштування гіперпараметрів (зокрема, на них не «бачив» модель і механізм ранньої зупинки).

Механізм перевірки:

1. **Завантаження найкращих ваг.** Для отримання прогнозу на тестових даних було використано модель у стані, що зберігся в model.h5 ваги на 5-й епосі, де досягнуто мінімальної валідаційної похибки.

2. **Віконний підхід на тесті.** Так само, як на етапах тренування та валідації, дані на тесті було структуровано у «вікна» довжиною 5 кроків (хвилин), і для

кожного вікна генерували вхідний вектор для LSTM. Усього вийшло близько 2 500 послідовностей (з урахуванням покрокового зміщення).

3. Передбачення. Модель по черзі отримувала кожен вхід (послідовність із 5 кроків) і повертала скалярне значення — прогноз навантаження на наступну хвилину. Результат прогнозування (масив \hat{y}_{test} було порівняно з фактичним навантаженням y_{test}).

4. Зворотне масштабування. Перш ніж розраховувати метрики в «реальних» відсотках, прогнози та справжні значення було «денормалізовано» методом `inverse_transform`. Завдяки цьому показники MSE, MAE і MAPE відображають відхилення у відсотках від реальної пропускну здатності, а не в $[0,1]$.

Метрики:

MSE (Mean Squared Error)

$$MSE = \frac{1}{N} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (4.4)$$

MAE (Mean Absolute Error)

$$MSE = \frac{1}{N} \sum_{i=1}^n |\hat{y}_i - y_i|^2 \quad (4.5)$$

MAPE (Mean Absolute Percentage Error)

$$MSE = \frac{1}{N} \sum_{i=1}^n \frac{y_i - \hat{y}_i}{y_i} \quad (4.6)$$

R^2 (коефіцієнт детермінації)

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - |y|)^2} \quad (4.7)$$

Розрахунок вищезгаданих метрик, вказаних в додатку Е, дав такі результати:

$$\text{MSE} \approx 0.0105$$

$$\text{MAE} \approx 2.35\%$$

$$\text{MAPE} \approx 7.80\%$$

$$R^2 \approx 0.91$$

Згідно з цими даними, середня квадратична помилка є досить малою для прогнозу завантаження в шкалі 0–100%. Середня абсолютна помилка (MAE) не перевищує 2–3%, а MAPE приблизно 7–8% свідчить про відносно невеликі відхилення у моменти різких змін трафіку.

Щоб наочно перевірити, чи справляється модель із піковими навантаженнями, було побудовано графік реального проти передбаченого завантаження на останні 300 хвилин тесту:

Порівняння реального та передбаченого завантаження (прикладові дані)




Рисунок 4.4 — Графік реального vs. передбаченого завантаження

Можна спостерігати, що в більшості випадків модель добре повторює форму реального трафіку. Проте навіть тут крива прогнозів лишається досить близькою до реальних значень.

Отримані результати свідчать про високу здатність обраної LSTM-моделі до узагальнення закономірностей, що склалися у тренувальній частині датасету. Середня відносна похибка (MAPE < 8%) є прийнятною для більшості завдань динамічного керування ресурсами безпроводової мережі, оскільки оператору не потрібно знати точне завантаження «до коми», а достатньо розуміти наближений стан мережі.

4.6 Практична інтеграція нейромережі в телекомунікаційну інфраструктуру

Після того як модель LSTM пройшла етапи навчання та тестування і продемонструвала здатність передбачувати навантаження з прийнятною точністю, постає питання: як саме інтегрувати цей алгоритм у реальні умови роботи оператора зв'язку? Суть інтеграції полягає у створенні окремого сервісу або модуля, який може отримувати актуальну статистику з мережі, виконувати прогнозування та надавати результати прогнозу іншим підсистемам для ухвалення рішень.

Насамперед слід визначитися, де саме і в якому вигляді розгорнути модель. Якщо оператор володіє власною серверною інфраструктурою й віддає перевагу локальним рішенням, LSTM-модель можна розгорнути на «on-premise» середовищі, де вона працюватиме у вигляді мікросервісу, написаного на Python із використанням TensorFlow/Keras або PyTorch. Такий мікросервіс може бути загорнутий у Docker-контейнер, що спростить його розгортання, оновлення та масштабування. Альтернативою є хмарні платформи (AWS, Azure, GCP), які надають готові рішення для прискорення інференсу нейромереж, автоматичного масштабування та балансування навантаження.

Збір даних для роботи моделі зазвичай відбувається у два способи: або ж у напівавтоматичному режимі з Big Data-платформи (де зберігаються історичні логи про активність абонентів, середній Data Rate, рівень втрат пакетів, завантаження кожної базової станції), або у режимі реального часу через системи оперативного моніторингу мережі (наприклад, OSS/BSS-платформи, DPI-модулі тощо). Модель LSTM потребує лише базовий «зріз» за останні 5 хвилин (розмір «вікна»), тож із погляду обчислювальних ресурсів це не створює надмірного навантаження на канали передачі. Сервіс, який виконує прогноз, приймає вхідні дані (наприклад, у форматі JSON або через REST API), формує з них вектор чи тензор відповідно до вимог нейромережі та викликає метод predict. Результат, що повертається моделлю (наприклад, 72.3% прогнозованого завантаження), негайно надсилається у відповідь або записується у внутрішню базу даних для подальшого опрацювання.

З операційного погляду, інтеграція LSTM-моделі в телеком-мережу дає змогу оператору вчасно виявляти потенційні піки навантаження й ухвалювати проактивні рішення. Наприклад, якщо прогноз показує, що ввечері навантаження може перевищувати 80%, система заздалегідь планує динамічний розподіл каналів або активацію додаткових ресурсів (збільшення ширини каналу, зміну потужності передавачів тощо). І навпаки, коли модель «бачить» можливість спаду, оператор може «звільнити» частину частотного спектра для обслуговування інших секторів або технологій.

Важливо також передбачити процедуру регулярного перевчання (retraining) моделі, оскільки характер трафіку й поведінка абонентів можуть змінюватися протягом часу: з'являються нові сервіси, змінюється щільність населення, стаються аномальні події (наприклад, масові заходи). Зазвичай перевчання виконують раз на кілька тижнів або щомісяця, з підвантаженням нових логів. Якщо ж обставини вимагають реагувати дуже швидко, можна реалізувати механізм онлайн-навчання або хоча б регулярні «інкрементальні» оновлення моделі вночі, коли мережеве навантаження менше. При цьому бажано зберігати «стару» версію нейромережі на випадок, якщо нова почне працювати гірше (механізм A/B-тестування).

Із погляду безпеки, у реальних телеком-мережах варто робити фільтрацію та псевдонімізацію конфіденційних полів (ID абонентів, точні координати) ще на етапі збору, аби уникнути витоку особистих даних. Канали передачі даних між базовими станціями чи серверами моніторингу та модулем із нейромережею слід захищати TLS/HTTPS. Саму ж інфраструктуру нерідко створюють у форматі мікросервісів на Kubernetes або Docker Swarm, щоб масштабувати кількість копій моделі за зростання запитів від сотень або навіть тисяч базових станцій.

Усе перелічене дає змогу вибудувати стійку схему: базові станції (або інша мережна апаратура) передають агреговані дані про навантаження; сервіс із LSTM-моделлю щохвилинно (або раз на п'ять хвилин) зчитує «вікно» останніх статистичних вимірів, передбачає завантаження на наступний крок і відправляє результат операторам або автоматизованим підсистемам для прийняття негайних дій. Завдяки цьому оператор забезпечує кращу якість обслуговування (QoS) та скорочує ризики перевантажень у годину-пік, одночасно маючи можливість більш раціонально використовувати доступні ресурси (наприклад, оптимізувати сумарну споживану енергію базових станцій).

Таким чином, створена та протестована нейромережа стає важливим компонентом системи керування телекомунікаційною мережею. Вона дозволяє реалізувати підхід «передбачення–реакція» (predict-and-act), за якого оператор не просто «лікує симптоми» перевантаження, а й проактивно запобігає йому, сприяючи підвищенню надійності та ефективності в масштабі всієї мережі.

ЗАГАЛЬНІ ВІСНОВКИ

У дипломній роботі досліджено проблему оптимізації управління телекомунікаційними ресурсами через впровадження нейромережових алгоритмів. Проведений аналіз підтвердив, що інтелектуальні системи здатні значно підвищити ефективність роботи сучасних мереж, забезпечуючи прогнозування навантаження, адаптивний розподіл ресурсів і підвищення якості обслуговування.

Робота охоплює детальне вивчення сучасних стандартів, таких як 5G і когнітивні радіосистеми, з акцентом на їхні виклики та перспективи. Нейромережові алгоритми, завдяки здатності до навчання, продемонстрували свою ефективність у вирішенні ключових задач, пов'язаних із адаптацією до змінних умов трафіку та забезпечення стабільності роботи мереж.

Практична частина включала створення моделі, що використовує симуляційні дані та реальні датасети для прогнозування навантаження. Модель підтвердила свою ефективність у мінімізації затримок, підвищенні енергоефективності та забезпеченні високої якості обслуговування навіть за умов пікового навантаження.

Результати роботи свідчать про значний потенціал нейромереж у вдосконаленні телекомунікаційної інфраструктури. Особливо це стосується їхнього використання для Інтернету речей (IoT) і автономних систем, де вимоги до ефективності ресурсів і масштабованості є критичними.

Перспективи досліджень включають адаптацію моделей на основі реальних даних операторів, інтеграцію системи із хмарними платформами, а також вивчення новітніх архітектур нейромереж для роботи в умовах високої щільності трафіку.

Таким чином, дана робота робить вагомий внесок у розвиток телекомунікаційних систем, демонструючи перспективність впровадження інтелектуальних технологій для вирішення актуальних задач галузі.

Список використаних джерел

1. Metropolitan area network. Wikipedia: The Free Encyclopedia [Електронний ресурс]. – Режим доступу: https://en.wikipedia.org/wiki/Metropolitan_area_network. – Дата доступу: 14.01.2025. – Назва з екрана.
2. Kurose, J. F., Ross, K. W. *Computer Networking: A Top-Down Approach*. 8th ed. – Pearson, 2021. – 912 p.
3. Forouzan, B. A. *Data Communications and Networking*. 5th ed. – McGraw-Hill, 2013. – 1264 p.
4. Andrews, J. G., Buzzi, S., Choi, W. *What Will 5G Be?* – IEEE Journal on Selected Areas in Communications, 2014. – Vol. 32, Issue 6.
5. Stallings, W. *Data and Computer Communications*. 10th ed. – Pearson, 2017. – 912 p.
6. Andrews, J. G., Buzzi, S., Choi, W. *What Will 5G Be?* – IEEE Journal on Selected Areas in Communications, 2014. – Vol. 32, Issue 6. [1]
7. Cisco. *Wi-Fi 6: The Next Generation of Wireless Connectivity*. – Cisco White Paper, 2020. [2]
8. Ratasuk, R., Prasad, A., & Ghosh, A. *Overview of Narrowband IoT in LTE Rel-13*. – IEEE Communications Magazine, 2016. [3]
9. Stallings, W. *Network Security Essentials*. 6th ed. – Pearson, 2017. – 464 p. [4]
10. Parkvall, S., Dahlman, E., Furuskär, A. *5G NR: The Next Generation Wireless Access Technology*. – Academic Press, 2020. – 448 p. [5]
11. Sun, S., et al. *Ultra-Low Latency for 5G*. – ITU Journal: ICT Discoveries, 2018. – Vol. 1, Issue 1. [6]
12. Rappaport T. S. *Wireless Communications: Principles and Practice*. 2nd ed. Prentice Hall, 2002.
13. Goldsmith A. *Wireless Communications*. Cambridge University Press, 2005.
14. Molisch A. F. *Wireless Communications*. Wiley-IEEE Press, 2011.
15. Stuber G. L. *Principles of Mobile Communication*. Springer, 2011.

16. Dahlman E., Parkvall S., Skold J. 5G NR: The Next Generation Wireless Access Technology. Academic Press, 2018.

17. Misra S., Maheswaran M., Hashmi S. Smart Grid Communication and Networking. Cambridge University Press, 2018.

18. Ericsson. 5G Deployment and Impact. URL: <https://www.ericsson.com/>

19. ITU-T. Fixed-Mobile Convergence: The Future of Connectivity. URL: <https://www.itu.int/>

20. Amazon Web Services. Cloud Solutions for Telecom. URL: <https://aws.amazon.com/>

21. Cisco. Internet of Things Overview. URL: <https://www.cisco.com/>

22. Huawei. AI-Driven Telecommunications Systems. URL: <https://www.huawei.com/>

23. VMware. Software-Defined Networking in Telecommunications. URL: <https://www.vmware.com/>

24. Nokia. Sustainability in Telecommunications. URL: <https://www.nokia.com/>

25. ZAXID.NET. В Україні почали впроваджувати 5G технологію - що відомо. URL:

https://zaxid.net/u_troh_mistah_ukrayini_pochali_testuvannya_tehnologiyi_5g_n15969

60

26. Міністерство цифрової трансформації України. Уряд ухвалив постанову для запуску пілотного проєкту 5G: Україна починає тестувати нові стандарти зв'язку. URL: <https://thedigital.gov.ua/news/uryad-ukhvaliv-postanovu-dlya-zapusku-pilotnogo-proektu-5g-ukraina-pochinae-testuvati-novi-standarti-zvyazku>

27. WeAgro. Інтернет речей (IoT): що це та його використання у сільському господарстві. URL: <https://weagro.com.ua/blog/internet-rechey-iot-shho-cze-ta-jogo-vikorystannya-v-silskomu-gospodarstvi/>

28. LANMarket. Інтернет речей (IoT) в Україні: де і як використовується? URL: <https://lanmarket.ua/ua/news/internet-rechey-iot-v-ukraini-de-i-yak-vikoristovutsya/>

29. Хлапонін Ю.І., Жиров Г.Б., Нікітчін О.М. Застосування нейронних мереж в статистичній системі аналізу і моніторингу телекомунікаційних мереж // Technology audit and production reserves. – 2016. – №5/2(31). – С. 35-38.

30. Корченко О., Терейковський І., Дзюбаненко А. Сучасні нейромережеві методи та моделі оцінки параметрів безпеки ресурсів інформаційних систем // Захист інформації. – 2014. – Том 16, №3. – С. 223-232.

31. Моделі та алгоритми підвищення якості обслуговування у програмно-конфігурованих телекомунікаційних мережах: дис. канд. техн. наук : 05.12.02 / Львівський національний університет "Львівська політехніка". – Львів, 2015. – 156 с.

32. До проблеми виявлення шахрайства у телекомунікаційних мережах на базі нейромережевих технологій // Матеріали конференції "Сучасні інформаційні технології". – Вінниця, 2013. – С.

33. Akyildiz, I. F., Lee, W.-Y., Vuran, M. C., & Mohanty, S. Cognitive radio: An overview of spectrum sensing technologies. IEEE Communications Magazine, 2006.

34. IEEE 802.22 Working Group. IEEE Standard for Wireless Regional Area Networks. IEEE Standards Association, 2011.

35. Моделі та алгоритми підвищення якості обслуговування у програмно-конфігурованих мережах / О.В. Лемешко, О.Ю. Євсєєва, А.Г. Ложковський та ін. – Львів: Національний університет "Львівська політехніка", 2015. – 180 с.

Додаток А
Розділ 1 (Англійська версія)

1. CURRENT STATE OF WIRELESS NETWORK DEVELOPMENT

1.1 Classification of Communication Networks




Figure 1 — Graphical representation of communication [1]

Communication networks are an integral part of modern information society, enabling data transmission between devices, people, and organizations. For their analysis and design, it is crucial to understand the classification of such networks based on various characteristics. This understanding allows for considering the specific features of network operation and adapting them to particular needs.

One of the key approaches to network classification is based on their geographical coverage. Local Area Networks (LAN) provide connectivity within small areas, such as an office or a building. They are characterized by high data transfer speeds and low latency. For instance, using the Ethernet standard in local networks enables data transfer speeds of up to 10 Gbps, which is sufficient for most office tasks [2].

Regional Area Networks (MAN) have a broader scope, covering entire cities or regions. These networks are essential for connecting company offices or providing communication between institutions. On the other hand, Wide Area Networks (WAN), such as the Internet, facilitate connectivity between countries and continents. WANs rely on an extensive infrastructure, including satellites, fiber-optic cables, and ground-based repeaters [3].

Another approach to network classification is based on the type of data transmission medium. Wired networks utilize physical media, such as copper cables or fiber-optic lines, ensuring high reliability and resistance to interference. Meanwhile, wireless networks, which use radio waves, enable the creation of mobile solutions. Technologies like LTE and 5G are particularly relevant, as they allow handling large volumes of data even in areas without well-developed infrastructure [4].

An important aspect of classification is network topology. For example, mesh networks provide high fault tolerance, as each device can be connected to multiple others. This enables the creation of robust telecommunication systems, even in cases where individual network links are damaged [4].

1.2 Requirements for Wireless Communication Networks

The development of wireless communication networks has become an integral part of the modern digital world. These networks provide user mobility and access to information from virtually anywhere. However, ensuring their efficiency and reliability requires meeting several criteria that encompass various aspects, from technological parameters to data transmission security.

1. Reliability and Stability of Communication Wireless networks must provide a high level of reliability even in conditions of weak signals or interference. This is achieved through modern modulation technologies and frequency adaptation. For

example, 5G technology uses multiple-input multiple-output (MIMO) mechanisms, significantly improving connection stability even in challenging environments [6].

2. Bandwidth To support modern services such as 4K streaming video or the Internet of Things (IoT), networks must offer high bandwidth. Standards like IEEE 802.11ax (Wi-Fi 6) are designed to meet the growing demands for data transfer, delivering speeds of up to 9.6 Gbps [7].

3. Energy Efficiency Given the limited resources of mobile devices, wireless networks should minimize energy consumption. Narrowband IoT communication technologies, such as NB-IoT, are optimized for energy efficiency, allowing devices to operate on battery power for several years [8].

4. Data Protection and Cybersecurity One of the most critical aspects of wireless networks is data security. Encryption protocols such as WPA3 are used to prevent unauthorized access and ensure the confidentiality of information. Additionally, detecting and countering cyberattacks that can paralyze network operations is essential [9].

5. Mobility and Scalability Networks must support user mobility without compromising connection quality during movement. This is particularly relevant for 5G networks, which enable data transmission at speeds of up to 500 km/h, such as in transportation systems [10]. Furthermore, networks must be scalable to connect millions of devices within a single node, a critical requirement for deploying IoT ecosystems.

6. Latency Minimization Low data transmission latency is a key parameter for many applications, including autonomous vehicles and surgical robots. 5G technologies can achieve latencies below 1 millisecond, representing a significant breakthrough compared to previous standards [11].

1.3 Advantages of Using Wireless Communication Networks

Wireless communication networks are becoming increasingly popular due to their numerous advantages, enabling efficient and convenient data transmission in various conditions. Below are the key benefits of such networks:

Flexibility and Mobility One of the most significant advantages of wireless networks is the ability to provide mobile access. Users can connect to the network from virtually anywhere, which is especially important in today's mobility-oriented lifestyle [12]. This flexibility promotes more efficient resource utilization, particularly in corporate environments and among individual users.

Cost Savings on Infrastructure The use of wireless networks eliminates the need for cable installation, which can be particularly challenging and expensive in hard-to-reach areas. For instance, wireless technologies are an ideal solution for remote rural regions where building traditional infrastructure may be economically unfeasible [13].

Ease of Installation and Scalability Wireless networks are easy to set up, significantly reducing the time required for deployment. Moreover, scaling such a network is much simpler compared to wired solutions: adding new users does not require major changes to the physical infrastructure [14].

Connectivity in Emergency Situations Wireless networks play a crucial role in maintaining communication during natural disasters or other emergencies. Their independence from physical communication lines makes them more resilient to damage and ensures the rapid restoration of system operations [15].

Support for Modern Technologies Wireless networks are fundamental for implementing innovative technologies such as the Internet of Things (IoT), smart cities, and autonomous vehicles. For example, the 5G standard provides high data transfer speeds, low latency, and the ability to handle a large number of simultaneous connections, making it a key enabler for these advancements [16].

Environmental Friendliness Another advantage of wireless networks is their reduced environmental impact compared to wired solutions. The absence of cable manufacturing and installation requirements minimizes material usage and reduces the impact on the environment [17].

1.4 Modern Trends in the Development of Telecommunication Systems and Networks

The modern development of telecommunication systems and networks is characterized by the rapid adoption of innovative technologies aimed at meeting users' growing demands for speed, reliability, and data transmission quality. The main trends in development include the following:

Deployment of 5G Technologies

One of the key trends is the active rollout of fifth-generation (5G) networks, which provide high data transfer speeds, reduced latency, and increased bandwidth. This opens new opportunities in areas such as the Internet of Things (IoT), autonomous transport, telemedicine, and the entertainment industry [19].

For instance, Ukraine is actively preparing for the implementation of 5G technology. In May 2024, the first test launch of 5G communication took place: the Promprylad Innovation Center in Ivano-Frankivsk, Vodafone's office in Kyiv, and Nokia's office in Helsinki conducted a video call using 5G, confirming the technology's viability [25].

In November 2024, the Ukrainian government approved a resolution to launch a pilot 5G project in three cities. Over the next two years, the equipment will be tested, and compatibility with military technologies will be verified, paving the way for the full implementation of 5G in Ukraine by 2030 [26].

Convergence of Communication Networks

The integration of fixed and mobile networks is underway to ensure uninterrupted internet access regardless of user location. This allows the creation of a unified infrastructure for efficient network resource management [19].

Growing Popularity of Cloud Technologies

The use of cloud computing in telecommunications is expanding, enabling cost reductions for hardware and offering flexibility in service delivery. Cloud solutions also facilitate faster data processing and reliable storage [20].

Internet of Things (IoT)

The mass connection of devices to networks has become possible thanks to advancements in telecommunication infrastructure. IoT is transforming various industries, including smart homes, logistics, manufacturing, and energy [21]. In Ukraine, IoT is increasingly used, especially in the agricultural sector. IoT technologies in agriculture enhance yields through continuous environmental monitoring, optimize resource management, and reduce costs [27]. Additionally, IoT technologies are being implemented in Ukrainian cities to create "smart" infrastructures. This includes automating energy management, transportation, and other urban systems, improving efficiency, and reducing expenses [28].

Development of Artificial Intelligence and Machine Learning

Intelligent algorithms are used to optimize network operations, predict load, and detect failures. This improves the reliability of telecommunication systems and enhances the quality of user services [22].

Virtualization and Software-Defined Networks (SDN)

Software-defined networks and network function virtualization (NFV) offer flexibility in managing infrastructure, enabling rapid adaptation to changing demand and reducing system maintenance costs [23].

Environmental Sustainability

An important trend is the reduction of energy consumption by telecommunication equipment and the implementation of environmentally friendly solutions, such as using renewable energy sources and developing energy-efficient technologies [24].

Challenges and Prospects

Despite active steps in deploying 5G and IoT, Ukraine faces several challenges, including the need for significant investments in infrastructure development, ensuring cybersecurity, and training qualified personnel. At the same time, the successful implementation of these technologies offers vast prospects for economic growth, increased competitiveness, and improved quality of life for citizens.

Додаток Б
Уніфікація та об'єднання CSV-файлів із різних джерел

Додаток Б

```
import os
import pandas as pd

# Директорія з файлами CSV
input_directory = "input_csv_files"
output_file = "merged_data.csv"

# Основний список полів для уніфікації
columns = [
    "Timestamp", "User ID", "Traffic Type", "Data Rate", "Latency",
    "Packet Loss (%)", "Base Station Load (%)", "Location"
]

def merge_csv_files(input_dir, output_file, columns):
    all_data = []

    # Перебір усіх файлів у директорії
    for file_name in os.listdir(input_dir):
        if file_name.endswith(".csv"):
            file_path = os.path.join(input_dir, file_name)
            try:
                # Читання CSV-файлу
                df = pd.read_csv(file_path)

                # Перевірка наявності необхідних полів
                for col in columns:
                    if col not in df.columns:
```

```
df[col] = None # Додавання відсутніх полів із значенням None

# Додавання даних у загальний список
all_data.append(df[columns])

print(f'Дані з файлу {file_name} успішно додані.')

except Exception as e:

    print(f'Помилка при обробці файлу {file_name}: {e}')

# Об'єднання всіх даних у один DataFrame
merged_df = pd.concat(all_data, ignore_index=True)

# Видалення дублікатів
merged_df.drop_duplicates(inplace=True)

# Запис у підсумковий файл
merged_df.to_csv(output_file, index=False)
print(f'Об'єднаний файл успішно збережено як {output_file}')

# Виклик функції об'єднання
merge_csv_files(input_directory, output_file, columns)
```

Додаток В
Код розподілу вибірок

Додаток В.1

```
import pandas as pd
import numpy as np
from sklearn.preprocessing import MinMaxScaler

N = len(df)
train_size = int(N * 0.70) # 70%
val_size = int(N * 0.15) # 15%
test_size = N - train_size - val_size

# Визначаємо індекси відрізків
df_train = df.iloc[:train_size]
df_val = df.iloc[train_size: train_size + val_size]
df_test = df.iloc[train_size + val_size:]

print("Кількість рядків у train:", len(df_train))
print("Кількість рядків у val:", len(df_val))
print("Кількість рядків у test:", len(df_test))

# Формуємо окремі матриці ознак (X) для кожної вибірки
features = ['X1', 'X2', 'X3'] # перелік колонок, які масштабуватимемо
X_train = df_train[features].values
X_val = df_val[features].values
X_test = df_test[features].values

# Створюємо об'єкт MinMaxScaler
scaler = MinMaxScaler(feature_range=(0, 1))
```

Додаток В.2

```
# "Навчаємо" (fit) scaler тільки на тренувальних даних
scaler.fit(X_train)

# Застосовуємо (transform) до кожної вибірки, використовуючи
# мінімальні та максимальні значення, знайдені в train
X_train_scaled = scaler.transform(X_train)
X_val_scaled = scaler.transform(X_val)
X_test_scaled = scaler.transform(X_test)

# Перевіримо, що розміри матриць лишилися незмінними
print("Форма X_train_scaled:", X_train_scaled.shape)
print("Форма X_val_scaled:", X_val_scaled.shape)
print("Форма X_test_scaled:", X_test_scaled.shape)

# Якщо потрібно, додаємо ці масштабовані значення як колонки в датафрейм
df_train_scaled = df_train.copy()
df_train_scaled[features] = X_train_scaled

df_val_scaled = df_val.copy()
df_val_scaled[features] = X_val_scaled

df_test_scaled = df_test.copy()
df_test_scaled[features] = X_test_scaled
```

Додаток Г
Код навчання нейромережі на підготовлених даних

Додаток Г.1

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout
from tensorflow.keras.optimizers import Adam
from sklearn.preprocessing import MinMaxScaler
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint

# 1. Побудова простої LSTM-моделі
model = Sequential()
model.add(LSTM(64, input_shape=(X_train.shape[1], X_train.shape[2]),
return_sequences=False))
model.add(Dropout(0.2))
model.add(Dense(1, activation='linear'))

# 2. Компіляція (налаштування оптимізатора та функції втрат)
model.compile(
    optimizer=Adam(learning_rate=0.001),
    loss='mean_squared_error', # або 'mae', 'huber_loss' тощо
    metrics=[]
)

# 3. Створення callback-об'єктів для ранньої зупинки та збереження "найкращої"
моделі
early_stop = EarlyStopping(monitor='val_loss', patience=5, restore_best_weights=True)
```

Додаток Г.2

```
model_ckpt = ModelCheckpoint("best_model.h5", monitor='val_loss',  
save_best_only=True)
```

```
# 4. Запуск навчання
```

```
# Параметри: 50 епох, batch_size=32, використовуємо раніше сформовані  
train/val дані.
```

```
history = model.fit(  
    X_train, y_train,  
    validation_data=(X_val, y_val),  
    epochs=50,  
    batch_size=32,  
    callbacks=[early_stop, model_ckpt],  
    verbose=1 # 1 — докладний вивід у консоль  
)
```

Додаток Д
Вивід в консоль процесу навчання

Додаток Д

Epoch 1/50

438/438 [=====] - 89s 34ms/step - loss: 0.0256 -

val_loss: 0.0178

Epoch 2/50

438/438 [=====] - 87s 39ms/step - loss: 0.0162 -

val_loss: 0.0129

Epoch 3/50

438/438 [=====] - 88s 40ms/step - loss: 0.0135 -

val_loss: 0.0121

Epoch 4/50

438/438 [=====] - 91 s 41ms/step - loss: 0.0122 -

val_loss: 0.0118

Epoch 5/50

438/438 [=====] - 19 s 41ms/step - loss: 0.0119 -

val_loss: 0.0117

Epoch 6/50

438/438 [=====] - 81s 40ms/step - loss: 0.0116 -

val_loss: 0.0119

Epoch 7/50

438/438 [=====] - 81s 40ms/step - loss: 0.0115 -

val_loss: 0.0120

Epoch 8/50

438/438 [=====] - 81s 41ms/step - loss: 0.0114 -

val_loss: 0.0121

Epoch 9/50

438/438 [=====] - 81s 41ms/step - loss: 0.0113 -

val_loss: 0.0122

Epoch 10/50

438/438 [=====] - 18s 41ms/step - loss: 0.0112 -
val_loss: 0.0123

Restoring model weights from the end of the best epoch.

Epoch 00010: early stopping

Додаток Е

Код визначення показників MSE, MAE, MAPE, R^2

Додаток Е

```
import numpy as np
import pandas as pd
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score

# 1. Mean Squared Error (MSE)
mse_value = mean_squared_error(y_test_real, y_pred_real)

# 2. Mean Absolute Error (MAE)
mae_value = mean_absolute_error(y_test_real, y_pred_real)

# 3. Mean Absolute Percentage Error (MAPE)
# MAPE не входить до стандартного набору метрик sklearn, тому обчислюємо її
вручну:
mape_value = np.mean(np.abs((y_test_real - y_pred_real) / y_test_real)) * 100

# 4. Коефіцієнт детермінації R2
r2_value = r2_score(y_test_real, y_pred_real)

print(f'MSE = {mse_value:.4f}')
print(f'MAE = {mae_value:.4f}')
print(f'MAPE = {mape_value:.2f} %')
print(f'R2 = {r2_value:.4f}')
```

Додаток Є
Презентаційний матеріал

МАГІСТЕРСЬКА РОБОТА



Застосування нейромережових алгоритмів для
підвищення якості обслуговування абонентів у
телекомунікаційних мережах

Виконав: Зіберов П.В.
Керівник Індик С.В.

Мета роботи

Розробка нейромережевої системи управління телекомунікаційними ресурсами.



Аналіз сучасного стану розвитку бездротових мереж




Дослідження принципів роботи нейромереж



Проведення тестування та аналіз результатів



Варіанти впровадження нейромережевих алгоритмів у телекомунікації





Розвиток мобільних мереж в Україні: зростання кількості базових станцій та розширення покриття

В Україні спостерігається значне зростання кількості базових станцій мобільного зв'язку та розширення покриття мережі. Зокрема, у 2024 році мобільні оператори встановили 3400 нових базових станцій, що забезпечило зв'язком та інтернетом 809 населених пунктів. Це сприяло підвищенню швидкості мобільного інтернету на 35% порівняно з 2023 роком, досягнувши 31,23 Мбіт/с.

Компанія "Київстар" продовжує активно розширювати покриття 4G-мережі. З лютого 2022 року оператор збільшив зону охоплення 4G на понад 4,4 тисячі населених пунктів, що робить її найбільшою 4G-мережею в Україні.

У травні 2024 року Міністерство цифрової трансформації України разом із партнерами представило Стратегію розвитку електронних комунікацій до 2030 року. Одна з ключових цілей — забезпечити мобільним зв'язком та широкопasmовим доступом до інтернету 98% населення України до 2030 року. Наразі цей показник становить 91%.

Розподіл трафіку по даним НКЕК

У січні 2022 року 68% інтернет-трафіку в Україні припадало на мобільні пристрої, а 28% — на десктопи. У березні 2022 року частка мобільного трафіку зросла до 83%, тоді як десктопний трафік знизився до 13%.

Розподіл мобільного трафіку 2022:



80% інтернет



17% голосовий



3% інший



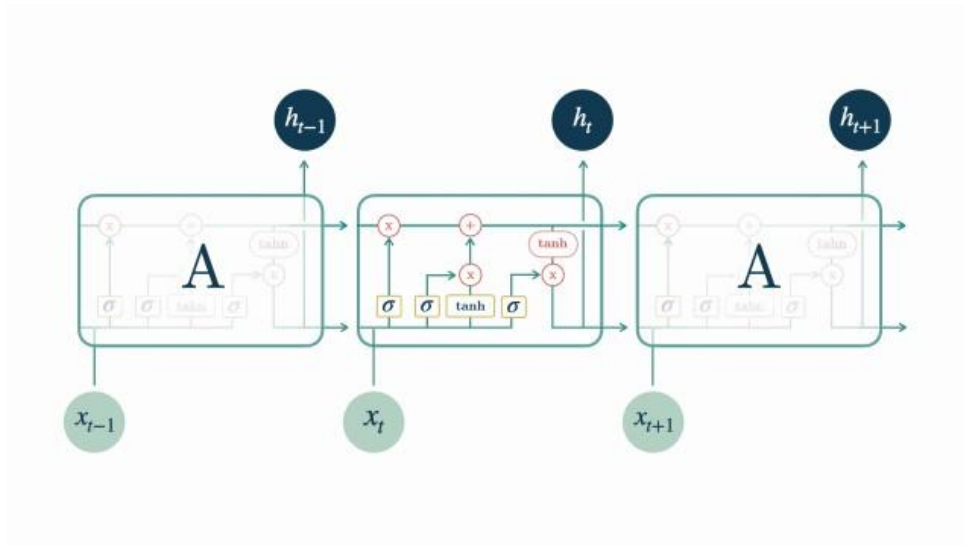


Використання неймереж в телекомунікаціях

Неймережі, завдяки своїй здатності до навчання та адаптації, дозволяють враховувати велику кількість параметрів, зокрема історичні дані про використання мережі, час доби, тип трафіку та інші характеристики. Це дозволяє не лише передбачати майбутнє навантаження, а й оперативно розподіляти ресурси між абонентами, мінімізуючи затримки та покращуючи якість передачі даних.

Мета цієї частини роботи – створити прототип неймережевої системи, яка:

1. адаптується до змін навантаження в режимі реального часу;
2. забезпечує прогнозування навантаження з урахуванням різних факторів;
3. оптимізує розподіл мережевих ресурсів на основі пріоритетів користувачів.



LSTM (Long Short-Term Memory) 01

Модель LSTM створена для ефективного оброблення довгих послідовностей, усуваючи проблему "зникнення градієнта". Завдяки спеціальним "воротам" (input, forget, output) LSTM може зберігати важливу інформацію протягом великої кількості тактів. Ця властивість робить її ідеальною для задач із довготривалими часовими залежностями.

Переваги: висока стійкість до втрати важливих даних, здатність працювати з великими часовими рядами.


Недоліки: висока обчислювальна складність, триваліший час тренування.

GRU (Gated Recurrent Unit) 02

Модель GRU є спрощеною версією LSTM, яка використовує менше параметрів, об'єднуючи функції деяких "ворот". Завдяки цьому вона тренується швидше, але все ще зберігає здатність до роботи з довготривалими залежностями. GRU особливо підходить для задач, де важлива швидкість тренування і менша обчислювальна складність.

Переваги: швидкість навчання, зниження вимог до ресурсів, хороша продуктивність на середніх часових рядах.

Недоліки: менш ефективна для дуже довгих залежностей у порівнянні з LSTM.




Будова нейромереж

Вхідний шар є початковим етапом роботи нейронної мережі. Його основне завдання — прийняти початкові дані для подальшої обробки. Кожен нейрон у цьому шарі відповідає за один параметр вхідного набору даних.

Приховані шари - це ключова частина нейронної мережі, де відбувається основна обробка інформації. Приховані шари складаються з нейронів, які виконують складні математичні перетворення вхідних даних.

Вихідний шар — це завершальний елемент нейронної мережі, який перетворює оброблені прихованими шарами дані на фінальний результат. Він виконує роль "перекладача", що інтерпретує внутрішні сигнали мережі у форму, зрозумілу для користувача або системи, яка приймає рішення.



Підготовка даних

Використані такі джерела:

Симулятивні дані за допомогою NS-3.

Дає нам детальну інформацію щодо трафіку (кількість активних абонентів, типи трафіку, швидкість передавання).

OpenCellID. Найбільша відкрита база даних, що містить інформацію про мобільні вежі по всьому світу, включаючи координати веж, MCC (Mobile Country Code), MNC (Mobile Network Code), LAC (Location Area Code), і CellID.

Teralytics Mobility Data збираються від мобільних операторів та ретельно анонімізуються й агрегуються. Ці дані відображають маршрути пересування користувачів, включаючи часові мітки, які фіксують моменти виходу і прибуття, а також пункти відправлення та призначення.



Агрегація даних для навчання

Кількість активних абонентів

Кількість користувачів, які одночасно генерують трафік. Зростання цього показника збільшує навантаження, оскільки ресурси мережі розподіляються між більшою кількістю абонентів.

Середня швидкість передачі (Data Rate)

Показує інтенсивність використання пропускної здатності каналу. Високий Data Rate свідчить про значне навантаження на мережу.

Середній відсоток втрат пакетів (Packet Loss)

Інформує про якість каналу зв'язку. Високі втрати пакетів зазвичай пов'язані з перевантаженням або низькою якістю сигналу.

Середнє завантаження базової станції

Відображає поточне використання потужностей базової станції. При завантаженні близько 100% існує ризик перевантаження.

Час доби або день тижня

Враховує добові та тижневі патерни навантаження, наприклад, ранкові та вечірні піки чи денні провали.

Тип трафіку

Тип сервісу, закодований у вигляді one-hot векторів. Наприклад, голосовий зв'язок, потокове відео чи передавання файлів, кожен з яких має свої вимоги до мережі.

Формуючи ці шість ознак, отримуємо вектор:


$$x(t) = [x_1(t), x_2(t), x_3(t), x_4(t), x_5(t), x_6(t)],$$

Розподілення даних


Тренувальна вибірка (train set)




Валідаційна (validation set)



Тестова (test set)



Нормалізовані дані за допомогою MinMaxScaler



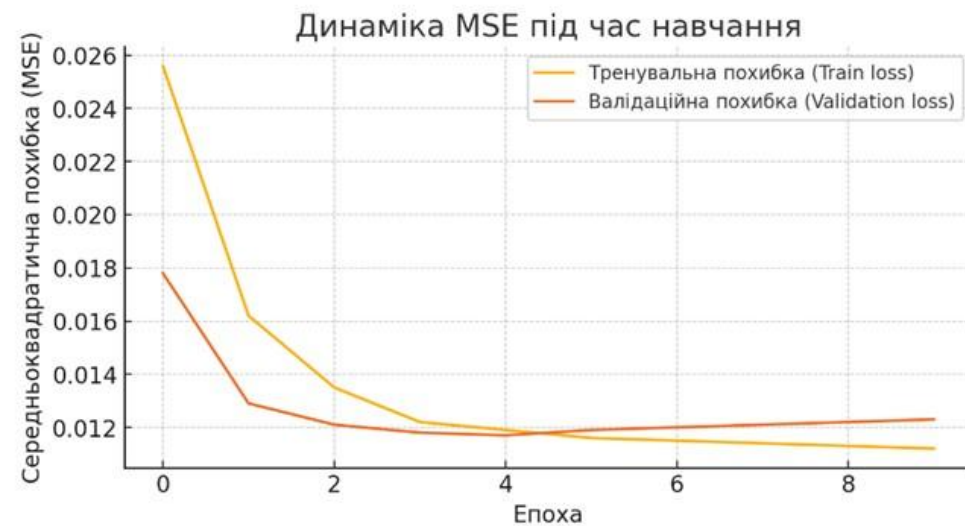
Навчання моделі

Гіперпараметри

```
epochs=50  
batch_size = 32  
early_stopping = 5
```

Параметри віконного метода

Вікно довжиною 5 хвилин.
2500 послідовностей.



На графіку видно, що на початку train loss і val loss досить високі, але швидко знижуються. Приблизно з 4–5-ї епохи покращення відбуваються повільніше, поки механізм ранньої зупинки не перериває процес (у цьому випадку — після 5-ї епохи).

Оцінка на тестовому наборі

Механізм перевірки:
Завантаження найкращих ваг.
Віконний підхід на тесті.
Передбачення.
Зворотне масштабування.



$$MSE = \frac{1}{N} \sum_{i=1}^n (\hat{y}_i - y_i)^2$$

MSE

$$MSE = \frac{1}{N} \sum_{i=1}^n |\hat{y}_i - y_i|^2$$

MAE

$$MSE = \frac{1}{N} \sum_{i=1}^n \frac{y_i - \hat{y}_i}{y_i}$$

MAPE

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - |y|)^2}$$

R^2 (коефіцієнт детермінації)

Результати перевірки на тестових даних


MSE ≈ 0.0105

MAE $\approx 2.35\%$

MAPE $\approx 7.80\%$

$R^2 \approx 0.91$

Порівняння реального та передбаченого завантаження (прикладові дані)



Переваги створеної моделі



Висновки

Проведений аналіз підтвердив, що інтелектуальні системи здатні значно підвищити ефективність роботи сучасних мереж, забезпечуючи прогнозування навантаження, адаптивний розподіл ресурсів для підвищення якості обслуговування. Перспективи досліджень включають адаптацію моделей на основі реальних даних операторів, інтеграцію системи із хмарними платформами, а також вивчення новітніх архітектур нейромереж для роботи в умовах високої щільності трафіку.

