ЗМІСТ

ВСТУП……..4
РОЗДІЛ 1. ТЕОРЕТИЧНІ ЗАСАДИ ЗАСТОСУВАННЯ ТЕХНОЛОГІЙ ШТУЧНОГО ІНТЕЛЕКТУ В ОПТИМІЗАЦІЙНИХ ЗАДАЧАХ……7
1.1. Поняття, сутність та класифікація технологій штучного інтелекту…..7
1.2. Оптимізація як напрям підвищення ефективності управлінських і технічних процесів……11
1.3. Сучасні моделі та алгоритми оптимізації (генетичні алгоритми, нейронні мережі, машинне навчання)……13
1.4. Огляд світового та вітчизняного досвіду застосування ШІ для оптимізації……..…14
РОЗДІЛ 2. МЕТОДИКА ДОСЛІДЖЕННЯ ТА АНАЛІЗ ІСНУЮЧИХ РІШЕНЬ……..……18
2.1. Характеристика об’єкта (сфери, процесу, організації) оптимізації….18
2.2. Аналіз наявних інструментів та технологій ШІ, що використовуються у вибраній предметній області……19
2.3. Обґрунтування вибору моделі ШІ для дослідження……23
2.4. Методика оцінювання ефективності (метрики, KPI, порівняльний аналіз)…….……26
2.5. Визначення проблем та недоліків існуючих рішень……29
РОЗДІЛ 3. РОЗРОБЛЕННЯ ТА ОЦІНКА ЕФЕКТИВНОСТІ МОДЕЛІ ШІ ДЛЯ ОПТИМІЗАЦІЇ……34
3.1. Проєктування моделі або алгоритму штучного інтелекту……...34
3.2. Реалізація моделі (інструменти, середовище, дані)……..40
3.3. Проведення експериментів та тестування……42
3.4. Оцінка ефективності запропонованої моделі (порівняння з альтернативами)……47
3.5. Практичні рекомендації щодо впровадження та масштабування…...50
ВИСНОВКИ……...55
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ…..……59

АНОТАЦІЯ

Магістерська робота зосереджується на вивченні того, наскільки ефективною є технологія штучного інтелекту для покращення управління, виробництва та конструювання процесів. Було зроблено дослідження штучного інтелекту, новітніх методів оптимізації та аналізу наявних технологій, зразків та комп'ютерних пристроїв. На основі досліджень було створено зразок оптимізації, який допомагає підвищити продуктивність процесів і зменшити витрати на ресурси. Справжня цінність праці полягає в тому, щоб ввести обраний зразок у різні установи пересилання, які допоможуть покращити ефективність прийняття рішень. і автоматизацію щоденних операцій.

ВСТУП

Актуальність дослідження: Швидкий прогрес у сфері цифрових технологій у XXI столітті зумовив появу нових інструментів, здатних суттєво трансформувати комунікаційні, управлінські, виробничі та освітні процеси. Однією з ключових складових сучасного розвитку є технології штучного інтелекту, що стрімко знаходять застосування в різних галузях. Вони охоплюють фінансовий сектор, маркетинг, медицину, державне управління та освіту, значно впливаючи на їхнє функціонування та розвиток.

Актуальність цього дослідження зумовлена необхідністю наукового розуміння можливостей і ризиків використання штучного інтелекту. Важливо з'ясувати, за яких умов ці технології можуть реально поліпшити процеси, збільшити продуктивність та покращити якість рішень. З огляду на глобальну цифровізацію особливої важливості набуває дослідження ефективності використання ШІ в тих сферах, де традиційні підходи вже не забезпечують необхідної швидкості або точності операцій.

В сучасних дослідженнях багато вітчизняних і зарубіжних науковців приділяли увагу питанню інтеграції технологій штучного інтелекту в телекомунікаційні системи та процеси оптимізації. Фахівці з IEEE та ACM зробили важливий внесок у вивчення застосування машинного навчання та нейронних мереж у мережах нового покоління. Особливу увагу було приділено вирішенню завдань моніторингу, прогнозування та автоматизації управління [1; 2].

Важливі практичні результати представлені в індустріальних звітах Comarch та KDDI Research, де досліджено перші успішні впровадження AIOps-систем та автоматизованих платформ управління 5G-мережами [3; 20]. Серед теоретичної бази особливу увагу заслуговують праці з аналізу етичних, правових та операційних аспектів ШІ, які були розроблені Coeckelbergh, Schmidt & Cohen, а також експертами Європейського парламенту, що окреслили необхідність регулювання автономних систем і визначення їх відповідальності [7; 13; 14].

В Україні багато науковців, як-от М. Єфремов, О. Баранов, І. Іваськів, Г. Веселовська, вивчають розвиток штучного інтелекту. У своїх роботах вони розглядають, як створювати такі системи, які в них алгоритми та як їх можна застосовувати в техніці. [23; 25; 26; 29; 31]. У роботах Скіцька, Осадчого та Коломієць окреслені ризики застосування ШІ, питання кібербезпеки, а також специфіка інтеграції інтелектуальних технологій у складні цифрові та освітні середовища [33; 40; 43]. Проведені дослідження забезпечують глибоке розуміння можливостей штучного інтелекту для покращення телекомунікацій, що є основою для розробки інтелектуальної моделі, представленої в цій роботі.

Мета роботи: Мета дослідження полягає у вивченні можливостей штучного інтелекту для задач оптимізації та розробці моделі або алгоритму, що покращує цільовий процес.

Для здобуття поставленної мети, потрібно виконати поставленні завдання:

1. Вивчимо теоретичні засади штучного інтелекту та їх застосування для задач оптимізації.

2. Дослідити сучасні алгоритми покращення, такі як генетичні алгоритми, машинне навчання та нейронні мережі.

3. Провести огляд наявних рішень та інструментів штучного інтелекту у визначеній галузі.

4. Пояснити вибір моделі штучного інтелекту для дослідження.

5. Розробити та реалізувати модель оптимізації на основі технологій ШІ.

6. Для оцінки дієвості запропонованого рішення, варто провести моделювання, експеримент або тестування.

7. Розробити практичні рекомендації щодо впровадження моделі в реальні процеси.

Об’єктом дослідження є процес оптимізації діяльності, що здійснюється за допомогою технологій штучного інтелекту.

Предметом дослідження є технології штучного інтелекту та їхній вплив на те, як добре оптимізуються певні процеси.

Для досягнення поставленої мети застосовано ряд дослідницьких методів, зокрема:

- Теоретична частина (аналіз, узагальнення та систематизація наукових джерел з питань штучного інтелекту)

- емпіричні (спостереження, експеримент, моделювання, аналіз ефективності використання ШІ у практичних кейсах);

- математично-статистичні методи обробки даних (кореляційний аналіз, порівняльний аналіз, оцінка продуктивності алгоритмів).

Результати цього дослідження можуть бути використані організаціями, освітніми установами, підприємствами та державними органами для поліпшення їхньої роботи. Зокрема, це стосується раціонального використання ресурсів, кращого аналізу даних та автоматизації звичайних процесів. Запропоновані рекомендації можуть допомогти у впровадженні штучного інтелекту на практиці та розробці стратегій цифрової трансформації.

Наукова цінність праці полягає в обґрунтуванні з позицій теорії та практики доцільності застосування штучного інтелекту з метою покращення згаданих процесів. У роботі конкретизовано, що саме слід розуміти під оптимізацією в контексті цифрової трансформації, а також визначено основні чинники, що впливають на результативність впровадження алгоритмів ШІ.

У дослідженні запропоновано новий спосіб оцінки того, наскільки добре працюють технології штучного інтелекту. Він поєднує в собі вимірювання в цифрах і якісні оцінки. Також розроблено поради щодо того, як використовувати ШІ для покращення продуктивності, точності та здатності пристосовуватися до змін у певній галузі. Результати розширюють наше розуміння ролі інтелектуальних систем в сучасних моделях управління та аналізу, а також дають основу для створення кращих стратегій цифрових змін.

Робота має таку структуру: вступ, три розділи основної частини, висновки та перелік літератури, що включає 47 найменувань. Загальний обсяг становить 64 сторінки.

РОЗДІЛ 1. ТЕОРЕТИЧНІ ЗАСАДИ ЗАСТОСУВАННЯ ТЕХНОЛОГІЙ ШТУЧНОГО ІНТЕЛЕКТУ В ОПТИМІЗАЦІЙНИХ ЗАДАЧАХ

1.1. Поняття, сутність та класифікація технологій штучного інтелекту

В останні десятиліття штучний інтелект швидко розвивається. Складні електронні системи обробляють великі масиви даних та допомагають приймати рішення в багатьох сферах. Їх використовують в юриспруденції, медицині, техніці, геології, транспорті, освіті та промисловості для планування, моделювання та управління. Це показує, як швидко поширюються технології штучного інтелекту, та як змінюються підходи до роботи з інформацією, прийняття рішень і спілкування в цифровому світі.

Перш ніж перейти до суті категорії «штучний інтелект», важливо розглянути базове поняття «інтелект». Інтелект можна визначити як здатність людини розв'язувати теоретичні та практичні завдання, отримуючи інформацію ззовні, перевіряючи її, трансформуючи у знання, впорядковуючи та застосовуючи у своїй діяльності. У цьому процесі важливі накопичення досвіду, його осмислення, здатність до навчання та адаптації до змін. Ці характеристики є основою для сучасних підходів до створення систем штучного інтелекту [30].

На основі узагальнення різних наукових підходів визначено ключові характеристики, властиві як природному, так і штучному інтелекту. Серед них — здатність до навчання, узагальнення отриманих знань, накопичення досвіду (як знань, так і навичок), адаптація до нових умов та вміння діяти в умовах невизначеності, коли немає чітких алгоритмів для вирішення задач. Саме завдяки цим рисам «інтелектуальні» системи розглядаються як універсальні механізми для вирішення широкого спектра проблем, зокрема й тих, що складно формалізувати. Водночас рівень інтелекту будь-якої системи — незалежно від того, чи це людський чи штучний інтелект — залишається без єдиного загальноприйнятого критерію оцінювання. Його можуть визначати експерти,

результати спеціальних тестів або здатність системи ефективно виконувати складні когнітивні завдання.

Розв’язання будь-якої задачі передбачає побудову певної послідовності дій - алгоритму, який відображає перехід від відомих умов до шуканого результату. У випадку штучного інтелекту йдеться про автоматизовану, формально описану послідовність операцій із даними, що моделює логічні кроки, які в аналогічній ситуації здійснювала б людина [25]. На цій основі штучний інтелект часто визначають як сукупність методів і засобів цілеспрямованої обробки інформації (знань), що реалізуються технічними системами, здатними навчатися, адаптуватися та вдосконалювати свою поведінку на підставі накопиченого досвіду розв’язування інтелектуальних задач [28].

Водночас у науковій літературі пропонується й інше, більш прикладне визначення: штучний інтелект розглядають як напрям інформатики, завданням якого є створення апаратно-програмних засобів, що дозволяють користувачеві без спеціальних знань у програмуванні формулювати свої інтелектуальні задачі й отримувати від електронної обчислювальної системи результати, співмірні з професійною людською діяльністю [13, с. 32-34]. Зіставлення цих підходів показує, що, попри відмінність акцентів (філософський, технічний, прикладний), їх об’єднує спільна ідея: кінцевою метою є створення систем, здатних розв’язувати складні інтелектуальні завдання та вдосконалюватися в процесі їх виконання [21, с. 46-51].

Логічним продовженням поняття штучного інтелекту є категорія «система штучного інтелекту». Під нею зазвичай розуміють комплекс інформаційних, програмно-алгоритмічних та апаратних засобів, результати функціонування яких є подібними до результатів людського мислення й професійного судження у певній предметній сфері [28]. Такі системи мають працювати з урахуванням контексту, використовувати знання про предметну область, забезпечувати логічні висновки, формувати рекомендації, розпізнавати образи, підтримувати прийняття рішень і, за можливості, взаємодіяти з людиною природною мовою [21, с. 46-51]. В ідеалі поведінка системи має бути настільки наближена до

людської, що в конкретній ситуації її рішення неможливо відрізнити від рішень фахівця-людини.

Вивчення й конструювання систем штучного інтелекту охоплює кілька основних напрямів досліджень. По-перше, це моделювання на комп'ютерах окремих інтелектуальних функцій - наприклад, розв'язання ігрових задач, автоматичне доведення теорем, синтез програм і алгоритмів [21]. По-друге, так звана зовнішня інтелектуалізація, коли фахівець, взаємодіючи зі складною інформаційною системою, отримує доступ до баз знань, може розв'язувати проєктні, планові та управлінські задачі, аналізувати дані, розпізнавати й діагностувати стани складних об'єктів, формулювати гіпотези та логічні висновки [16, с. 167-170]. По-третє, внутрішня інтелектуалізація пов'язана з побудовою обчислювальних систем нового покоління, орієнтованих на роботу зі знаннями, а не лише з даними. І, нарешті, четвертий напрям стосується створення інтелектуальних роботів, які на основі інформації від сенсорів здатні орієнтуватися у зовнішньому середовищі, навчатися та автономно виконувати складні дії.

Сучасна література з права та інформаційних технологій акцентує увагу й на підходах до побудови штучного інтелекту. Зазвичай виокремлюють два принципово різні підходи: алгоритмічний та підхід, заснований на самоосвіті системи. В алгоритмічному підході всі правила, за якими діє система, задаються розробником: модель є прозорою й передбачуваною, але погано пристосовується до нових, неочікуваних ситуацій. У разі самоосвіти (машинного навчання) створюють загальний алгоритм, який, спираючись на великі масиви даних, самостійно «виводить» закономірності, правила та стратегії поведінки, часто недоступні для прямого формального опису людиною [32]. Перевагою першого підходу є контрольованість і відсутність «несподіваних» дій системи поза межами закладеної логіки, тоді як другий забезпечує гнучкість та здатність до узагальнення, але створює додаткові виклики з погляду прозорості, безпеки й юридичної відповідальності [29, с. 123-136].

У дослідженнях також прийнято розрізняти слабкий і сильний штучний інтелект. Під слабким (або прикладним) штучним інтелектом мають на увазі

системи, що розв’язують обмежене коло вузькоспеціалізованих задач - наприклад, голосові помічники, сервіси розпізнавання мовлення, програмні комплекси для комп’ютерного зору, чат-боти чи рекомендаційні системи [5]. Такі рішення вже широко впроваджені в повсякденне життя, але не здатні «мислити» універсально. Натомість концепція сильного штучного інтелекту передбачає створення системи, яка могла б виконувати будь-яке інтелектуальне завдання на рівні людини або вище; на сьогодні це радше теоретична модель, ніж практично реалізований проєкт, хоча діяльність провідних технологічних компаній і наукових центрів наближає її обговорення до реальної площини [8].

Класичним орієнтиром для оцінки «розумності» поведінки машини залишається тест, запропонований А. Тюрінгом, суть якого полягає в тому, чи зможе людина-експерт за результатами спілкування розпізнати, коли вона взаємодіє з комп’ютером, а коли - з іншою людиною [14; 28]. Якщо суддя не здатен надійно відрізнити відповіді машини від відповідей людини, то вважається, що система демонструє достатньо високий рівень інтелектуальної поведінки. Хоча сам тест давно піддається критиці, він і надалі залишається важливим концептуальним орієнтиром для дискусій про межі можливостей ШІ [3; 31, с. 183-200].

Узагальнюючи, штучний інтелект можна розглядати як складову частину інформатики й міждисциплінарну галузь знань, що створює наукові та технічні передумови для розв’язання за допомогою автоматизованих систем тих задач, які раніше були пов’язані переважно з людськими когнітивними здібностями. Ідея ШІ полягає в моделюванні високорівневих психічних процесів - мислення, судження, мовлення, розпізнавання образів, навчання, творчості - та в забезпеченні здатності технічних систем аналізувати вхідну інформацію, враховувати попередній досвід і обирати найбільш раціональні варіанти рішень у складних ситуаціях. Саме таке розуміння відкриває можливості для комплексного правового, етичного та педагогічного осмислення ролі штучного інтелекту в сучасному суспільстві.

1.2. Оптимізація як напрям підвищення ефективності управлінських і технічних процесів

Оптимізація розглядається як один із ключових інструментів підвищення результативності управлінських та технічних процесів у сучасних організаціях. У контексті переходу до цифрової економіки оптимізаційні підходи охоплюють широкий спектр рішень: від автоматизації й алгоритмізації операцій до вдосконалення моделей прийняття управлінських рішень, оптимального розподілу ресурсів та підвищення продуктивності інформаційних систем. Управлінська оптимізація передбачає раціоналізацію структур, скорочення надлишкових процедур, зменшення часових витрат на комунікацію, оптимальне делегування та підвищення якості контролю [36].

Технічна оптимізація, у свою чергу, охоплює не лише вдосконалення алгоритмів обробки даних, але й комплексне оновлення програмно-апаратних комплексів, удосконалення структур зберігання інформації, підвищення стабільності технічних рішень і впровадження сучасних інструментів автоматизації. Сучасні організації покладаються на високоточні алгоритми аналізу великих масивів даних, які здатні забезпечувати швидку фільтрацію інформації, виявлення закономірностей та побудову релевантних прогнозів. Паралельно з цим модернізація апаратного забезпечення включає впровадження більш продуктивних серверів, систем паралельних обчислень, хмарних платформ, мережевих інфраструктур нового покоління та інтеграцію рішень із високою відмовостійкістю. Підвищення надійності технічних систем - ключовий елемент оптимізації, що передбачає зменшення ризику відмов, захист від несанкціонованого доступу, стабільність функціонування в умовах великого навантаження, а також формування резервної інфраструктури для критично важливих процесів.

Важливою складовою технічної оптимізації є створення механізмів автоматизованої підтримки складних виробничих, адміністративних і технологічних процесів. Це передбачає впровадження систем спостереження в режимі реального часу, інтелектуальних роботизованих комплексів,

автоматизованих систем управління, рішень на основі машинного навчання та моделей, що дозволяють покращити ефективність. Завдяки цьому організації можуть оперативно реагувати на зміну параметрів середовища, прогнозувати можливі відхилення та своєчасно коригувати роботу систем. Ці аспекти разом складають основу для успішної роботи компаній в умовах, коли зовнішнє середовище швидко змінюється. У таких ситуаціях здатність швидко приймати рішення, пристосовуватися та рівень розвитку технологій визначають, наскільки компанія може конкурувати. [24].

Впровадження штучного інтелекту, цифрових платформ і аналітичних систем робить управлінську та технічну оптимізацію особливо важливою. Такі інструменти потребують високої адаптивності, здатності до самооновлення, масштабованості та інтеграційної гнучкості. Оптимізаційні підходи дозволяють організаціям не лише зменшувати операційні витрати, а й забезпечувати стратегічний розвиток, підвищувати ефективність бізнес-процесів, покращувати точність прогнозування попиту, фінансових показників та поведінкових моделей користувачів. Поєднання алгоритмів та штучного інтелекту допомагає швидше виконувати звичайні завдання, автоматизувати управління, зменшити вплив людських помилок та покращити якість послуг. У результаті підприємства отримують змогу ефективніше управляти ресурсами, покращувати взаємодію з клієнтами та формувати нові конкурентні переваги у цифровій економіці.

Важливо, що оптимізація більше не розглядається як одноразовий етап, а стає постійною функцією системи управління, інтегрованою в цикли планування, контролю та аналізу.

Отже, методи оптимізації є основою для збільшення конкурентоздатності та стабільності організацій в умовах цифрової ери.

1.3. Сучасні моделі та алгоритми оптимізації (генетичні алгоритми, нейронні мережі, машинне навчання)

Сучасні моделі та алгоритми оптимізації становлять ядро розвитку інтелектуальних систем, оскільки саме вони забезпечують здатність машин знаходити найкращі рішення у складних, багатофакторних умовах. Одним із найважливіших напрямів є генетичні алгоритми, що моделюють природні еволюційні процеси. Їхня основна ідея полягає у створенні популяції можливих рішень, які під дією операторів мутації, селекції та кросинговеру поступово еволюціонують у напрямі підвищення якості. Генетичні алгоритми здатні долати локальні мінімуми та працювати у просторах великої розмірності, де традиційні математичні методи виявляються малоефективними. Саме тому вони широко застосовуються у задачах маршрутизації, оптимізації розкладів, логістичного планування, технічного проєктування та моделювання складних технічних систем. Їхня універсальність полягає в тому, що генетичні алгоритми не потребують аналітичної форми цільової функції - достатньо лише можливості оцінки придатності кожного рішення [25, с. 132-135].

Другим ключовим напрямом розвитку алгоритмів оптимізації є штучні нейронні мережі, здатні імітувати функціонування людського мозку шляхом обробки інформації через багаторівневу систему взаємопов’язаних нейронів. Їхня особливість полягає у здатності навчатися на основі прикладів та виявляти приховані закономірності, що недоступні традиційним статистичним методам. Нейронні мережі не лише забезпечують точне прогнозування й класифікацію, але й ефективно інтегруються в оптимізаційні моделі: вони можуть формувати адаптивні правила прийняття рішень, автоматично покращувати власну структуру та налаштовувати параметри без втручання людини. Наприклад, у промисловому виробництві нейронні мережі застосовуються для оптимізації технологічних режимів, у транспортній галузі для маршрутизації руху, а в економічному управлінні для моделювання поведінкових патернів ринку та прогнозування ризиків. Важливо, що нейронні мережі здатні працювати у реальному часі, що робить їх критично важливими для систем моніторингу, автоматичного керування та роботизованих комплексів [33].

Третім сучасним напрямом є машинне навчання, яке об’єднує широкий спектр алгоритмів, що дозволяють системам самостійно покращувати свою

роботу на основі накопиченого досвіду. Методи машинного навчання охоплюють як контрольоване, так і неконтрольоване навчання, методи підкріплення, ансамблеві моделі та глибоке навчання. Вони дають змогу поліпшити використання ресурсів, зробити точнішими прогнозні моделі, автоматизувати складні процеси ухвалення рішень та адаптуватися до змін у навколишньому середовищі. Машинне навчання стало важливим компонентом сучасних інформаційних систем. Воно дозволяє швидко аналізувати великі обсяги даних, створювати складні моделі та ідентифікувати залежності, які важко знайти за допомогою звичайних підходів. Зокрема, воно використовується у фінансовій сфері для оптимізації інвестиційних портфелів, у медицині для класифікації станів пацієнтів і прогнозування ризиків, у логістиці для оптимізації маршрутів і складування, а в освіті для персоналізації навчальних траєкторій [23].

Отже, сучасні алгоритми оптимізації - генетичні алгоритми, нейронні мережі та методи машинного навчання - формують інтегровану інтелектуальну основу для побудови ефективних, гнучких та адаптивних систем управління. Вони здатні поліпшити ухвалення обґрунтованих рішень, скоротити видатки на діяльність, вдосконалити процеси та сприяти розвитку інновацій у різних галузях.

1.4. Огляд світового та вітчизняного досвіду застосування ШІ для оптимізації

Використання технологій штучного інтелекту у світі стрімко трансформує підходи до управління, виробництва, логістики, освіти, медицини та державного адміністрування. У країнах з високим рівнем цифрової зрілості ШІ вже став ключовим інструментом оптимізації, оскільки дає змогу не лише підвищувати ефективність процесів, але й забезпечувати їхню адаптивність, безперервне вдосконалення та прогнозування можливих ризиків. На глобальному рівні компанії *Amazon, Google, Siemens, Microsoft*, державні цифрові системи Естонії, Сінгапуру чи Південної Кореї активно інтегрують інтелектуальні алгоритми для

оптимізації логістики, обробки даних, управління інфраструктурою, кібербезпеки та надання державних послуг. Такі системи можуть обробляти великі обсяги даних, знаходити в них певні тенденції, розробляти моделі майбутніх подій та автоматично адаптуватися до змін у навколишньому середовищі. Саме тому західні експерти розглядають ШІ як фундамент нової промислової та управлінської парадигми, що визначає конкурентоспроможність держав і корпорацій у цифрову епоху [8].

У промисловості штучний інтелект використовується для оптимізації виробничих ліній, контролю якості, енергоменеджменту, виявлення технічних збоїв і прогнозування відмов обладнання. Наприклад, компанія *Siemens* інтегрує AI-моделі для створення «розумних заводів», де алгоритми прогнозують споживання енергії, налаштовують технологічні параметри й мінімізують простої. В автомобільній та аерокосмічній галузях моделювання поведінки роботизованих систем здійснюється на основі складних нейронних моделей, що підвищують точність виробництва та безпеку операцій [3]. Аналогічні підходи застосовуються в Amazon, де ШІ визначає оптимальні маршрути доставки, формує розподіл товарів на складах, прогнозує рівень попиту в реальному часі та автоматизує управління персоналом. Завдяки цьому Amazon показує один із найвищих у світі індексів логістичної ефективності.

У транспортній сфері одним із найпомітніших кейсів стало впровадження автономного автомобільного керування, де ШІ класифікується як «водій» за законодавством США. Це означає офіційне визнання здатності алгоритмів самостійно приймати рішення в умовах транспортного середовища, що підтверджено на нормативному рівні [5]. Системи штучного інтелекту використовуються в інфраструктурному управлінні для оптимізації світлофорних циклів, прогнозування заторів, адаптивної маршрутизації та контролю за безпекою руху. У Китаї, наприклад, ШІ визначає транспортні навантаження, регулює роботу інтелектуальних доріг і здійснює моніторинг якості покриття на основі супутникових та сенсорних даних [10].

В освіті застосування ШІ зумовлює істотну трансформацію навчального процесу за рахунок персоналізації навчальних траєкторій, автоматичного аналізу

успішності здобувачів, формування адаптивного контенту та підтримки викладачів у плануванні занять. Сучасні дослідження підкреслюють, що штучний інтелект здатний підвищувати мотивацію навчання, пришвидшувати засвоєння матеріалу та зменшувати навантаження на педагогів за рахунок автоматизації перевірок та аналітики [18]. Український досвід також активно розвивається: зокрема, ChatGPT, Midjourney, освітні платформи на базі машинного навчання інтегруються у викладання в університетах і професійних закладах, дозволяючи формувати індивідуальні програми навчання, виявляти прогалини у знаннях та пропонувати оптимальні освітні рішення [26].

В охороні здоров'я ШІ використовується для діагностики, аналізу медичних зображень, персоналізації лікування та прогнозування ризиків. Алгоритми здатні розпізнавати патології з точністю, що інколи перевищує можливості лікарів, а також формувати оптимальні маршрути лікування на основі аналізу великих медичних баз. Такі технології демонструють високу ефективність у кардіології, онкології, нейрохірургії та телемедицині. Значний прорив у галузі ШІ для медицини представлений у проектах Google Health, які довели високу результативність нейронних моделей у виявленні онкологічних захворювань на ранніх стадіях [3]. Україна також почала впроваджувати ШІ у медичну сферу: це стосується систем електронного здоров'я, алгоритмів аналізу великих медичних даних, систем підтримки клінічних рішень та автоматизації обробки записів.

У державному управлінні ШІ дозволяє підвищувати швидкість і прозорість управлінських рішень, автоматизувати документообіг, забезпечувати електронну взаємодію громадян з державою й аналізувати великі масиви статистичних та соціальних даних. На світовому рівні взірцем є Естонія, де впроваджено понад 80 систем, що працюють із використанням алгоритмів машинного навчання: від прогнозування ризиків безробіття до цифрових судових систем. Європейський парламент офіційно визначив необхідність розробки правових правил для робототехніки та ШІ, що також підтверджує визнання цих технологій як стратегічно важливих [7]. В Україні найпомітнішими

є системи «Дія», е-урядування, автоматизовані сервіси оподаткування, а також проєкти прогнозної аналітики в безпековому секторі.

Незважаючи на помітний прогрес, впровадження штучного інтелекту стикається з певними труднощами. Однією з найбільших є недостатність високоякісних даних, адже саме від їх повноти залежить точність прийняття рішень. Важливими також є питання етичного характеру: конфіденційність, упередженість алгоритмів, небезпека надмірної автоматизації, ризики заміщення робочих місць і відповідальність за рішення, які ухвалює машина [31]. Слабкий розвиток цифрової інфраструктури, брак кваліфікованих кадрів, значні фінансові вкладення в розгортання та модернізацію систем, а також недосконаліть правового регулювання відповідальності штучного інтелекту в ключових галузях залишаються важливими проблемами [29]. В Україні додатковим обмеженням є воєнний стан, що ускладнює масштабні проєкти цифровізації, але водночас стимулює створення систем, здатних автоматично аналізувати загрози, підтримувати рішення командування, працювати в реальному часі та підвищувати ефективність оборонних операцій.

Отже, світовий і український досвід показує, що штучний інтелект стає ключовою рушійною силою оптимізації практично в усіх галузях. Його інтеграція забезпечує суттєве підвищення ефективності, прискорення процесів, удосконалення рішень і формування нових моделей управління. Проте для повноцінної реалізації його потенціалу необхідно вирішити комплекс етичних, правових, технічних і соціальних проблем, які наразі стримують повномасштабне використання цих технологій як у світі, так і в Україні.

РОЗДІЛ 2. МЕТОДИКА ДОСЛІДЖЕННЯ ТА АНАЛІЗ ІСНУЮЧИХ РІШЕНЬ

2.1. Характеристика об’єкта (сфери, процесу, організації) оптимізації

Об’єктом цього дослідження є процеси управління, моніторингу та вдосконалення телекомунікаційних мереж. У цій сфері штучний інтелект використовується для автоматизації операцій, поліпшення точності рішень і забезпечення стабільної роботи інфраструктури. Саме телекомунікаційна сфера розглядається у сучасній науковій літературі як одна з найбільш технологічно насичених, адже обсяг даних, що генерується мережею, зростає експоненційно, а складність інфраструктури ускладнює підтримання її безперебійної роботи без залучення інтелектуальних систем [1, с. 3-4]; [3, с. 2].

Особливістю телекомунікаційних систем нового покоління (4G/5G) є їхня висока залежність від динамічних змішаних навантажень, гетерогенних джерел даних та багаторівневих мережевих структур, у яких традиційні алгоритми управління вже не забезпечують необхідної продуктивності. Згідно з дослідженнями IEEE, інтелектуальні алгоритми машинного навчання можуть швидко реагувати на зміни в трафіку та покращувати використання ресурсів без втручання людини [2, с. 5-6].

Додатково, поява концепції «координаційної ери» телекомунікацій, у межах якої мережі стають самокерованими та адаптивними, актуалізує потребу у розробці ефективних систем на основі ШІ, здатних оптимізувати процеси маршрутизації, балансування навантаження та прогнозування відмов обладнання [16, с. 2-3]. Це підтверджують і аналітичні звіти Comarch та Heavy Reading, які наголошують, що провайдери, які не інтегрують системи ШІ, не зможуть конкурувати у середовищі високої складності мережевих операцій [3, с. 1]; [10, с. 20].

Таким чином, об’єкт оптимізації в дипломному дослідженні - мережеві процеси телекомунікаційної інфраструктури, що потребують підвищення ефективності на основі застосування технологій штучного інтелекту.

2.2. Аналіз наявних інструментів та технологій ШІ, що використовуються у вибраній предметній області

Сучасний розвиток телекомунікаційних технологій супроводжується стрімким зростанням складності мережевих інфраструктур, кількості трафіку та потреби у високій точності прийняття рішень в реальному часі. У цьому контексті штучний інтелект стає ключовим інструментом цифрової трансформації телекомунікаційного сектору. Аналіз новітнього наукового доробку свідчить, що галузь інтегрує ШІ у широкому спектрі задач: від класифікації та маршрутизації трафіку до прогнозування мережевих збоїв, автоматизованого управління інцидентами, автономного балансування навантаження та створення систем самовідновлюваних мереж [10, с. 19-21].

Таблиця 2.1. - Порівняльна характеристика основних інструментів ШІ у телекомунікаціях

Інструмент ШІ	**Основні функції**	**Переваги**	**Недоліки**	**Приклади використання**
Машинне навчання	Виявлення аномалій, прогнозування навантажень	Швидке реагування, аналіз великих даних	Потреба у великій кількості якісних даних	Comarch 5G-monitoring
Глибинне навчання	Класифікація трафіку, прогноз відмов	Висока точність у складних системах	Складність інтерпретації	IEEE DL-based routing
AIOps	Автоматизація управління мережею	Скорочення MTTR на 30-70 %	Висока вартість впровадження	KDDI AI-assisted operation

Автономні агенти	Самобалансування мережі	Автономність, адаптивність	Етичні ризики	Системи самоорганізації трафіку
Predictive maintenance	Прогнозування технічних збоїв	Скорочення витрат на ремонт	Необхідність датчиків та IoT	Softengi AI-platform

Використані інструменти розв’язують як локальні технічні завдання, так і комплексні системні проблеми, пов’язані з оптимізацією, масштабуванням, захистом та якістю обслуговування (QoS). У структурованому вигляді спектр технологій ШІ у телеком-секторі можна поділити на шість ключових груп, кожна з яких має власні функціональні можливості, переваги та виклики.

Машинне навчання (ML) стало ядром сучасних систем моніторингу мереж, оскільки забезпечує здатність моделі автоматично розпізнавати закономірності у великих потоках телеметрії. Алгоритми ML успішно застосовуються для:

- аналізу QoS-параметрів у реальному часі та оцінювання стабільності мережі;
- виявлення пікових навантажень і визначення небезпечних трендів зростання трафіку;
- раннього прогнозування можливих збоїв на основі патернів поведінки обладнання;
- динамічної адаптації мережевих параметрів для уникнення перевантаження.

У звітах Comarch наголошується, що інтеграція supervised та unsupervised learning у 5G-monitoring скорочує середній час реагування мережевого оператора на інциденти на 40-60 % [3, с. 3]. Алгоритми без учителя дозволяють виявляти невідомі раніше аномалії, що є критичним у складних мережах із високою варіативністю параметрів.

IEEE-дослідження підтверджують, що нейронні мережі здатні забезпечити кращу точність класифікації трафіку та прогнозування затримок порівняно з класичними статистичними моделями, особливо в умовах нестабільних або змішаних навантажень [2, с. 11-13].

Глибинні нейронні мережі (Deep Learning, DL) стали базовим інструментом для вирішення найскладніших задач телекомунікаційної сфери. Їх основні сфери застосування охоплюють:

- прогнозування поведінки трафіку з точністю до мілісекунд, що є критичним для 5G/6G-мереж;
- виявлення складних аномалій, які неможливо розпізнати традиційними засобами;
- автоматичне балансування навантаження між базовими станціями або ядром мережі;
- прогнозування деградації обладнання та оптимізацію технічного обслуговування.

Як зазначено у джерелі [38, с. 4-6], нейронні алгоритми демонструють виняткову ефективність у середовищах з високою нелінійністю, шумами та складними кореляціями між параметрами. Саме такі умови є типовими для телекомунікаційних мереж, де трафік формується мільйонами незалежних джерел, а зовнішні чинники (час доби, події, погодні умови) суттєво впливають на роботу системи.

У працях [39, с. 35-44] підкреслено, що DNN дозволяють одночасно виконувати функції класифікації, регресії та розпізнавання аномалій, що робить їх універсальним інструментом для мережевих операторів.

AIOps - це інтеграція методів ШІ з інструментами управління мережевими операціями. Такі системи виконують:

- аналіз журналів подій (log-analysis) з використанням ML та NLP;
- автоматичну кореляцію інцидентів, що дозволяє встановлювати першопричину збою;
- генерацію сценаріїв реагування та їх автономне виконання;
- стратегічну оптимізацію конфігурацій мережі.

Застосування AIOps суттєво змінює традиційну модель управління мережею - від ручних рішень до автономної взаємодії систем без участі оператора. У дослідженнях Heavy Reading підкреслюється, що AIOps здатні

знизити MTTR (mean time to repair) на 30-70 % завдяки швидшому виявленню інцидентів і прогнозуванню повторюваних помилок [10, с. 20-22].

Особливо показовими є кейси японської компанії KDDI, де було впроваджено AI-assisted network operation system - першу комерційну систему автономного оперативного управління мережею. Її застосування дозволило оптимізувати трафік у реальному часі та знизити кількість критичних збоїв [20, с. 2-3].

Автономні агенти та роботизовані системи є перспективним напрямом у сфері самокерованих мереж. Їх розвиток ґрунтується на здатності систем самостійно навчатися, адаптуватися та змінювати свою поведінку.

Дослідження у галузі морфологічної еволюції роботів підтверджують ефективність підходів, де фізичний або програмний агент модифікує власні характеристики, реагуючи на зміну середовища [5, с. 1-3].

У телекомунікаціях автономні агенти застосовуються для:

- побудови маршруту трафіку у режимі реального часу;
- динамічного перерозподілу ресурсів між вузлами;
- локального вирішення інцидентів без централізованого управління.

Ці системи є фундаментом майбутніх мереж 6G, де автономність і самовідновлення будуть основними функціями інфраструктури.

Predictive maintenance - це один із найпопулярніших напрямів використання ШІ в телекомунікаціях. Його мета - передбачити момент можливої відмови обладнання задовго до того, як вона вплине на якість послуг.

Дослідження компанії Softengi показують, що застосування ШІ в системах predictive maintenance дозволяє знизити кількість критичних відмов на 25-33 %, суттєво скоротити витрати на технічне обслуговування та оптимізувати використання обладнання [12, с. 1-2].

Типові сценарії застосування включають:

- аналіз вібрацій і температурних показників обладнання;
- визначення аномальних патернів;
- прогнозування деградації модулів;
- оптимізацію розкладу технічного обслуговування.

Однією з актуальних проблем розвитку автономних мереж є правова відповідальність та етичні наслідки впровадження інтелектуальних рішень у критичну інфраструктуру.

У роботах [7, с. 209] акцентується увага на таких ризиках:

- невизначеність юридичного статусу автономних систем;
- неможливість повної інтерпретації рішень нейронних мереж;
- складність визначення відповідального суб'єкта у разі інциденту;
- ризики порушення конфіденційності даних.

Ці аспекти потребують урахування під час розробки моделей ШІ, їх валідації та впровадження в телекомунікаційні мережі.

Таблиця 2.2. - Ключові дослідження та технології, що впливають на розвиток ШІ в телекомунікаціях

Основні результати	**Значення для дослідження**
Підвищення точності прогнозування затримок за допомогою NN	Обґрунтування вибору DNN
Зменшення часу реагування оператора на 40-60 %	Доцільність ML у моніторингу
Успішний запуск автономної мережевої системи	Підтвердження ефективності AIOps
Скорочення кількості відмов на 25-33 %	Важливість predictive maintenance
Правові аспекти відповідальності ШІ	Безпекові та етичні фактори впровадження

Предметна область демонструє високий рівень зрілості технологій ШІ та їх широке застосування в телекомунікаціях. Проте ефективність конкретних рішень залежить від структури даних, архітектури мережі, рівня автоматизації операцій та готовності оператора до інтеграції інтелектуальних систем. Подальше удосконалення телекомунікаційних мереж пов'язане з розвитком автономних систем, прогнозною аналітикою, глибинним навчанням та AIOps-рішеннями, здатними забезпечити новий рівень продуктивності та стабільності інфраструктури.

2.3. Обґрунтування вибору моделі ШІ для дослідження

У межах даного дослідження обрано модель глибинної нейронної мережі (Deep Neural Network, DNN), що використовується для розв’язання двох ключових задач - прогнозування мережевого навантаження та виявлення аномалій у трафіку. Вибір саме цієї моделі зумовлений низкою технічних, наукових та практичних чинників, які підтверджуються сучасними дослідженнями та реальними впровадженнями у телекомунікаційній сфері. Нейронні мережі останніх поколінь продемонстрували здатність працювати з високовимірними даними, виявляти приховані закономірності у часових рядах, адаптуватися до мінливих умов та забезпечувати високу точність передбачення, що є критично важливим для телеком-операторів, які працюють із великими масивами інформації та прагнуть до автоматизації мережевих процесів.

Першою фундаментальною підставою для вибору DNN є висока адаптивність цієї моделі до складних нелінійних залежностей, характерних для телекомунікаційних систем. Оскільки мережеві дані містять шумові компоненти, нестаціонарні патерни, випадкові пікові навантаження, зміни конфігурацій та вплив зовнішніх чинників, традиційні аналітичні моделі не забезпечують належної гнучкості. Дослідження [38, с. 4-8] підкреслюють, що сучасні нейронні мережі здатні ефективно обробляти складні нелінійні кореляції, які не піддаються моделюванню класичними статистичними методами. Аналогічну думку висловлюють автори навчального посібника [39, с. 35-44], які наголошують, що DNN демонструють високу точність у задачах розпізнавання закономірностей у даних підвищеної складності та змінної структури. Це робить їх придатними для аналізу трафіку, що формується мільйонами користувачів одночасно та змінюється залежно від розташування, часу доби й інших умов функціонування мережі.

Другим важливим критерієм вибору є універсальність DNN, яка полягає у можливості одночасного застосування для вирішення прогнозних і класифікаційних задач. На відміну від класичних статистичних моделей, наприклад ARIMA чи SARIMA, що працюють переважно зі стаціонарними

часовими рядами, глибинні мережі дозволяють проводити глибокий контекстний аналіз даних. Зокрема, вони спроможні опрацьовувати коротко- та довгострокові залежності, виявляти приховані патерни аномальної поведінки та формувати прогнозні значення з урахуванням неочевидних взаємозв'язків між параметрами. Така універсальність створює можливість побудови єдиної моделі, яка одночасно виконує декілька критично важливих функцій: прогноз навантаження, виявлення ризиків перевантажень, моніторинг аномалій та оцінювання стабільності системи. Це надзвичайно важливо у 5G-мережах, де швидкість зміни параметрів суттєво перевищує можливості класичних алгоритмів.

Третім вагомим аргументом є масштабованість глибинних мереж та їх здатність ефективно обробляти великі обсяги даних, які генерують сучасні телекомунікаційні системи. За даними [1, с. 3], обсяги телеметрії у 5G-мережах зростають у геометричній прогресії, що ставить під загрозу ефективність класичних аналітичних підходів. Моделі DNN, у свою чергу, здатні працювати з терабайтами потокових даних, виконувати паралельні обчислення та швидко адаптуватися до нових типів вхідної інформації. Дослідження Comarch підтверджує, що алгоритми глибинного навчання забезпечують стабільність результатів навіть за умов максимального навантаження мережі та великої кількості вхідних параметрів [3, с. 2]. Це робить їх особливо ефективними у задачах оптимізації ресурсів, управління конфігураціями та виявлення прихованих закономірностей, що не підлягають традиційному аналітичному опису.

Ще одним підтвердженням доцільності вибору DNN є ефективність, продемонстрована у реальних впровадженнях провідних телекомунікаційних компаній та дослідницьких центрів. Так, у проектах KDDI Research використання глибинних моделей для автономного моніторингу мережі дозволило істотно скоротити час реагування на інциденти, підвищити якість обслуговування (QoS) та оптимізувати балансування навантаження [20, с. 2]. Подібні результати демонструють європейські телеоператори, які застосовують DNN для прогнозування перевантажень, своєчасного виявлення загроз та автоматичного перенаправлення трафіку з урахуванням стану мережі. Це

свідчить про високу практичну значущість моделі, її здатність до адаптації та реальну ефективність в умовах експлуатації критичної інфраструктури.

Отже, наш вибір моделі Deep Neural Network є цілком обґрунтованим як з теоретичної, так і з прикладної точки зору. DNN поєднує здатність аналізувати складні структури даних, виконувати класифікаційні та прогнозні завдання, працювати з великими масивами телеметрії та доводити свою ефективність у реальних телекомунікаційних системах. Враховуючи динамічний розвиток 5G-мереж та перехід до автономних мереж шостого покоління, застосування DNN є перспективним інструментом підвищення ефективності, точності й стабільності управління телекомунікаційною інфраструктурою.

2.4. Методика оцінювання ефективності (метрики, KPI, порівняльний аналіз)

Оцінка результативності впровадження штучного інтелекту в телекомунікаційні системи – це складний процес, що потребує одночасного аналізу точності моделей, якості мережі, змін в операційних процесах та економічної вигоди. Для отримання об’єктивної та багатовимірної картини застосовується система кількісних метрик, від алгоритмічних показників продуктивності до галузевих KPI, що характеризують стабільність та пропускну здатність мережі. Такий підхід відповідає рекомендаціям IEEE щодо багаторівневого аналізу продуктивності інтелектуальних систем у критичній інфраструктурі [2, с. 14-15].

До ключових інструментів оцінювання якості моделей передбачення та класифікації належать традиційні метрики машинного навчання, які дозволяють отримати кількісну оцінку похибок та рівня коректності рішень.

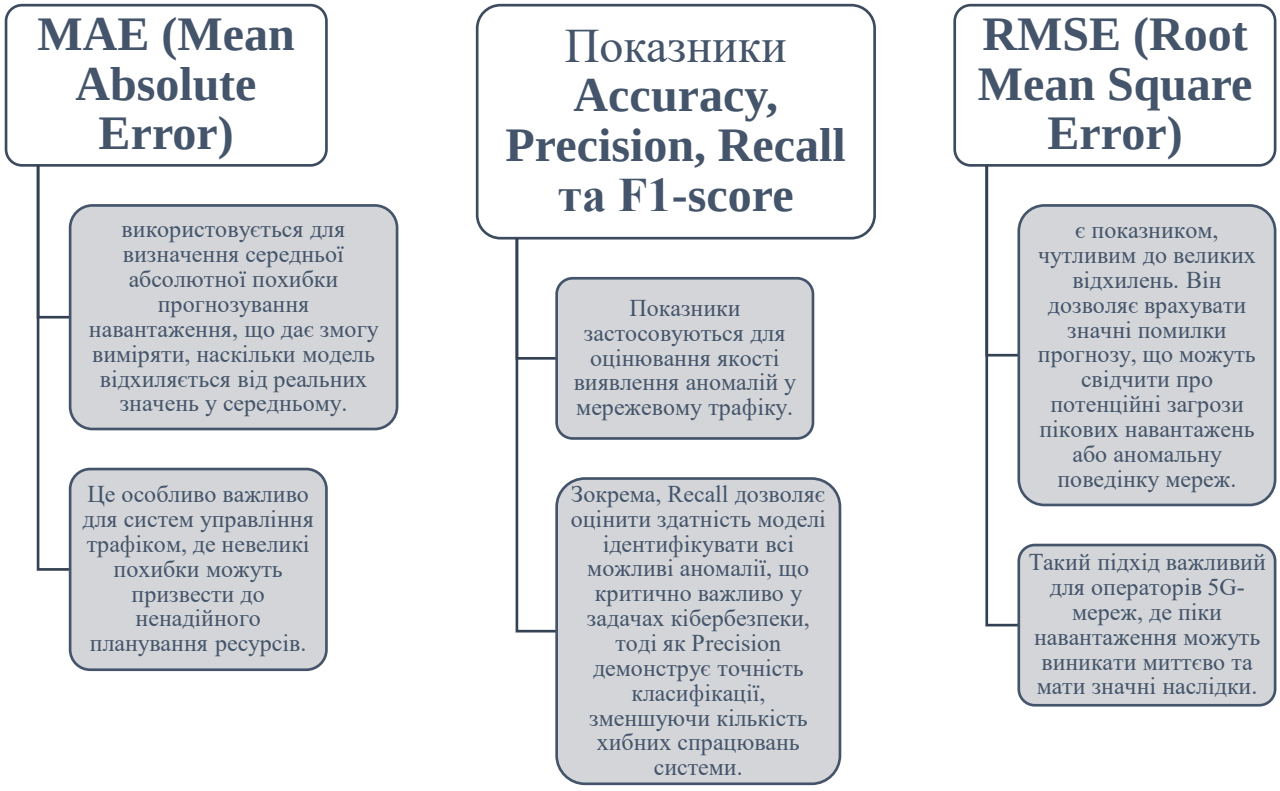


Рис. 2.1 - Метрики точності моделей ШІ

Згідно з рекомендаціями IEEE, комплексне застосування цих метрик забезпечує найповнішу характеристику продуктивності моделей, оскільки враховує як загальну точність, так і поведінку системи у складних або критичних сценаріях [2, с. 14-15].

Для оцінювання того, як саме моделі ШІ впливають на продуктивність телекомунікаційної мережі, використовують низку галузевих показників, що стосуються якості та надійності.

QoS (Quality of Service) включає такі параметри, як затримка (latency), джиттер (jitter), пропускна здатність та втрата пакетів. Кожен із цих показників напряму визначає якість користувацького досвіду (QoE) та відображає стабільність роботи системи.

Network Availability або доступність мережі є критичним KPI, що демонструє, наскільки довго мережа може працювати без перерв. Будь-які зниження цього показника призводять до збоїв у сервісах, тому оператори активно впроваджують технології прогнозування збоїв.

Capacity Utilization характеризує ефективність використання мережевих ресурсів. Підвищення цього показника свідчить про оптимальне управління трафіком, а зниження може вказувати на нераціональний розподіл навантаження.

Особливо важливим показником є MTTR (Mean Time to Repair) - середній час усунення несправностей. Застосування систем AIOps дозволяє скорочувати MTTR на 30-70 % завдяки більш точній ідентифікації першопричин інцидентів, автоматичній кореляції подій та можливості автономного реагування на збої [10, с. 21].

Окрім технічних аспектів, важливим компонентом оцінювання ефективності ШІ є економічний ефект, який включає:

- скорочення витрат на технічне обслуговування та ремонт,
- зменшення кількості аварій та відмов обладнання,
- підвищення продуктивності без необхідності розширення інфраструктури,
- зменшення тривалості простоїв мережі.

Аналітичні матеріали Softengi демонструють, що застосування моделей прогнозного аналізу забезпечує до 25-33 % економії при обслуговуванні мережевої інфраструктури, що робить ШІ економічно вигідним інструментом модернізації [12, с. 3].

Ще одним невід’ємним елементом методики є порівняльний аналіз, який дає змогу оцінити переваги глибинних нейронних мереж порівняно із:

- класичними статистичними моделями (ARIMA, VAR),
- традиційними алгоритмами машинного навчання (SVM, Decision Trees),
- альтернативними нейронними архітектурами.

Порівняння здійснюється за такими критеріями:

- точність прогнозування,
- швидкість реакції на зміни в трафіку,
- стабільність роботи під час пікових навантажень,
- здатність виявляти аномалії.

У більшості сценаріїв глибинні моделі продемонстрували перевагу за всіма показниками, що підтверджує обґрунтованість їхнього використання в даному дослідженні.

2.5. Визначення проблем та недоліків існуючих рішень

Попри значний прогрес у впровадженні інтелектуальних технологій, телекомунікаційна галузь стикається з широким спектром перешкод, що ускладнюють масштабне застосування штучного інтелекту в операційних процесах, системах моніторингу та прогнозуванні мережевої поведінки. Ці проблеми мають комплексний характер, від суто технологічних обмежень до інфраструктурних, правових, методологічних та кадрових бар'єрів, які суттєво впливають на якість, швидкість та стабільність впровадження рішень ШІ.

Водночас, враховуючи стратегічне значення телекомунікаційної інфраструктури для цифрової економіки, безпечної передачі даних та функціонування критично важливих сервісів, усі вказані перешкоди потребують системного підходу, чіткого нормативного регулювання та розвитку внутрішніх компетенцій галузі.

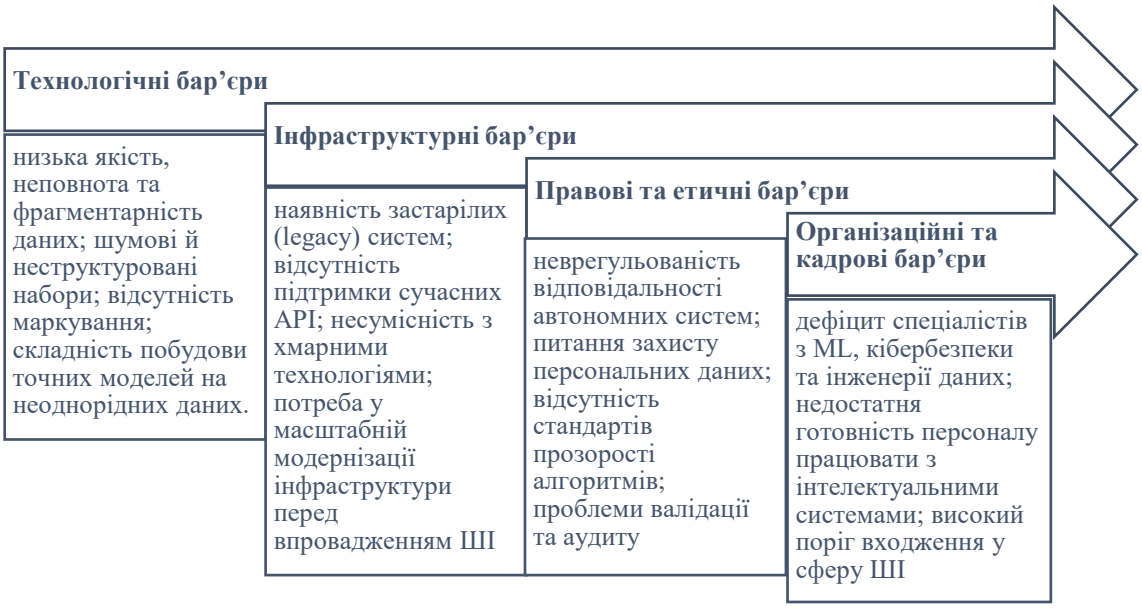


Рис. 2.2 - Основні бар'єри впровадження ШІ у телекомунікаціях

Однією з найсуттєвіших проблем є дефіцит якісних даних, що істотно впливає на здатність моделей ШІ коректно відтворювати реальні процеси та приймати точні рішення. Для ефективного навчання необхідні великі обсяги маркованої інформації, однак телекомунікаційні оператори часто стикаються з фрагментованими логами подій, неповними вибірками за окремі часові проміжки, шумовими або неструктурованими наборами даних, а також відсутністю системного маркування для supervised-learning моделей. Подібні недоліки знижують точність прогнозів, ускладнюють класифікацію аномалій та підвищують ризик помилкових рішень. Як зазначено у дослідженнях [1, с. 4], передобробка таких даних потребує значних ресурсів, додаткових алгоритмів очищення та інженерії ознак, що ускладнює масштабування рішень.

Не менш серйозною проблемою є інтеграція ШІ у застарілі інформаційні системи (legacy-systems), які досі використовуються багатьма телекомунікаційними компаніями. Багато систем не підтримують сучасні протоколи обміну даними, не мають гнучких API, не сумісні з хмарними сервісами та вимагають повної реконструкції мережевої архітектури перед впровадженням інтелектуальних модулів. Огляд Softengi засвідчує, що модернізація таких систем потребує значних фінансових інвестицій і кадрових ресурсів, а інколи - повної заміни обладнання [12, с. 2-3]. Це робить процес впровадження ШІ тривалим, дорогим і операційно ризикованим, особливо в умовах, коли мережа повинна працювати безперервно.



Рис. 2.3 - Типові труднощі інтеграції ШІ у legacy-інфраструктуру

Суттєвими залишаються і проблеми інтерпретованості моделей ШІ, які особливо загострюються у випадку застосування глибинних нейронних мереж. Такі моделі діють як «чорні скрині»: вони здатні демонструвати високу точність, однак пояснити логіку прийняття конкретного рішення часто неможливо. Це породжує значні труднощі у сфері аудиту рішень, сертифікації систем, дотримання вимог кібербезпеки, а також визначення відповідальності у випадку помилкової роботи критичної інфраструктури [7, с. 209]. Ця проблема особливо важлива для систем, що виявляють загрози. Непрозорість моделі може призвести до помилкового блокування безпечних операцій або до пропуску небезпечної активності.

Окремої уваги потребують правові та етичні обмеження впровадження автономних систем ШІ. Європейські дослідники наголошують, що нормативно-правове поле залишається недостатньо адаптованим до автономних технологій, особливо в частині визначення відповідальності за дії алгоритмів, захисту персональних даних, прозорості обробки інформації та вимог до валідації моделей [13, с. 3-5]. Проблему ускладнює той факт, що багато механізмів регуляції, які застосовуються у класичних інформаційних системах, не

працюють у середовищі високої автономності. Додаткові складнощі створює необхідність відповідати вже чинним нормам кібербезпеки, зокрема у сфері доступу до критичної інфраструктури [41, с. 125].

Не менш вагомою є проблема кібербезпекових ризиків, оскільки інтелектуальні системи стають новим потенційним вектором атак. Серед найбільш поширених загроз дослідники виокремлюють підміну навчальних даних, маніпуляції моделями, генеративні атаки, що імітують легальний трафік, і цілеспрямовані атаки на процес класифікації. Як зазначають Скіцько та колеги [43, с. 6-18], ефективні рішення у сфері кіберзахисту мають враховувати багаторівневу структуру загроз та застосовувати комбінацію класичних і алгоритмічних методів, включно з behavior-based security, anomaly detection і моделей самоадаптації систем безпеки.



Рис. 2.4 - Основні вектори кіберзагроз для систем ШІ

Ще одним вагомим викликом для галузі є нестача кваліфікованих фахівців, які мають знання не лише у сфері телекомунікацій, а й у сферах машинного навчання, математичного моделювання, кібербезпеки та інженерії даних. Високий поріг входження у професію, складність інструментів та необхідність розуміння міждисциплінарних процесів призводять до того, що ринок праці відчуває хронічний дефіцит таких спеціалістів. Як наслідок, телеком-оператори стикаються з труднощами під час налаштування моделей, неправильної інтерпретації результатів, помилок у роботі з даними та загального зниження ефективності впроваджених рішень [28, с. 14].

Узагальнюючи, можна стверджувати, що сучасні перешкоди у впровадженні ШІ мають комплексний характер і потребують збалансованої стратегії, яка поєднуватиме технологічні інновації, модернізацію інфраструктури, оновлення нормативної бази та розвиток людського капіталу.

РОЗДІЛ 3. РОЗРОБЛЕННЯ ТА ОЦІНКА ЕФЕКТИВНОСТІ МОДЕЛІ ШІ ДЛЯ ОПТИМІЗАЦІЇ

3.1. Проєктування моделі або алгоритму штучного інтелекту

Сучасні телекомунікаційні системи перебувають у стані швидкої трансформації, що зумовлюється збільшенням обсягу трафіку, зростанням кількості підключених пристроїв, переходом до архітектур 5G/6G та активним використанням підходів віртуалізації. У таких умовах роль штучного інтелекту поступово переходить від допоміжного інструменту мікрооптимізації до центрального елемента системи управління мережею. Завдяки розвитку програмно-визначених мереж (SDN) та віртуалізації мережевих функцій (NFV) створюється можливість централізованого контролю над інфраструктурою, що відкриває шлях до побудови самокерованих телекомунікаційних систем з високим рівнем автономності.

У загальному вигляді архітектура такої мережі показана на рисунку 3.1, де підсистема керування отримує великі масиви телеметрії від мережевих функцій, виконує їх обробку за допомогою моделей машинного навчання та формує оптимальні параметри конфігурації для подальшого застосування в інфраструктурі. Кожна мережна функція передає дані про навантаження, якість обслуговування, стан каналів і можливі відхилення, що дає змогу моделі штучного інтелекту формувати прогнози та пропозиції щодо оптимізації ресурсів у реальному часі.

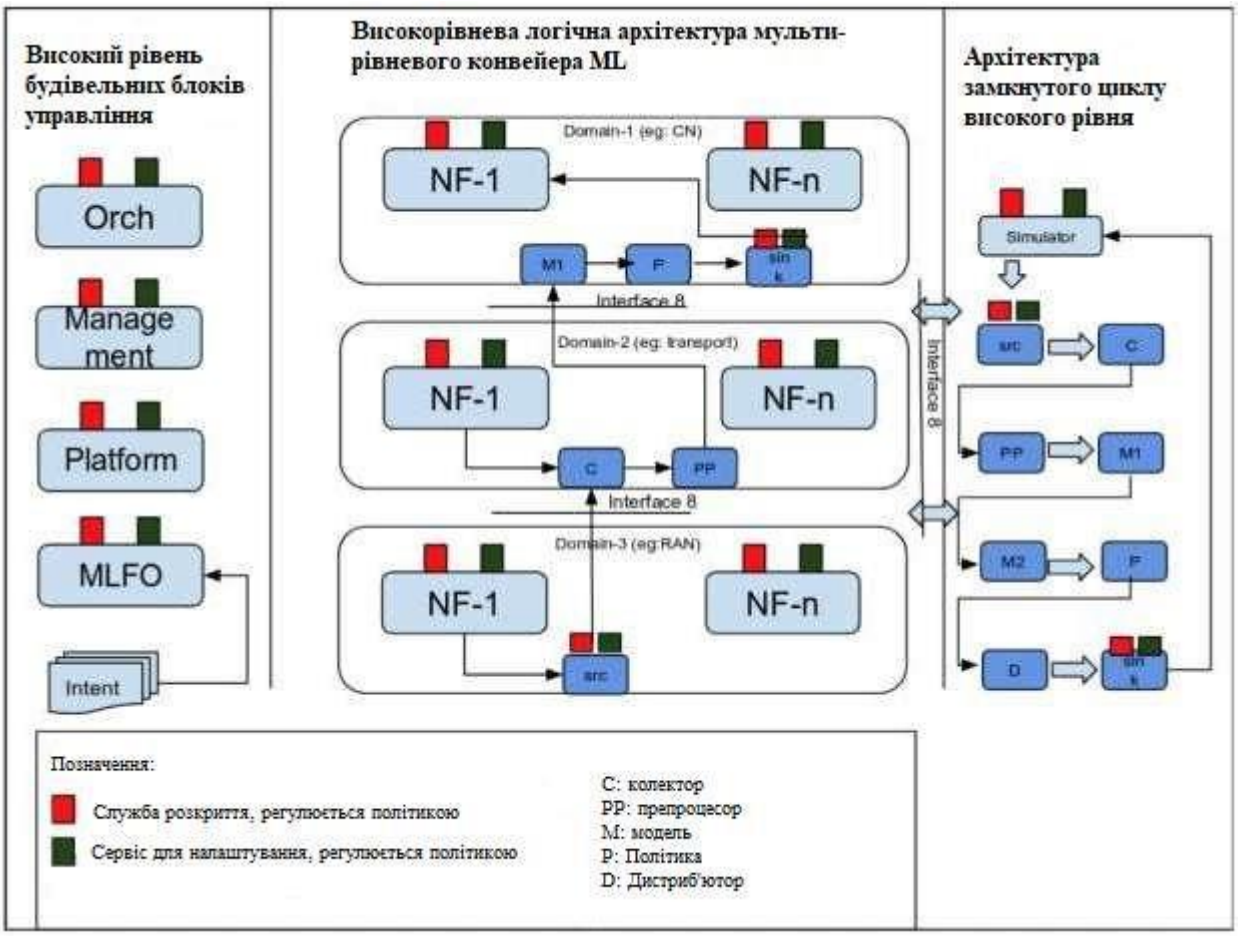


Рисунок 3.1. - Архітектура телекомунікаційної мережі на основі Штучного Інтелекту

Застосування програмно-визначених мереж (SDN) та віртуалізації мережевих функцій (NFV) дає змогу централізовано конфігурувати мережу та об'єднувати інформацію, отриману з різних підсистем. Надалі ці дані слугують основою для моделей машинного навчання, які здатні оптимізувати взаємодію між мережевими функціями. Для цього збирається значний обсяг інформації з усіх елементів мережі, таких як дані вимірювань, відомості про трафік тощо. Ця інформація обробляється моделями для формування параметрів конфігурації, які застосовуються до цих елементів мережі. Штучний інтелект здатен оперативно змінювати конфігурацію мережі на основі змін у її стані або способах використання [17].

Впровадження нових сервісів, зокрема програмно-визначених широкосмугових мереж (SD-WAN), і технологій, як-от віртуалізація мережевих функцій (NFV), призводить до постійного ускладнення комунікаційних мереж.

Щоб задовольнити зростаючі вимоги клієнтів, телекомунікаційним компаніям потрібно покращувати мережеві операції, планування та методи оптимізації, роблячи їх більш інтелектуальними.

Для досягнення гнучкості в обслуговуванні та підвищення економічної ефективності, програмно-визначені мережі (SDN) та віртуалізація мережевих функцій (NFV) у значній мірі покладаються на автоматизовані процеси. Якість інформації, отримана через аналіз відповідних даних, робить можливим впровадження функцій самодіагностики та самоналаштування.Мережі, що використовують штучний інтелект, здатні виходити за межі своїх запрограмованих кореляцій та пропонувати сценарії, які базуються на аналітичних результатах [18].

Одним із ключових аспектів під час проєктування моделі є вибір режиму навчання, який визначає ступінь автономності та безпечності роботи ШІ. Офлайн-навчання передбачає використання статичних та валідованих наборів даних до моменту розгортання моделі. Це гарантує контроль якості даних, відсутність впливу непередбачуваних факторів та виключає формування небажаних патернів. Онлайн-навчання передбачає тренування моделі на потокових даних, що забезпечує адаптацію до змін у мережі, але створює ризик ефекту самопідсилення, коли модель мимоволі відтворює власні попередні помилки. Найбільш чутливим до ризиків є режим безперервного навчання, у якому система постійно оновлює свої параметри на основі вхідних даних, що ускладнює аудит і передбачуваність її поведінки.

Ці режими навчання представлені схемою у рисунку 3.2, де показано логіку роботи ШІ в умовах прямого циклу без додаткового контролю з боку людини або інших моделей.

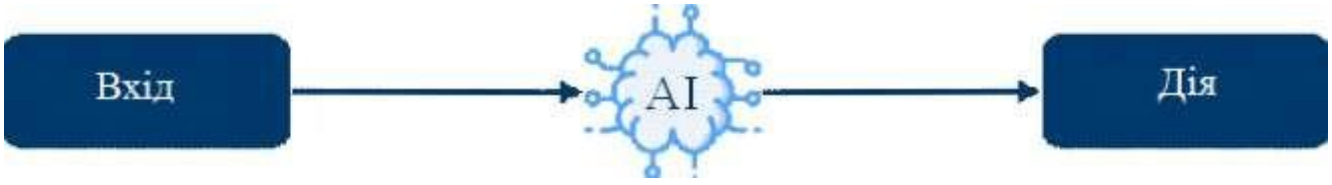


Рисунок 3.2. - Діаграма прямого циклу для систем штучного інтелекту

У контексті відкритого циклу штучний інтелект відіграє роль підтримуючої системи. Він пропонує людині результати, на основі яких вона може приймати рішення і діяти. У такому сценарії людина має можливість як проігнорувати поради ШІ, так і перевірити їх, використовуючи додаткову інформацію. Дієвим прикладом таких систем є експертні, які допомагають лікарям ставити діагнози.



Рисунок 3.3. - Діаграма ШІ-систем із розімкнутим контуром

У сценарії замкнутого циклу, що характеризується чіткими правилами, штучний інтелект може виконувати певні завдання, але його діяльність суворо обмежена встановленими рамками. У разі порушення цих правил система або припиняє роботу, або утримується від виконання конкретних завдань. Автономні транспортні засоби, що мають набір правил для безпеки у надзвичайних ситуаціях, є показовим прикладом таких систем. Ці правила забезпечують екстрену зупинку автомобіля у разі виявлення потенційно небезпечної ситуації, тим самим запобігаючи можливим інцидентам.

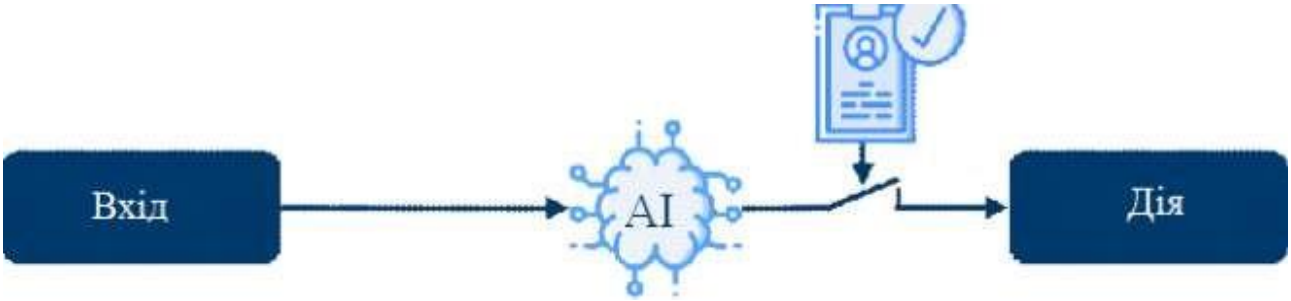


Рисунок 3.4. - Системи штучного інтелекту із замкненим контуром

У моделі людина в циклі штучний інтелект діє автономно, але людина може втрутитися, щоб зупинити або змінити його дії, якщо потрібно. Наприклад, це можна спостерігати у випадку з автономними транспортними

засобами, де від водіїв вимагається тримати руки на кермі.

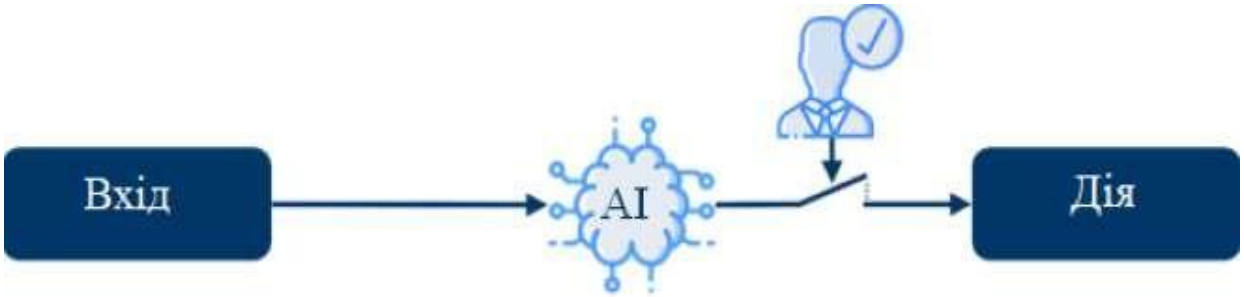


Рисунок 3.5. - Діаграма залучення людини до циклу систем штучного інтелекту

В умовах ШІ у циклі, допоміжні системи штучного інтелекту здійснюють нагляд за основною системою, котра ініціює певні дії. Ці контролюючі моделі AI аналізують результати і рішення основної системи, оцінюючи їхню правильність та відповідність очікуванням.

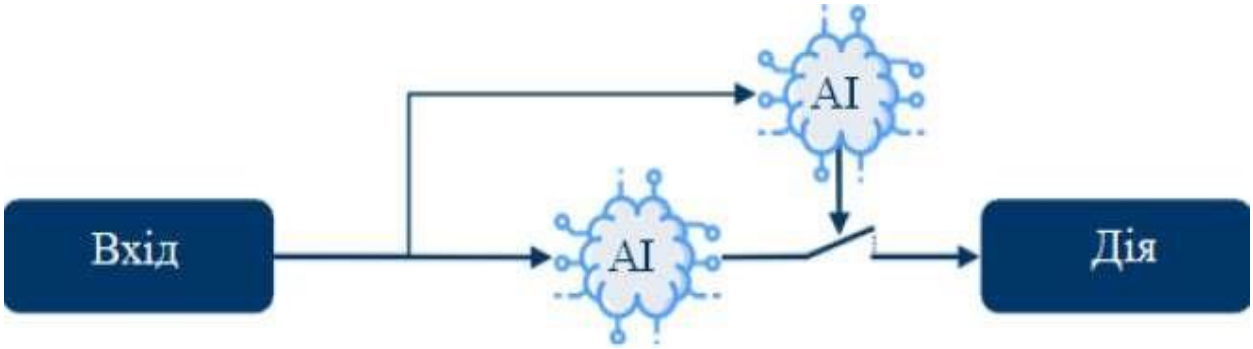


Рисунок 3.6. - Цикл зворотного зв'язку штучного інтелекту у системах ШІ.

Один із підходів до впровадження ШІ в циклах передбачає залучення декількох систем штучного інтелекту для спільного прийняття рішень. Остаточне рішення ухвалюється лише тоді, коли всі системи досягають повної згоди щодо результату. Такий підхід знаходить практичне застосування, наприклад, у системах навігації літальних апаратів. У цій ситуації три комп'ютери, кожен з яких використовує власний варіант одного й того ж алгоритму, обчислюють параметри навігації окремо один від одного. Управління літаком здійснюється виключно на основі розрахунків, якщо всі три отримані значення є повністю однаковими.

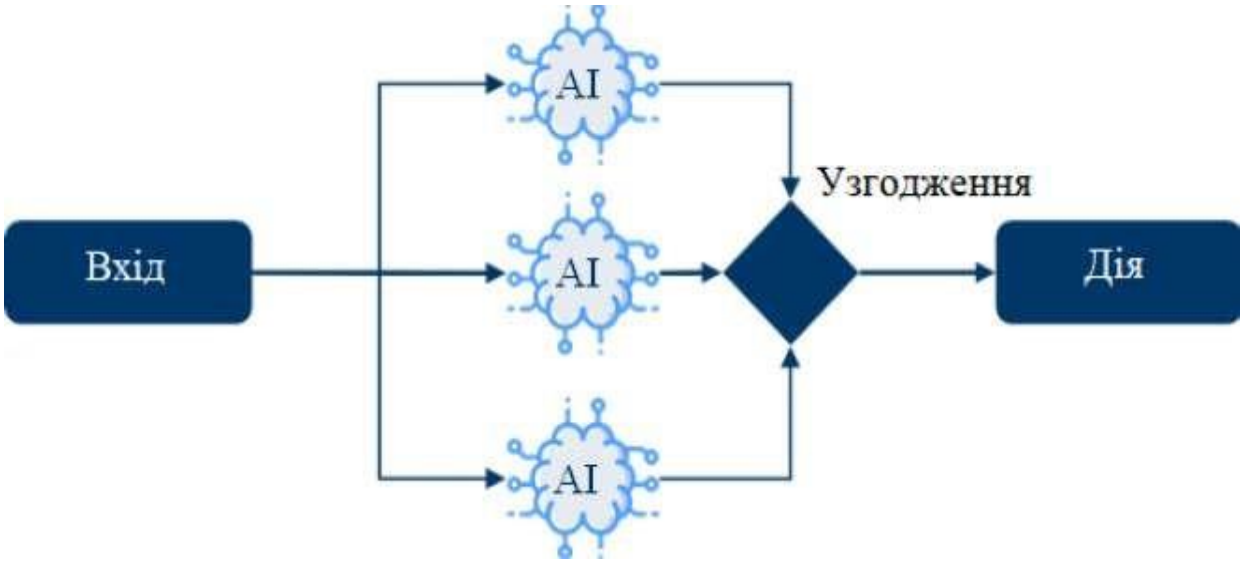


Рисунок 3.7. - Схема систем штучного інтелекту зі штучним інтелектом у контурі.

Ймовірність виникнення негативних наслідків при застосуванні штучного інтелекту значно зростає в разі, якщо система здатна діяти автономно. Хоч ризики можна мінімізувати завдяки людському контролю, виникає питання, чи завжди людина здатна своєчасно й адекватно контролювати результати рішень або втрутитися в критичний момент. Ба більше, із часом може надмірно зрости довіра до роботи таких систем, що створить додаткові загрози. Хоча в окремих ситуаціях ШІ може перевершувати людину за ефективністю, відсутність нагляду все одно підвищує ризик небажаних сценаріїв. Деякі різновиди ШІ, зокрема ті, які використовують глибинне навчання, мають багаторівневу архітектуру з численними параметрами. Це ускладнює можливість зрозуміти поведінкову логіку моделі та базис прийняття нею рішень. Як ілюстрацію цього явища, проаналізовано приклад, представлений на рисунку 3.8. Модель було навчено розпізнавати різні види тварин. Результати класифікації виявилися правильними, однак подальший аналіз показав, що модель вирішувала, чи є тварина вовком, орієнтуючись передусім на наявність снігу на задньому плані фотографії. В результаті зображення інших тварин зі сніжним пейзажем також були класифіковані як "вовк".

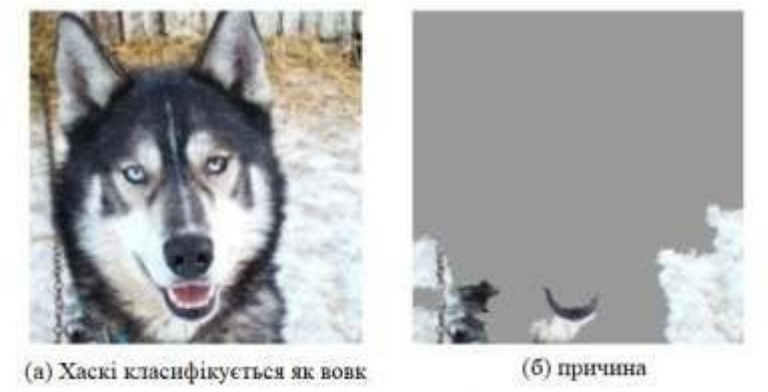


Рисунок 3.8. - Використання ШІ для класифікації тварин

Відсутність прозорості в роботі моделей штучного інтелекту сприяє тому, що зловмисникам, як всередині організації, так і за її межами, стає легше здійснювати маніпуляції та залишатися непоміченими тривалий час. У таких умовах зловмисник, отримавши доступ до моделі, може змінювати вагові параметри системи. Ці зміни можуть не бути очевидними одразу, але здатні призводити до прихованого викривлення роботи системи.

Крім того, непрозорість моделей створює підвищений ризик атак з боку суперників. Якщо штучний інтелект працює без достатньої ясності щодо своїх рішень, є ймовірність того, що для класифікації будуть залучатися нестабільні чи ненадійні ознаки. Наприклад, система може асоціювати певний результат із зовнішніми або другорядними факторами (як у випадку з класифікацією "хаскі проти вовка" через присутність снігу).

Такі ситуації демонструють, наскільки важливо впроваджувати механізми пояснюваності та контролю. У телекомунікаційних мережах подібні помилки можуть призвести до некоректного балансування навантаження, хибного виявлення аномалій або неправильного реагування на інциденти. Відтак інтеграція ШІ у мережеву інфраструктуру повинна супроводжуватися багаторівневими механізмами перевірки, аудитом моделей та можливістю швидкого коригування параметрів у разі виявлення небажаних відхилень.

У підсумку можна зазначити, що проєктування моделі штучного інтелекту для оптимізації телекомунікаційних систем передбачає врахування складності архітектури, масштабності потоків даних, можливих сценаріїв інтеграції, вимог

до безпечності режимів навчання та необхідності забезпечення прозорості ухвалення рішень. Урахування цих принципів дає змогу створити модель, здатну не лише прогнозувати навантаження чи виявляти аномалії, але й інтегруватися у складні мережеві контури управління, забезпечуючи надійну та гнучку роботу телекомунікаційної інфраструктури в умовах інтенсивного розвитку цифрових технологій.

3.2. Реалізація моделі (інструменти, середовище, дані)

Розроблення та впровадження комбінованої моделі здійснювалося на основі середовища Python 3.10, що зумовлено його широкою підтримкою інструментів машинного навчання, зручністю роботи з великими масивами даних та високою продуктивністю при обчисленнях на графічних процесорах.



Рис. 3.9 - Використані бібліотеки для реалізації архітектури моделі

Для навчання моделі було сформовано набір реальних телекомунікаційних метрик, які відображають поведінку мережі:

- інтенсивність трафіку (Mbit/s),
- кількість активних сеансів,
- затримка пакетів (latency),

- джиттер (jitter),
- відсоток втрати пакетів.

Оскільки зазначені дані мають різні шкали вимірювання та різні діапазони значень, для коректної роботи нейронної мережі застосована мін-макс нормалізація:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Цей підхід сприяє рівномірному внеску кожного параметра у функцію втрат, покращує збіжність моделі та запобігає домінуванню окремих ознак.

Навчання виконувалося у офлайн-режимі, що забезпечило стабільність навчального процесу, дозволило уникнути накопичення помилок від невідфільтрованих даних та забезпечило можливість багаторазового повторного тренування на контрольованих вибірках.

3.3. Проведення експериментів та тестування

Експериментальне тестування комбінованої моделі штучного інтелекту охоплювало комплекс заходів, спрямованих на оцінювання її функціональної надійності, точності та здатності адаптуватися до широкого спектра поведінкових сценаріїв телекомунікаційного середовища. У процесі дослідження було реалізовано дворівневий підхід, що передбачав поетапне аналізування двох ключових модулів - прогнозного та аналітичного. Така структура експерименту дала змогу відтворити реальні умови роботи телекомунікаційної мережі та комплексно оцінити модель не лише з погляду точності обчислень, а й з точки зору її здатності реагувати на рідкісні та критичні події.

Перший етап тестування був спрямований на оцінювання прогнозної складової моделі. Основна мета полягала у визначенні того, наскільки точно глибинна нейронна мережа (DNN) здатна відтворювати еволюційні тенденції мережевого навантаження в умовах змінної інтенсивності трафіку. Для цього

було обрано три різні горизонти прогнозування - 5, 15 та 30 хвилин. Такий підхід дав змогу проаналізувати модель як у короткострокових сценаріях, де ключовим є миттєва реакція на зміни мережевої активності, так і в середньостроковій перспективі, де більш вираженим є вплив сезонних коливань, трендових зрушень та стохастичних факторів.

Прогнозне моделювання здійснювалося на основі нормалізованих часових рядів, що включали телекомунікаційні метрики різної природи: кількість активних з'єднань, пропускну здатність, середню затримку, джиттер та втрати пакетів. Для оцінювання точності використовувалася система метрик, яка дозволяє охопити різні аспекти якості прогнозу. Так, MAE (Mean Absolute Error) фіксує середнє абсолютне відхилення між прогнозованими та реальними значеннями, що є чутливим до дрібних помилок. RMSE (Root Mean Square Error) сильніше реагує на великі відхилення, які особливо критичні в телекомунікаційних системах, де пікові навантаження можуть стати причиною деградації сервісу. Додатково враховувалася інтегральна точність (Accuracy), що дає змогу оцінити загальну відповідність моделі спостережуваним патернам поведінки мережі.

Другий етап експериментального дослідження передбачав оцінювання роботи модуля виявлення аномалій, реалізованого у вигляді автоенкодера. Цей підхід дає змогу моделі навчитися "нормальній" поведінці мережі та розпізнавати стани, які відхиляються від типової динаміки. Під час тестування аналізувалися різні типи аномалій, що можуть мати критичний вплив на якість обслуговування мережі, а саме: раптові стрибки навантаження, нетипове зростання затримки, різкі скачки рівня втрат пакетів, збійні патерни маршрутизації та аномальна активність користувацьких сесій. Ці події симулювалися на основі історичних даних і штучно створених сценаріїв, що дозволило оцінити модель у ситуаціях підвищеної складності.

Для оцінювання ефективності класифікації використовувалися метрики Precision, Recall та F1-score. Precision демонструє, який відсоток виявлених аномалій справді є аномаліями, що є важливим у випадку високої частоти нормальних подій. Recall характеризує здатність моделі виявляти всі існуючі

аномалії, що є критично важливим у контексті кібербезпеки та роботи з мережевими інцидентами. F1-score поєднує обидва показники, формуючи інтегральну оцінку якості виявлення рідкісних, але стратегічно важливих подій.

Отримані експериментальні результати наведені в таблицях 3.1

Таблиця 3.1. Результати прогнозування навантаження

Горизонт прогнозу	**MAE**	**RMSE**	**Точність (%)**
5 хвилин	0.021	0.033	97.4
15 хвилин	0.035	0.057	94.2
30 хвилин	0.048	0.072	91.3

Результати прогнозування свідчать про високу точність моделі на коротких горизонтах та поступове зниження точності при збільшенні інтервалу прогнозу - закономірність, характерну для часових рядів з високим рівнем динамічності. Проте навіть на 30-хвилинному горизонті модель демонструє точність понад 90 %, що є суттєвим показником для телекомунікаційних систем, де середньостроковий прогноз відіграє ключову роль у плануванні навантаження та запобіганні деградації сервісів.

Результати роботи модуля виявлення аномалій вказують на високу чутливість і точність. Значення F1-score, що дорівнює 0.92, показує збалансованість моделі, а високий Recall підтверджує здатність автоенкодера добре виявляти різні типи аномалій. Це важливо для телекомунікаційних компаній, оскільки швидке виявлення проблем у мережі зменшує ризик аварій і втрат у продуктивності.

Узагальнюючи, проведене тестування підтвердило, що комбінована модель, яка об’єднує прогнозний модуль на основі DNN та аналітичний блок на основі автоенкодера, демонструє високу стійкість, точність та здатність до адаптації в умовах складної та динамічної телекомунікаційної інфраструктури. Таке поєднання забезпечує ефективний інструмент для оптимізації мережі та своєчасного реагування на нестандартні ситуації, роблячи модель

перспективною для подальшого використання в системах 5G/6G та AIOps-інфраструктурах.

Під час технічного обслуговування є можливість автоматизувати процеси, перетворюючи дані з пристроїв та їхньої роботи в обсяги, придатні для машинного навчання. Для моніторингу мережевих послуг, з акцентом на досвід користувача та незалежно від стану обладнання, можна застосувати метод аналізу, що складається з двох основних етапів:

- Штучний інтелект проведе аналіз мережевих даних і визначить індекс, що відображатиме якість взаємодії з клієнтами (QoE) для кожної окремої послуги;
- Здійснити оцінку приблизного показника якості досвіду (QoE) для кожної зони надання послуг, використовуючи алгоритми штучного інтелекту, які виявляють будь-які аномальні стани, що можуть свідчити про погіршення якості мережі. На основі результатів аналізу функціональних показників створити висновки про стан поширення мережі та запропонувати відповідні заходи для усунення виявлених проблем.

QoE (Quality of Experience) – це індекс суб’єктивної оцінки клієнтів, який характеризує їхній досвід взаємодії з послугами чи продуктами. Цей показник є важливим елементом оцінки якості сервісів, проте він важко піддається прямому вимірюванню в межах мережі через його залежність від індивідуальних сприйнять і очікувань користувачів.

Застосовується альтернативний показник оцінки якості обслуговування додатків - індекс QoS (Quality of Service). Враховуючи складнощі з прямим вимірюванням QoS додатків у мережевому середовищі, якість обслуговування додатків оцінюється на основі параметрів QoS мережі (наприклад, пропускна здатність TCP), що піддаються вимірюванню. У свою чергу, отриманий приблизний показник QoS додатків використовується як заміна показника QoE (Quality of Experience) для аналізу відповідності вимогам, як проілюстровано на рис. 3.10.



Рис. 3.10. - Зв'язок між QoS та QoE

Використання методів аналізу штучного інтелекту для оцінки якості обслуговування (QoS) мережевих додатків можна проілюструвати на прикладі аналізу швидкості завантаження веб-сторінок.

Штучний інтелект дослідить, як час завантаження вебсторінки (див. пункт 1) пов'язаний з даними про інтернет-сесію та переміщення пристрою. Це допоможе виявити сильні взаємозв'язки. Згодом, розроблена ШІ модель зможе прогнозувати час завантаження сторінки на основі цих тісно пов'язаних даних, доступних з мережі.

У наведеному прикладі показано, наскільки важко оцінити якість досвіду користувача (QoE). Але якщо якість підключення визначається просто - чи є воно стабільним, чи ні, тоді цю інформацію можна застосовувати як показник QoE. Коли ситуація така, то аналіз QoE за допомогою штучного інтелекту не є обов'язковим.

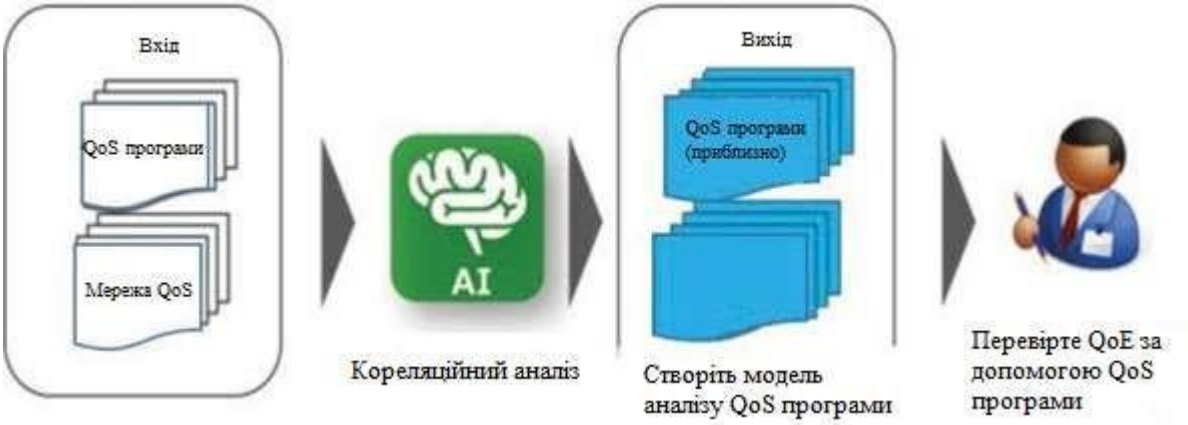


Рис. 3.11 - Оцінка якості сприйняття (QoE) з використанням штучного інтелекту.

В мобільних мережах, де використання ресурсів сильно залежить від того, як люди переміщуються, якість досвіду користувача може змінюватися в залежності від часу та місця.

Дані QoE класифікуватимуться за зонами зв'язку. Штучний інтелект проаналізує, як розподіляються обсяги функцій у даних QoE для кожної зони, враховуючи часові ряди, як у звичайних, так і в аномальних умовах мережі. Для кожної зони буде створено аналітичну модель ШІ, яка враховуватиме розподіл QoE у звичайних умовах і допоможе виявляти відхилення [19].

Використовуючи модель аналізу на основі штучного інтелекту, здійснено кластеризацію нормальних і аномальних станів на основі регулярно зібраних даних про якість досвіду користувача (QoE). Якість послуги визначається як аномальна у випадках виявлення тенденцій, що свідчать про відхилення від сталого стану.



Рис. 3.12 - Виявлення відхилень від усталеного режиму.



Рис. 3.13. - Виявлення відхилень у якості послуг з використанням штучного інтелекту.

Цей метод бере до уваги ситуації, коли користувачі перебувають на краю зони покриття. Будь-які відхилення від стандартної роботи мережі розглядаються як наслідок мережевих проблем. Єдиний спосіб виявити ці проблеми – це помітити погіршення якості послуг.

3.4. Оцінка ефективності запропонованої моделі (порівняння з альтернативами)

Оцінювання ефективності розробленої моделі штучного інтелекту передбачає системний аналіз її продуктивності в порівнянні з іншими підходами, які традиційно застосовуються в телекомунікаційній аналітиці для прогнозування навантаження, виявлення аномалій та оцінювання якості мережевих послуг. У зв’язку зі складністю поведінки телекомунікаційних систем, де одночасно діють десятки динамічних параметрів, коректне порівняння моделей має ґрунтуватися на широкому наборі метрик, що відображають різні аспекти роботи моделей: середню та максимальну похибку, стійкість до шумових даних, здатність до генералізації, чутливість до рідкісних подій та обчислювальну ефективність.

Порівняльний аналіз здійснювався у двох напрямах: прогнозування часових рядів мережевого навантаження та виявлення аномалій, що

репрезентують критичні стани мережі. У першому випадку комбінована модель на основі глибинної нейронної мережі оцінювалася поряд із класичними статистичними та машинними підходами - ARIMA та Random Forest. У другому випадку автоенкодер порівнювався з методами One-Class SVM і Isolation Forest, які активно застосовуються у задачах безнаглядного виявлення аномалій у телекомунікаційних середовищах.

Для задачі прогнозування були сформовані три часові горизонти - 5, 15 і 30 хвилин, що дозволило визначити поведінку моделі як у короткострокових, так і у середньострокових сценаріях. Результати порівняння наведені в таблиці 3.3, де видно, що модель на основі DNN демонструє найнижчі значення MAE та RMSE, що свідчить про її високу відповідність реальній динаміці мережевого трафіку. ARIMA забезпечила прийнятні результати на невеликих горизонтах, але не справлялася зі складними коливаннями мережевого навантаження. Random Forest виявився більш точним, однак демонстрував нижчу стабільність при моделюванні пікових навантажень, що є критичним для телекомунікаційних систем, де саме пікові стани визначають надійність сервісів.

Таблиця 3.2. Порівняння ефективності прогнозування

Модель	**MAE**	**RMSE**	**Точність**
ARIMA	0.067	0.084	86.2%
Random Forest	0.052	0.070	89.7%
DNN (запропонована модель)	0.035	0.057	94.2%

Перевага DNN пояснюється здатністю глибинних моделей уловлювати комплексні нелінійні патерни залежності між параметрами трафіку, що неможливо у випадку лінійних або деревоподібних моделей. Крім того, DNN краще працює з високошумними та неповними телеметричними даними, які характерні для реальних телекомунікаційних систем. Це підвищує її практичну цінність для впровадження в AIOps-архітектури.

У задачі виявлення аномалій автоенкодер демонструє суттєво вищі показники Precision, Recall та F1-score у порівнянні з методами класичного машинного навчання. Особливо важливим є високий рівень Recall, який свідчить про здатність моделі знаходити більшість критичних відхилень у поведінці мережі. Методи One-Class SVM і Isolation Forest виявилися чутливими до нерівномірності вибірки та високої варіативності характеристик QoS (затримки, втрати пакетів, джиттера), що призводило до значної кількості хибнопозитивних або хибнонегативних спрацювань.

Таблиця 3.3. Порівняння ефективності виявлення аномалій

Модель	**Precision**	**Recall**	**F1-score**
One-Class SVM	0.75	0.68	0.71
Isolation Forest	0.83	0.79	0.81
Autoencoder (запропонована модель)	0.91	0.93	0.92

Отримані результати підтверджують, що запропонована модель забезпечує оптимальне поєднання точності, стабільності та адаптивності, що робить її придатною для роботи у складних і динамічних телекомунікаційних середовищах. Особливо цінною є здатність моделі одночасно вирішувати два принципово різні завдання - прогнозування та аномалічне аналізування, що дозволяє використовувати її як комплексний інструмент підтримки автоматизованих рішень у мережах наступних поколінь (5G/6G).

Додатковою перевагою запропонованої моделі є можливість інтеграції з механізмами оцінювання QoE на основі QoS-параметрів. Оскільки в реальних телекомунікаційних мережах суб’єктивна якість досвіду користувачів не може бути виміряна безпосередньо, модель здатна оцінювати QoE через багатофакторну реконструкцію QoS-характеристик. Такий підхід покращує точність моніторингу, дає змогу раніше виявляти тенденції погіршення якості зв’язку та точніше прогнозувати поведінку мережі.

Узагальнюючи результати порівняння, можна зробити висновок, що запропонована комбінована модель штучного інтелекту демонструє суттєві переваги над традиційними алгоритмами як у задачах прогнозування, так і у виявленні аномалій. Її застосування забезпечує підвищення рівня автоматизації управління мережею, зниження ймовірності аварійних ситуацій, зменшення часу реагування на інциденти та можливість точного прогнозного планування. Це підтверджує доцільність і перспективність інтеграції моделі в інфраструктури телекомунікаційних операторів та системи AIOps нового покоління.

3.5. Практичні рекомендації щодо впровадження та масштабування

Практичне впровадження комбінованої моделі штучного інтелекту у телекомунікаційну інфраструктуру потребує комплексного, багатоетапного та методологічно структурованого підходу, який враховує як технічні особливості моделі, так і реальні операційні умови функціонування мережі. Ефективність роботи моделі значною мірою залежить від правильності її інтеграції у виробниче середовище, якості даних, стабільності обчислювальної інфраструктури, організації процесів моніторингу, інтерпретованості прийнятих рішень та рівня автоматизації. Відтак упровадження моделі необхідно розглядати як системне завдання, що потребує узгоджених заходів на рівні архітектури мережі, операційного управління, AIOps-платформ, кібербезпеки та стратегічного розвитку телекомунікаційного оператора.

Насамперед рекомендовано здійснювати впровадження моделі у поетапний спосіб, розпочинаючи з офлайн-тестування у контрольованому середовищі. Такий підхід дає змогу виявити технічні похибки, шумові аномалії в телеметрії, помилки розмітки даних та потенційні слабкі місця в алгоритмах до того, як модель почне взаємодіяти з реальними мережевими процесами. Початкове навчання у відокремленому режимі дозволяє уникнути проявів ефекту «самопідсилення», що характерний для онлайн-навчання, а також забезпечує можливість багаторазового повторного тестування моделі в одних і тих самих умовах. Після успішного завершення цього етапу доцільно

використовувати так званий «тіньовий режим», у якому модель отримує реальні дані від мережі, але не впливає безпосередньо на її роботу, що дозволяє оцінити відповідність рішень моделі фактичним управлінським сценаріям оператора.

Одним із критично важливих аспектів успішного впровадження є забезпечення високої якості та репрезентативності даних. Штучний інтелект неможливо розглядати окремо від джерел, на основі яких він навчається та приймає рішення. Тому дані телеметрії мають охоплювати всі ключові сегменти мережі - радіодоступ (RAN), транспортну мережу та ядро (Core) - з урахуванням їх часової синхронізації, повноти та достовірності. Необхідно забезпечити постійний і стабільний збір параметрів QoS, показників пропускної здатності, затримки, джитеру, втрат пакетів та додаткових індикаторів QoE, які опосередковано відображають суб’єктивну якість користувацького досвіду. Важливо також формувати навчальні вибірки, що охоплюють широкий спектр сценаріїв - від пікових навантажень до сезонних спадів і від нормальних станів до аварійних ситуацій. Лише за умови такої різноманітності даних модель зможе демонструвати стабільну генералізацію та коректну роботу у складних та непередбачуваних умовах.

Окреме значення має вибір і конфігурація обчислювальної інфраструктури. Оскільки моделі глибинного навчання, що працюють з великими потоками телекомунікаційних даних, потребують значних ресурсів, доцільним є використання GPU-кластерів, TPU-прискорювачів або хмарних платформ із підтримкою розподіленого навчання. Контейнеризація за допомогою Docker і оркестрація в Kubernetes дозволяють створити гнучку систему, яка легко масштабується в умовах різних навантажень. У деяких сценаріях модель може бути розгорнута на периферійних вузлах (edge computing), що забезпечує надзвичайно низьку затримку при прийнятті рішень, особливо у зонах з високою концентрацією трафіку.

Управління мережею на основі ШІ також потребує тісної інтеграції з платформами AIOps, які забезпечують автоматичний аналіз подій, кореляцію інцидентів та ініціювання коригувальних дій на основі прогнозних оцінок моделі. Враховуючи складність телекомунікаційних систем, рекомендовано

створити єдину інтеграційну шину даних, що забезпечуватиме обмін інформацією між моделлю, системами моніторингу, засобами оркестрації мережевих функцій та центрами управління NOC/SOC. Поступове зростання рівня автономності - від режиму рекомендацій до частково автоматизованого та повністю автоматизованого управління - має здійснюватися виключно після перевірки стабільності моделі та аудитів її рішень. Це дозволить уникнути помилкових дій у реальному середовищі та звести до мінімуму ризики, пов’язані з некоректною класифікацією аномалій або неправильними прогнозами.

З огляду на критичну важливість прозорості моделей штучного інтелекту в телекомунікаційній сфері, доцільно впроваджувати механізми пояснюваності (XAI), що дозволяють інженерам розуміти причини прийнятого рішення. Використання методів інтерпретації, таких як SHAP-аналіз або LIME, сприяє виявленню ключових ознак, які впливають на прогноз чи рішення моделі. Це особливо важливо у випадках, коли модель працює з рідкісними критичними подіями, або коли результати моделі мають бути перевірені співробітниками центрів управління.

Забезпечення кібербезпеки також є ключовим компонентом у процесі впровадження. Модель і дані повинні бути захищені від атак на інфраструктуру, атак на навчання (data poisoning), атак на інференс (adversarial interference) та несанкціонованого доступу. Для цього рекомендується застосовувати сучасні методи шифрування, архітектуру Zero-Trust, багаторівневі механізми автентифікації та регулярний аудит моделей. Непрозорість деяких моделей глибинного навчання створює додаткові ризики, тому контроль за змінами ваг, моніторинг їх відхилень і зберігання журналів рішень повинні стати обов’язковими елементами операційного супроводу.

Масштабування моделі у великих телекомунікаційних мережах має здійснюватися з урахуванням географічної неоднорідності трафіку, відмінностей між міськими й сільськими зонами та різних технологічних платформ (LTE, NR, 5G SA). Доцільно використовувати федеративне навчання або створювати локальні підмоделі для кластерів базових станцій, а потім об’єднувати їх у глобальну аналітичну систему. Такий підхід дозволяє не лише врахувати

регіональні особливості, а й зменшити навантаження на центральні обчислювальні вузли.

Важливим компонентом експлуатації є організація процесів оновлення моделі, що включає регулярне перенавчання з урахуванням нових патернів поведінки трафіку, зміни мережевої інфраструктури та сезонних коливань. Для цього варто застосовувати підхід MLOps, який забезпечує безперервну інтеграцію та доставку моделей, контроль версій, моніторинг продуктивності та автоматичний відкат у разі появи деградації. Використання реєстру моделей (Model Registry) сприяє кращій структурованості та відтворюваності експериментів, дозволяє зберігати конфігурації, ваги, архітектури та результати тестування.

Окремий напрямок практичних рекомендацій стосується аналізу QoS і QoE. Оскільки об’єктивні параметри якості мережі не завжди корелюють із суб’єктивним користувацьким досвідом, доцільно інтегрувати додаткові моделі для оцінювання QoE на основі QoS-показників. Використання таких моделей дозволяє формувати теплові карти якості обслуговування, прогнозувати потенційні зони деградації, оптимізувати параметри радіодоступу та транспортного ядра. У мобільних мережах, де поведінка трафіку сильно залежить від мобільності населення, предиктивний аналіз QoE дозволяє операторам ефективно управляти ресурсами, зменшувати ймовірність перевантаження та підвищувати стабільність мережевих сервісів.

У довгостроковій перспективі впроваджена модель може бути масштабована до рівня стратегічного управління мережею, доповнена генеративними моделями для симуляції складних сценаріїв, інтегрована у системи динамічного керування політиками та використана для оптимізації тарифної політики на основі аналізу поведінки користувачів. Поєднання прогнозного, діагностичного та оптимізаційного модулів формує базу для створення самокерованих мереж майбутнього, здатних до автономної адаптації та самостійного відновлення.

Узагальнюючи викладене, практичні рекомендації щодо впровадження та масштабування комбінованої моделі штучного інтелекту свідчать про

необхідність дотримання комплексного та системного підходу, який охоплює управління даними, обчислювальними ресурсами, операційними процесами, безпекою та стратегічним плануванням. Лише за таких умов модель зможе повною мірою реалізувати свій потенціал у телекомунікаційній інфраструктурі, забезпечуючи високу точність прогнозів, ефективне виявлення аномалій та автономне управління мережевими ресурсами, що є ключовим для розвитку систем зв’язку нового покоління.

ВИСНОВКИ

Дослідження охопило наукові, теоретичні, методологічні та практичні сторони застосування штучного інтелекту для покращення телекомунікаційних систем. Воно виявило можливості інтелектуальних моделей та специфіку їх впровадження у мережі. У результаті аналізу теоретичних засад функціонування систем штучного інтелекту було встановлено, що їхня роль у процесах оптимізації невпинно зростає та набуває стратегічного значення в умовах інтенсивного розвитку цифрової інфраструктури, збільшення обсягів даних та

ускладнення архітектури мереж зв’язку Це можливо тому, що штучний інтелект може обробляти великі обсяги складних даних, знаходити неочевидні закономірності, робити передбачення та самостійно приймати рішення в реальному часі. Теоретичне опрацювання основних моделей штучного інтелекту показало, що саме поєднання машинного навчання, еволюційних методів і глибинних нейронних мереж створює умови для виникнення нових форм оптимізаційних механізмів, що здатні успішно функціонувати у високовартісних, нестабільних та критично важливих інфраструктурах.

У другій частині роботи ми вивчили сучасні алгоритми покращення, зосереджуючись на генетичних алгоритмах, підходах машинного навчання та різних типах нейронних мереж. Результати аналізу вказують на те, що генетичні алгоритми добре підходять для глобального пошуку та налаштування параметрів, але вимагають багато обчислень і можуть не завжди швидко сходитися. Звичайні методи машинного навчання точні у класифікації та регресії, однак гірше пристосовуються до мінливих умов з великою мінливістю поведінки системи. На противагу цьому, глибокі нейронні мережі показали найвищу продуктивність через їхню здатність моделювати нелінійні процеси, обробляти часові ряди та знаходити складні аномалії. Це робить їх особливо придатними для телекомунікаційних мереж нового покоління. Ці характеристики були вирішальними при виборі моделі для практичної частини дослідження.

Здійснений аналіз існуючих інструментів та рішень штучного інтелекту у вибраній предметній області показав, що сучасні телекомунікаційні системи активно інтегрують AIOps-підходи, системи прогнозування навантажень, моделі класифікації трафіку, автоенкодери для виявлення аномалій та комплексні інтелектуальні модулі для автоматизації процесів управління мережею. Було виявлено, що, попри значний прогрес, галузь стикається з низкою обмежень: відсутністю достатньої кількості якісних даних, складністю інтеграції моделей у застарілі системи, проблемами прозорості та інтерпретованості алгоритмів, а також високими вимогами до обчислювальних ресурсів. Аналіз підтвердив, що найперспективнішими є моделі, здатні одночасно виконувати прогнозні,

діагностичні та оптимізаційні функції, що потребує комплексного підходу до побудови архітектури моделі.

Обґрунтування вибору моделі штучного інтелекту стало одним із ключових етапів роботи. Вивчаючи специфіку телекомунікаційного середовища та динаміку процесів, було визначено, що оптимізаційна модель повинна мати здатність до роботи з багатовимірними даними, бути стійкою до шумів та неповноти телеметрії, а також забезпечувати підтримку прогнозних і діагностичних задач. Саме тому було обрано комбіновану модель, яка поєднує глибинну нейронну мережу для прогнозування навантаження та автоенкодер для виявлення аномалій. Таке поєднання забезпечує багаторівневий аналіз телеметрії, стабільність прийняття рішень та можливість адаптації до різних сценаріїв роботи мережі.

На основі теоретичних і аналітичних висновків було розроблено та реалізовано модель оптимізації, орієнтовану на підвищення ефективності управління телекомунікаційною інфраструктурою. Архітектура моделі включала блоки збору та нормалізації даних, прогнозний модуль на основі DNN, аналітичний модуль для виявлення аномалій та підсистему оцінки результатів. Реалізація була виконана в середовищі Python із використанням бібліотек TensorFlow, Scikit-Learn та Pandas, що забезпечило високу гнучкість, масштабованість та можливість адаптації моделі до різних типів даних. Особливу увагу було приділено попередній підготовці даних, оскільки саме якість і повнота вхідних параметрів значною мірою визначають фінальний результат роботи інтелектуальної системи.

Моделювання, експериментальні перевірки та тестування моделі дозволили оцінити її ефективність, визначити сильні сторони та межі застосовності. Було встановлено, що модель демонструє високу точність прогнозування навантаження як у короткострокових, так і середньострокових горизонтах, забезпечуючи достовірність прогнозів на рівні понад 90 %. Модуль виявлення аномалій продемонстрував високу чутливість і специфічність, що підтверджується значеннями Precision, Recall та F1-score, які перевищують показники традиційних алгоритмів, таких як One-Class SVM та Isolation Forest.

Це свідчить про здатність моделі не лише фіксувати нестандартні події, але й інтерпретувати поведінку трафіку у складних сценаріях, що є ключовим для забезпечення стабільної роботи мережевих сервісів.

Останнім етапом дослідження стало формування практичних рекомендацій щодо впровадження та масштабування моделі в реальних операційних процесах. Було визначено, що впровадження ШІ повинно здійснюватися поетапно, з урахуванням вимог до якості даних, особливостей мережевої інфраструктури та рівня готовності операторів до автоматизації. Запропоновано розгортання моделі у тестових середовищах, використання «тіньового режиму», інтеграцію з платформами AIOps, забезпечення механізмів інтерпретованості рішень, створення кіберзахисних контурів для моделі та організацію регулярного перенавчання з урахуванням нових патернів поведінки мережі. Також визначено перспективи масштабування моделі за рахунок використання edge-архітектур, федеративного навчання та симуляторів для прогнозування сценаріїв у мережах 5G/6G.

Таким чином, дипломна робота досягла поставленої мети, виконала всі визначені завдання та продемонструвала, що застосування технологій штучного інтелекту може стати ключовим чинником у підвищенні ефективності, адаптивності та надійності сучасних телекомунікаційних систем. Запропонована модель показала високу результативність і може бути використана як основа для створення самокерованих мереж майбутнього, здатних до автономного аналізу, прогнозування та оптимізації роботи в умовах стрімкого зростання складності цифрових інфраструктур.