

УДК 004.891:621.391

DOI: 10.31673/2412-9070.2026.017414

О. М. ТКАЛЕНКО, канд. техн. наук, доцент;

ORCID: 0000-0001-6313-5138

Д. А. БОНДАРЕНКО, аспірант;

ORCID: 0009-0005-0197-4493

В. М. МЕЖІНСЬКИЙ, студент;

ORCID: 0009-0006-7334-9467

Д. В. БІЛИЙ, студент,

ORCID: 0009-0001-4755-6140

Державний університет інформаційно-комунікаційних технологій, Київ

## ПОРІВНЯЛЬНИЙ АНАЛІЗ АЛГОРИТМІВ МАШИННОГО НАВЧАННЯ ДЛЯ КЛАСИФІКАЦІЇ СЕРВІСІВ У МЕРЕЖАХ LTE/5G НА ОСНОВІ QoS ПАРАМЕТРІВ

*У статті розглянуто задачу автоматичної класифікації типів сервісів у мобільних мережах LTE/5G на основі ключових параметрів якості обслуговування (QoS). Для проведення дослідження сформовано імітаційний набір даних, що відображає показники пропускну здатності, затримки, джитера, втрат пакетів та співвідношення прямого та зворотного трафіку для різних класів сервісів (URLLC, eMBB, mMTC), із введенням шумових спотворень та випадкових помилок у мітках для більшої наближеності до реальних умов мереж.*

*Проведене порівняння таких моделей машинного навчання як логістичної регресії, методу опорних векторів із лінійною та радіально-базисною функцією ядра, випадкового лісу, k-найближчих сусідів, наївного байєсівського класифікатора та дерева рішень. Виконано оцінку ефективності моделей машинного навчання за точністю класифікації на тестовому наборі даних, результати представлено у вигляді графічного порівняння з відображенням діапазонів Assurance.*

*Різні алгоритми машинного навчання демонструють свою ефективність в залежності від характеру даних, рівня зашумленості та нелінійності залежностей між параметрами мережі. Це обумовлює необхідність порівняльного аналізу моделей класифікації з метою вибору найбільш придатних рішень для практичного застосування у мережах LTE/5G.*

**Ключові слова:** машинне навчання; набір даних; пропускну здатність; ML-модель; аналіз мережного трафік; алгоритми класифікації; якість обслуговування; оптимізація мережних ресурсів; тип сервісу.

### Вступ

**Постановка проблеми.** Сучасні мобільні мережі LTE та 5G обслуговують різноманітні сервіси, серед яких відеострімінг, голосові та інтерактивні застосунки, що мають різні вимоги до параметрів якості обслуговування (QoS) - затримки, джитера, пропускну здатності, втрат пакетів, рівня сигналу та відношення сигнал/завади. Забезпечення гарантованого QoS для кожного типу сервісу стає критичною задачею, особливо за умов зростання обсягів зашифрованого трафіку, коли традиційні методи ідентифікації сервісів за аналізом вмісту пакетів виявляються неефективними.

Виникає необхідність розробки методів автоматичної класифікації типів сервісів на основі непрямих параметрів QoS, що дозволить ефективно управляти ресурсами мережі та забезпечувати оптимальний рівень обслуговування без аналізу вмісту трафіку.

Наукова значущість проблеми полягає у виявленні ефективних алгоритмів машинного навчання, здатних працювати з нелінійними, шумними та даними QoS, що перекриваються, а також у порівняльному аналізі їх точності та стабільності. Практична значущість вирішеної

задачі полягає в тому, що запропоновані підходи дозволять інтегрувати інтелектуальні моделі у системи управління мобільною мережею для автоматичної ідентифікації типів сервісів, оптимального розподілу ресурсів, пріоритетизації трафіку та підтримки гарантованого QoS для критичних сервісів.

**Аналіз останніх досліджень і публікацій.** Сучасні дослідження в галузі класифікації мережного трафіку та застосування машинного навчання підкреслюють актуальність пошуку ефективних методів для автоматичного визначення типів сервісів та забезпечення якості обслуговування у телекомунікаційних системах. Зокрема, низка робіт присвячена класифікації мережного трафіку з використанням алгоритмів машинного навчання, де автори розглядають завдання класифікації як спосіб підвищення ефективності обробки, виявлення аномалій та управління трафіком у складних середовищах передавання даних - від комп'ютерних мереж до мобільних систем зв'язку [1]. У публікаціях досліджується інтеграція машинного навчання з архітектурами SDN для оптимізації QoS і адаптації до динаміки мережного трафіку, що демонструє можливості побудови високоефективних класифікаторів у розподілених мережах [2]. Також зростає інтерес до розробки гібридних підходів, які поєднують класифікацію з передбаченням трафіку для покращення якості обслуговування у бездротових мережах [3].

У роботах, що розглядають класифікацію зашифрованого трафіку, показано, що машинне навчання дозволяє ефективно розпізнавати поведінкові патерни навіть при відсутності доступу до корисного навантаження пакетів, що є важливою передумовою для застосування таких методів у сучасних 4G/5G-середовищах [4].

Запропоноване дослідження узгоджується із світовими тенденціями, водночас робить акцент на порівняльному аналізі алгоритмів класифікації типів сервісів у мобільних мережах на основі параметрів QoS, що є недостатньо висвітленою темою у поточній науковій літературі.

**Метою статті** є розробка та порівняльний аналіз моделей машинного навчання для класифікації типів сервісів у мобільних мережах на основі параметрів якості обслуговування (QoS). Стаття спрямована на обґрунтований вибір найбільш ефективних методів машинного навчання для автоматичної класифікації типів сервісів у сучасних мобільних мережах, що є важливим для підвищення якості обслуговування користувачів та оптимізації розподілу ресурсів.

### *Основна частина*

Сучасні мобільні мережі LTE та 5G характеризуються великою кількістю типів сервісів (VoIP, відео, потокове аудіо, IoT, eMBB, URLLC, mMTC), динамічними умовами мережі, де QoS-параметри (Throughput, Latency, Jitter, Packet Loss, DL/UL) постійно змінюються через навантаження, перешкоди та мобільність користувачів; високою взаємозалежністю параметрів, де один і той же сервіс може мати різні QoS-профілі залежно від часу, місця, радіоканалу та призначення ресурсів [2, 4]. У таких умовах традиційні методи правил/порогів (rule-based classification) стають малоефективними адже неможливо задати точні порогові значення для всіх комбінацій QoS й ручне налаштування правил швидко застаріває при зміні мережі або додаванні нових сервісів.

URLLC (Ultra-Reliable Low-Latency Communications) - критично важливі сервіси з високими вимогами до надійності та низьких затримок, які характеризуються затримкою  $\leq 1-10$  мс, високою надійністю, швидкою доставкою. eMBB (Enhanced Mobile Broadband) - сервіси з високою пропускну здатністю та великим обсягом трафіку, які мають високу пропускну здатність, забезпечують стабільний широкопasmовий доступ (потокове відео, відеоконференції, VR/AR, завантаження великих файлів). Для масового підключення IoT-пристроїв використовується сервіс mMTC (Massive Machine Type Communications), який характеризується великою кількістю одночасних підключень, низькими вимогами до затримок та пропускну здатності та оптимізованим енергоспоживанням для пристроїв. Деякі стандарти 5G виділяють гібридні або розширені класи, такі як eURLLC - розширений URLLC з підвищеною пропускну здатністю; Critical IoT - IoT-пристрої, що потребують низьких затримок та високої надійності. Три голов-

них класи (URLLC, eMBB, mMTC) покривають практично всі реальні сценарії LTE/5G і достатньо різні за QoS-параметрами, щоб перевірити ефективність алгоритмів ML (рис. 1).

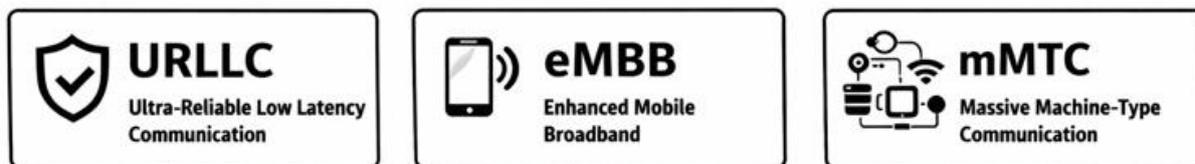


Рис. 1. Основні класи сервісів у мережах LTE/5G

Алгоритми машинного навчання дозволяють автоматично виявляти залежності між QoS-параметрами та класами сервісів, обробляти високовимірні дані, де одночасно беруться до уваги декілька показників, враховувати нелінійні взаємозв'язки (наприклад, взаємодія пропускної здатності та джитера при визначенні сервісу відео чи URLLC). Це є особливо актуальним так як лінійні алгоритми, такі як Logistic Regression, Linear SVM швидко визначають базові патерни, а нелінійні й ансамблеві алгоритми (RBF SVM, Random Forest) захоплюють складні закономірності QoS-параметрів, що дозволяє точніше класифікувати сервіси в умовах перекриття класів.

У реальних мережах QoS-дані завжди містять шум (флуктуації каналу, вимірювальні помилки). Також існують помилки маркування, коли система або оператор некоректно визначає тип сервісу. Алгоритми машинного навчання можуть бути стійкими до таких похибок, особливо ансамблеві методи (Random Forest, Gradient Boosting); здатні оцінювати ймовірність належності до класу, а не робити суворо детерміноване рішення; дозволять зробити адаптивну класифікацію, тобто модель можна буде повторно навчати на нових даних без повного перепишування правил.

Системи QoS/QoE та network slicing потребують швидкої та автоматичної класифікації сервісів для управління ресурсами радіоінтерфейсу, пріоритетизації критичних сервісів (URLLC), динамічного балансування навантаження. Машинне навчання дозволить навчати модель один раз і швидко робити передбачення для нових сеансів. Машинне навчання також дозволить інтегруватися в інтелектуальні системи управління мережею (SDN/NFV, RAN intelligent controller, 5G core).

Класичні алгоритми на основі правил потребують постійного ручного переналаштування, а машинне навчання легко адаптується до нових сервісів, якщо є хоча б невелика кількість нових даних; може навчатися без повного оновлення системи, що знижує витрати на експлуатацію мережі; підійде для передбачуваного прогнозування QoS, що є важливим для QoE-контролю.

Алгоритми машинного навчання є актуальними та необхідними для класифікації сервісів у LTE/5G, оскільки вони автоматизують процес, враховують складні та нелінійні взаємозв'язки QoS-параметрів, стійкі до шуму та помилок, легко інтегруються у сучасні системи управління мережею та дозволяють адаптуватися до нових сервісів і сценаріїв [8].

QoS (Quality of Service) у мобільних мережах 4G/LTE та 5G відіграє важливу роль, оскільки забезпечує контроль і гарантії якості обслуговування різних сервісів. Якість обслуговування QoS визначає, скільки ресурсу радіоінтерфейсу виділяється конкретному користувачу або сервісу - це дозволяє забезпечити стабільну швидкість передавання даних навіть при високому навантаженні мережі. Наприклад, потокове відео (eMBB) отримує достатню пропускну здатність для плавного відтворення. QoS дозволяє пріоритетизувати трафік із низькими затримками - це критично для URLLC-сервісів, де затримка не повинна перевищувати кілька мілісекунд. QoS визначає максимально допустимий рівень втрат пакетів для різних сервісів, що важливо для сервісів, які чутливі до помилок, наприклад, відеоконференцій або передавання команд керування.

У мережі одночасно можуть працювати сервіси з різними вимогами: URLLC, eMBB, mMTC. QoS дозволяє визначати, який трафік пріоритетніший, щоб критичні сервіси отримували ресурси у першу чергу. Наприклад, під час піку навантаження на базову станцію, URLLC-

трафік отримує пріоритет перед eMBB. QoS дозволяє балансувати мережеві ресурси, запобігаючи перевантаженню та зниженню якості для інших користувачів. Мережа може автоматично регулювати передавання даних, адаптуючи ресурси під поточні умови.

Порівняння сервісів LTE/5G за ключовими QoS-параметрами приведене у таблиці.

#### Порівняльна характеристика сервісів мобільних мереж LTE/5G за QoS-параметрами

№ п/п	Сервіс	Throughput, Мбіт/с	Latency, мс	Jitter, мс	Packet loss, %	DL/UL характер	Типове застосування
1	VoIP	0.05–0.1	≤ 100	≤ 30	≤ 1	Симетричний	Голосові дзвінки, VoLTE
2	Відео (streaming)	5–25	≤ 150	≤ 50	≤ 1	Переважно DL	Відеострімінг, OTT-сервіси
3	Потокове аудіо	0.1–0.5	≤ 200	≤ 50	≤ 2	Переважно DL	Онлайн-радіо, музичні сервіси
4	ІоТ (загальний)	< 1	100–1000	Не критичний	≤ 5	Переважно UL	Датчики, телеметрія
5	eMBB	100–1000+	10–50	≤ 20	≤ 0.1	DL-домінуючий	Відео, AR/VR, великі дані
6	URLLC	1–50	≤ 1–5	≤ 1	≤ 0.001	Симетричний	Критичні сервіси, керування
7	mMTC	< 0.1	100–1000	Не критичний	≤ 10	UL-домінуючий	Масовий ІоТ

У 5G QoS використовується для вирізання віртуальних мереж (network slices), кожна з яких обслуговує окремі класи сервісів із визначеними QoS-параметрами. Це дозволяє одночасно забезпечувати високошвидкісні послуги, масові ІоТ-з'єднання та критично важливі сервіси на одній фізичній інфраструктурі. QoS-параметри (Throughput, Latency, Jitter, Packet Loss, DL/UL) є ключовими ознаками для алгоритмів ML, що визначають тип сервісу. Аналіз QoS дозволить не тільки підтримувати якість обслуговування, але й автоматично класифікувати трафік, прогнозувати проблеми та оптимізувати ресурси.

Отже, якість обслуговування QoS у мобільних мережах 4G/5G є інструментом забезпечення надійності, передбачуваності та ефективності обслуговування різних класів сервісів. Вона дозволяє гарантувати мінімальні затримки і втрати, забезпечувати потрібну пропускну здатність, пріоритезувати критично важливий трафік, інтегрувати різні сервіси на одній мережевій інфраструктурі через network slicing і є основою для класифікації сервісів за допомогою алгоритмів ML.

Основні компоненти QoS у мобільних мережах:

- пропускну здатність (throughput) - швидкість передавання даних у мережі. Вимірюється у Мбіт/с або Гбіт/с й є важливою для сервісів з великими обсягами даних (відео, стрімінг);
- затримка (latency) - час, який потрібен пакету для надходження від джерела до отримувача. Вимірюється у мілісекундах (мс). Затримка є критичною для URLLC-сервісів (наприклад, автономне керування, телемедицина);
- джитер (Jitter) - відхилення у часі доставки пакетів. Високий джитер може погіршити якість відео або голосових сервісів;
- втрати пакетів (Packet Loss) - частка пакетів, які не досягли отримувача. Високі втрати погіршують стабільність і точність сервісів, особливо чутливих до помилок;
- співвідношення Downlink / Uplink (DL/UL) - баланс між завантаженням каналу для прийому і відправлення даних. Є важливим для додатків із асиметричними потребами (стрімінг vs. відеодзвінок).

Вказаний набір показників і правил визначає, наскільки добре мережа виконує завдання конкретного сервісу і саме ці параметри доцільно використовувати для класифікації сервісів у ML-моделях у даній статті. У дослідженні нижче доведено, чому саме ці параметри є інформативними для класифікації сервісів.

Різні сервіси мають різні вимоги до обсягу передаваних даних:

- eMBB: високі значення пропускної здатності для потокового відео, VR/AR;
- URLLC: низькі обсяги даних, але критична швидкість доставки;
- mMTC: малі обсяги, рідкісні передавання сенсорних даних.

Алгоритм ML зможе легко розрізнити сервіси за характерними діапазонами пропускної здатності. Через широкий діапазон значень для eMBB і вузький для URLLC/ mMTC, пропускна стає сильною ознакою для розділення класів.

URLLC-сервіси характеризуються низькими затримками, тоді як eMBB або mMTC допускають більшу затримку. Latency дозволяє ML-моделі розпізнати критично важливі сервіси. Цей параметр особливо ефективний для розділення URLLC та інших класів, де різниця у вимогах до часу передавання є суттєвою.

Високий джитер погіршує якість поточних сервісів (голос, відео), але мало впливає на малі IoT-пакети (mMTC). Jitter дозволяє ML-моделі визначити тип сервісу, орієнтуючись на стабільність передавання пакетів. Наприклад, URLLC очікує низький джитер, тоді як eMBB може мати середній рівень.

Критичні сервіси, такі як URLLC, чутливі до будь-яких втрат пакетів. Алгоритми ML можуть використовувати Packet Loss, щоб розрізнити сервіси, які допускають помилки (eMBB, mMTC) та сервіси, для яких будь-які втрати пакетів неприпустимі (URLLC). Високий Packet Loss у поєднанні з низьким Throughput і високою Latency часто вказує на перевантажені або малопродуктивні IoT-сервіси.

Сервіси відрізняються асиметрією трафіку:

- eMBB: більше Downlink (потокове відео);
- mMTC: невеликі пакети з переважним Uplink (сенсорні дані);
- URLLC: баланс залежить від застосунку.

DL/UL дозволяє ML-моделі визначити переважний напрям передавання даних і тип сервісу, особливо при схожих значеннях Throughput або Latency.

Слід зазначити, про комбінований ефект цих параметрів. Жоден параметр окремо не дозволяє точно класифікувати всі сервіси. Разом вони формують «QoS-профіль сервісу», який є унікальним для кожного класу (URLLC, eMBB, mMTC). ML-алгоритми здатні виявити комплексні закономірності та взаємозв'язки між цими параметрами, наприклад: низька Throughput + низька Latency + низький Jitter → URLLC; висока Throughput + середній Jitter + більші втрати → eMBB; низька Throughput + високий Packet Loss + маленький DL/UL → mMTC.

Через свою зв'язність із вимогами різних класів сервісів, числовий характер та вплив на якість обслуговування, QoS-параметри Throughput, Latency, Jitter, Packet Loss та DL/UL є найінформативнішими ознаками для класифікації сервісів у мобільних мережах. Вони дозволяють алгоритмам ML точно відокремлювати URLLC, eMBB та mMTC, оцінювати стабільність мережі та приймати рішення про управління ресурсами у реальному часі.

Для проведення дослідження було сформовано синтетичний набір даних, що моделює QoS-параметри трьох основних класів сервісів у мережах LTE/5G: URLLC, eMBB та mMTC. Кожен сеанс характеризувався п'ятьма ключовими параметрами: пропускна здатність (Throughput), затримка (Latency), джитер (Jitter), втрати пакетів (Packet loss) та співвідношення downlink/uplink (DL/UL). Загальна кількість сеансів склала 2100, при цьому дані були збалансовані між класами для забезпечення рівномірного представлення кожного сервісу.

Генерація даних здійснювалася із використанням функції випадкових чисел для кожного параметра у межах типових діапазонів, характерних для відповідного класу сервісів. Наприклад, URLLC-сервіси моделювалися з низькою пропускною здатністю, мінімальною затримкою та високою надійністю, eMBB - з високою пропускною здатністю та середніми затримками, а mMTC - з невеликими обсягами переданих даних та високим рівнем підключень. Цей підхід

дозволив створити реалістичні профілі сервісів та забезпечити різноманітність у даних для навчання моделей.

Щоб наблизити дані до реальних умов мереж, до всіх параметрів було додано випадковий шум, що імітує вимірвальні похибки, а також змодельовано 10% помилок у мітках класів сервісів. Такий підхід дозволяє оцінити стійкість алгоритмів машинного навчання до неточностей та некоректно маркованих даних.

Підготовка даних включала відокремлення ознак ( $X$ ) від міток класів ( $y$ ) та поділ на навчальну (70%) і тестову (30%) вибірки із застосуванням стратифікації, що забезпечує збереження пропорцій класів у обох підвибірках. Для усіх ознак було виконано стандартизоване масштабування (StandardScaler), що нормалізує дані до нульового середнього та одиничної дисперсії. Така нормалізація є критичною для алгоритмів, чутливих до масштабу ознак, таких як SVM чи Logistic Regression та забезпечує порівнянність результатів між різними моделями.

Отриманий набір даних представляє собою готову, збалансовану та масштабовану матрицю ознак і міток, яка використовується для навчання і тестування різних алгоритмів машинного навчання. Цей підхід дозволяє не тільки оцінити точність моделей, а й провести порівняльний аналіз їхньої стійкості до шуму та помилкових міток, що відображає реальні умови роботи LTE/5G мереж.

Для класифікації типів сервісів у мережах LTE/5G на основі QoS-параметрів було обрано різні алгоритми машинного навчання, що представляють різні підходи до моделювання даних: лінійні моделі, нелінійні ядрові методи, ансамблеві алгоритми, а також прості алгоритми на основі ймовірностей та схеми найближчих сусідів.

Лінійні алгоритми:

- Logistic Regression - класичний лінійний класифікатор, який моделює ймовірність належності об'єкта до класу на основі лінійної комбінації ознак;
- Linear SVM - метод опорних векторів із лінійним ядром, який шукає оптимальну гіперплощину для розділення класів.

Ці алгоритми прості в інтерпретації та ефективні для лінійно розділених даних, дозволяючи оцінити базову складність завдання класифікації QoS-сервісів. Вони служать еталоном для порівняння більш складних методів.

Нелінійні алгоритми:

- RBF SVM - метод опорних векторів із радіально-базисним (RBF) ядром, який здатний розпізнавати складні нелінійні залежності між параметрами QoS;
- Decision Tree - дерево рішень, яке будує послідовність правил для розділення класів за значеннями ознак, здатне моделювати нелінійні взаємозв'язки.

Ці алгоритми обиралися для оцінки того, наскільки складні закономірності QoS-параметрів впливають на точність класифікації. Дерева рішень добре працюють із змішаними та шумними даними, а RBF SVM забезпечує високу здатність до узагальнення для нелінійних кореляцій.

Ансамблевий алгоритм:

- Random Forest - ансамбль із багатьох дерев рішень із випадковим підбором ознак і даних для кожного дерева. Забезпечує високу точність, стійкість до шуму та перенавчання.

Ансамблевий метод обрано через його здатність покращувати узагальнення моделей і працювати з даними, що містять помилки або шум, що імітує реальні умови LTE/5G.

Алгоритми на основі схожості та ймовірності:

- K-Nearest Neighbors (KNN) - алгоритм на основі найближчих сусідів, який класифікує об'єкт залежно від класів його сусідів у багатовимірному просторі ознак;
- Naive Bayes - ймовірнісний класифікатор, який припускає незалежність ознак і використовує апостеріорні ймовірності для визначення класу.

Ці методи дозволяють оцінити ефективність простих підходів до класифікації, які не будуються на складних оптимізаційних процедурах, але часто демонструють високу швидкість та інтерпретованість.

Порівняння обраних алгоритмів є обґрунтованим з наступних причин. Обрані алгоритми належать до різних категорій (лінійні, нелінійні, ансамблеві, ймовірнісні, на основі схожості), що дозволяє оцінити, які підходи краще справляються з розпізнаванням QoS-профілів. У підготовленому наборі даних моделюється шум і 10% помилок у мітках. Ансамблеві та нелінійні методи можуть краще працювати в таких умовах, тоді як лінійні моделі і прості методи демонструють базові результати. Через різні діапазони параметрів для URLLC, eMBB та mMTC класифікація включає як лінійні, так і складні нелінійні закономірності. Порівняння дозволяє визначити, які моделі здатні враховувати ці взаємозв'язки. Різні алгоритми відрізняються швидкістю навчання, потребами в обчислювальних ресурсах і здатністю до узагальнення. Порівняння показує, які моделі оптимальні для реального застосування у мережному моніторингу.

Отже, для дослідження було обрано сім різних алгоритмів машинного навчання, що представляють різні підходи до класифікації. Таким чином, комплексний підбір алгоритмів забезпечує повну картину ефективності моделей машинного навчання для класифікації сервісів LTE/5G за QoS-параметрами, дозволяє оцінити їх точність, стійкість до шуму та обчислювальні характеристики, а також виявити оптимальні підходи для реального використання у мережних системах управління.

Моделі навчалися на масштабованій навчальній вибірці з використанням стандартних процедур `.fit()`. Після навчання здійснювалася прогнозна класифікація тестових даних і для кожної моделі обчислювалася точність (Accuracy) за формулою:

$$\text{Accuracy} = \frac{\text{кількість правильно класифікованих об'єктів}}{\text{загальна кількість об'єктів}} \quad (1)$$

Для оцінки варіативності результатів враховуються мінімальні та максимальні значення Accuracy, що дозволить оцінити стабільність моделей у присутності шуму та помилкових міток [3]. На основі отриманих показників Accuracy здійснювався порівняльний аналіз моделей, що дозволяє виявляти алгоритми з найвищою точністю класифікації; оцінити вплив нелінійних закономірностей QoS-параметрів на продуктивність моделей; виявити моделі, стійкі до шуму та помилкових міток; обґрунтувати доцільність застосування різних підходів у реальних мережних умовах.

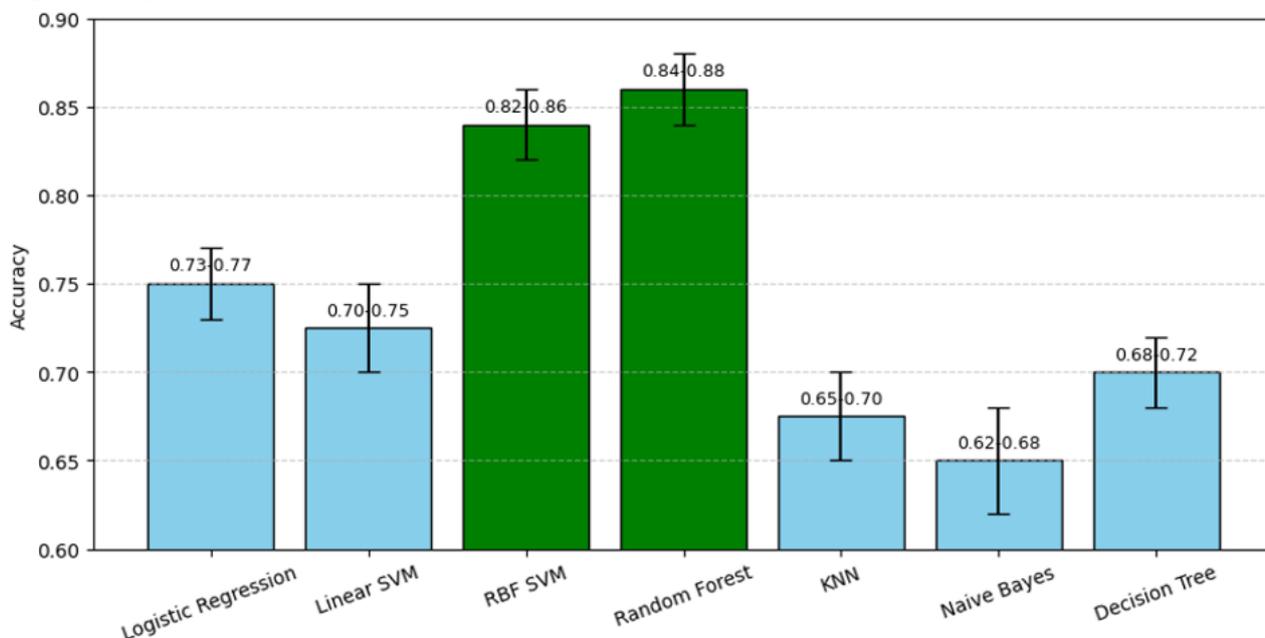


Рис. 2. Порівняльний аналіз моделей ML для класифікації типів сервісів

У результаті проведеного експериментального дослідження було отримано показники точності класифікації (Accuracy) для семи алгоритмів машинного навчання, застосованих до задачі розпізнавання типів сервісів LTE/5G на основі QoS-параметрів. Оцінювання виконувалося на тестовій вибірці, яка становила 30% від загального обсягу даних, із збереженням пропорцій класів за допомогою стратифікації.

Отримані результати демонструють суттєву різницю у здатності алгоритмів коректно ідентифікувати класи сервісів URLLC, eMBB та mMTC. Значення Accurasy для різних моделей знаходилися в діапазоні від 0.62 до 0.88, що свідчить про різний рівень ефективності обраних підходів. Найвищі середні значення точності були зафіксовані для Random Forest (0.84 – 0.88), SVM з RBF-ядром (0.82 – 0.86). Найнижчі результати продемонстрували Naive Bayes (0.62 – 0.68), K-Nearest Neighbors (KNN) (0.65 – 0.70). Лінійні моделі, такі як Logistic Regression та Linear SVM, показали середній рівень точності (0.70–0.77), що дозволяє використовувати їх як базовий орієнтир для оцінювання складності задачі.

### *Аналіз результатів за типами алгоритмів*

Logistic Regression та Linear SVM продемонстрували помірну точність класифікації. Це пояснюється тим, що QoS-параметри різних сервісів частково перекриваються, а їхні взаємозв'язки мають виражений нелінійний характер. Лінійні моделі здатні коректно розділяти лише прості границі між класами, тому їх ефективність обмежена в умовах шуму та помилок у мітках, які були змодельовані у наборі даних. Водночас отримані результати підтверджують, що базова класифікація сервісів можлива навіть без складних моделей, що є важливим для сценаріїв із обмеженими обчислювальними ресурсами.

SVM з RBF-ядром продемонстрував один із найкращих результатів серед усіх моделей. Це свідчить про те, що класи сервісів LTE/5G формуються складними нелінійними залежностями між параметрами Throughput, Latency, Jitter та Packet Loss. RBF SVM здатний ефективно формувати нелінійні межі розділення та зберігати високу узагальнюючу здатність навіть за наявності шуму. Decision Tree показує стабільні, але нижчі результати порівняно з RBF SVM і Random Forest. Обмеження глибини дерева дозволить уникнути перенавчання, але одиначне дерево поступається ансамблевим методам у здатності враховувати складні багатовимірні залежності.

Random Forest продемонстрував найвищу та найстабільнішу точність серед усіх досліджених алгоритмів. Поєднання великої кількості дерев рішень із випадковим відбором ознак дозволяє ефективно згладити вплив шуму та помилкових міток. Важливим є те, що Random Forest добре працює з корельованими QoS-параметрами, різними масштабами ознак, частковими перекриттями між класами сервісів. Це робить даний алгоритм одним із найбільш придатних для практичного застосування у системах моніторингу та управління мобільними мережами.

Naive Bayes продемонстрував найнижчу точність, що зумовлено порушенням припущення незалежності ознак. У реальних мережах QoS-параметри тісно пов'язані між собою (наприклад, Latency та Jitter), що суттєво знижує ефективність цього методу. KNN показав кращі результати, однак його продуктивність зменшується через чутливість до шуму, високу щільність даних у багатовимірному просторі, залежність від вибору кількості сусідів. Незважаючи на це, алгоритм KNN може використовуватися для швидкої попередньої оцінки належності сеансів до класів сервісів LTE/5G, а також як допоміжний метод для перевірки узгодженості результатів класифікації, отриманих більш складними моделями.

### *Висновки та перспективи*

Отримані результати дослідження показують, що ансамблеві та нелінійні моделі забезпечують найвищу точність і стабільність класифікації порівняно з іншими алгоритмами. Нелінійні та ансамблеві алгоритми перевершують лінійні моделі, що підтверджує складну природу QoS-залежностей у LTE/5G. Random Forest і RBF SVM є найбільш ефективними для класифікації сервісів при наявності шуму та помилкових міток. Простіші алгоритми можуть бути використані у системах із жорсткими вимогами до швидкодії, але з певною втратою точності. Отримані результати узгоджуються з практичними вимогами до інтелектуальних систем управління мережею, де важливими є як точність, так і стійкість моделей. Експериментально підтверджено, що параметри Throughput, Latency, Jitter, Packet Loss та DL/UL формують репрезентативний простір ознак для розпізнавання типів сервісів у мобільних мережах.

Практична значущість результатів дослідження полягає у можливості використання запропонованих методів для автоматичного визначення типів сервісів у реальних мережах LTE/5G, оптимізації розподілу ресурсів та підтримки гарантованого рівня QoS без аналізу вмісту трафіку. Використання ML дозволяє досліджувати ефективність різних алгоритмів у різних умовах QoS, оцінювати їх стійкість до шуму та перекриття класів, що додає цінність для наукових публікацій. Результати дослідження можна безпосередньо застосовувати у моніторингу, оптимізації та управлінні ресурсами LTE/5G, що робить дослідження корисним для операторів мереж і розробників мережного програмного забезпечення. Перспективи подальших досліджень полягають у застосуванні гібридних та глибоких моделей для підвищення стійкості класифікації до шуму та динамічних змін трафіку, а також в інтеграції цих моделей у системи реального часу для інтелектуального управління мобільними мережами.

### Список літератури

1. Serag R. H., Abdalzaher M. S., Elsayed H. A. A., Sobh M., Krichen M., Salim M. M. *Machine-learning-based traffic classification in software-defined networks* // *Electronics*. – 2024. – Vol. 13, No. 6. – Article 1108. – Режим доступу: <https://doi.org/10.3390/electronics13061108>
2. Глоба Л. С., Астраханцев А. А., Цуканов С. О. *Класифікація мережного трафіку методами машинного навчання* // *Проблеми телекомунікацій : електронне наукове фахове видання*. – 2023. – № 2 (33). – Режим доступу: <https://pt.nure.ua/authors/globa-l-s/>
3. Wang L., Yang M., Li B., Yan Z. *A method of combining traffic classification and traffic prediction based on machine learning in wireless networks* // *arXiv:2304.01590 [cs.NI]*. – 2023. – Режим доступу: <https://doi.org/10.48550/arXiv.2304.01590>
4. Huang Y.-F., Lin C.-B., Chung C.-M., Chen C.-M. *Research on QoS classification of network encrypted traffic behavior based on machine learning* // *Electronics*. – 2021. – Vol. 10, No. 12. – Article 1376. – Режим доступу: <https://doi.org/10.3390/electronics10121376>
5. Rahmayanti D. *Predicting quality of service on cellular networks using artificial intelligence* // *Jurnal Elektronika dan Energi Indonesia*. – 2023. – Vol. 5, No. 2. – Режим доступу: <https://doi.org/10.55606/jeei.v5i2.3901>
6. Gujarathi Y., Potekar Y. *Machine learning in network traffic analysis: Classification, optimization, and security* // *International Journal for Research in Applied Science and Engineering Technology*. – 2025. – Vol. 13, No. 4. – P. 455-459. – Режим доступу: <https://doi.org/10.22214/ijraset.2025.68216>
7. Gabilondo A., Fernandez Z., Viola R. *Traffic classification for network slicing in mobile networks* // *Electronics*. – 2022. – Vol. 11, No. 7. – Article 1097. – Режим доступу: <https://doi.org/10.3390/electronics11071097>
8. Mashragi A. M. *Utilizing hybrid machine learning models to predict quality of service (QoS) in multi-channel wireless networks* // *International Journal of Engineering Trends and Technology*. – 2022. – Vol. 70, No. 6. – P. 42-46. – Режим доступу: <https://doi.org/10.14445/22315381/IJETT-V70I6P205>
9. Melnyk V., Haleta P., Golphamid N. *Machine learning based network traffic classification approach for Internet of Things devices* // *Theoretical and Applied Cybersecurity*. – 2020. – Vol. 2, No. 1. – Режим доступу: <https://doi.org/10.20535/tacs.2664-29132020.1.209472>
10. Rezaei S., Kroencke B., Liu X. *Large-scale mobile app identification using deep learning* // *IEEE Access*. – 2019. – PP(99): 1-1. – Режим доступу: <https://doi.org/10.1109/ACCESS.2019.2962018>

O. Tkalenko, D. Bondarenko, V. Mezhinskyi, D. Bilyy

### COMPARATIVE ANALYSIS OF MACHINE LEARNING ALGORITHMS FOR CLASSIFICATION OF SERVICES IN LTE/5G NETWORKS BASED ON QoS PARAMETERS

The article considers the problem of automatic classification of service types in LTE/5G mobile networks based on key quality of service (QoS) parameters. The need for such classification arises

from the diverse requirements of modern mobile services, including Ultra-Reliable Low-Latency Communications (URLLC), enhanced Mobile Broadband (eMBB), and massive Machine-Type Communications (mMTC), which differ significantly in terms of throughput, latency, jitter, packet loss, and traffic patterns. To conduct the study, a simulated dataset was generated to realistically reflect the statistical characteristics of these parameters, including forward and reverse traffic ratios, and incorporating noise distortions and random label errors to better approximate real network conditions. This approach ensures that the experimental evaluation accounts for uncertainties and variations typical of operational LTE/5G environments.

A comparative analysis was carried out using several widely known machine learning models, including logistic regression, linear and radial basis function (RBF) support vector machines, random forest,  $k$ -nearest neighbors, naive Bayesian classifier, and decision tree. Each model was trained on a portion of the dataset and tested on the remaining samples to evaluate classification accuracy. The results of this analysis are presented graphically, highlighting the accuracy ranges of each algorithm and indicating that ensemble and kernel-based methods, particularly random forest and RBF SVM, outperform other approaches under the given experimental conditions. Different machine learning algorithms demonstrate their effectiveness depending on the nature of the data, the level of noise and the nonlinearity of the dependencies between network parameters. This necessitates the need for a comparative analysis of classification models in order to select the most suitable solutions for practical application in LTE/5G networks.

The study demonstrates that different machine learning algorithms exhibit varying performance depending on the nonlinearity of data, the presence of noise, and the overlapping characteristics of service classes. Accurate classification of service types based on QoS parameters is critical for effective network management, optimal resource allocation, and ensuring consistent quality of experience for end users. This underscores the importance of performing a comparative evaluation of multiple models to identify the most suitable algorithms for practical deployment in real LTE/5G networks. The findings of this research contribute to the development of intelligent network monitoring and management systems, providing guidance for future work in automated service classification and optimization in heterogeneous mobile networks.

**Keywords:** machine learning; dataset; bandwidth; ML-model; network traffic analysis; classification algorithms; quality of service; network resource optimization; service type.

---

Надійшла до редакції: 12.11.2025

Прийнята до друку: 19.12.2025

Опубліковано: 27.02.2026

© 2026 Ткаленко О. М., Бондаренко Д. А., Межінський В. М., Білий Д. В. Цей матеріал ліцензовано за умовами CC BY 4.0. <https://creativecommons.org/licenses/by/4.0>