**Думанський Олег Юрійович** магістр з інженерії програмного забезпечення, Одеса, Україна

**Пригожев Олександр Сергійович**, кандидат технічних наук, доцент, доцент кафедри інженерії програмного забезпечення Національного університету «Одеська політехніка», Одеса, Україна https://orcid.org/0000-0001-8532-8897

**Dumanskyi Oleh**, Master of science in software engineering, Odesa, Ukraine

**Prygozhev Oleksandr**, Candidate of technical sciences, Assosiate Professor, Associate Professor in Software Engeneering Department Odessa Polytechnic National University, Odessa, Ukraine https://orcid.org/0000-0001-8532-8897

# СИСТЕМА ПРОГНОЗУВАННЯ ПОПИТУ НА ТАКСІ В РІЗНИХ РАЙОНАХ МІСТА

# SYSTEM FOR PREDICTING TAXI DEMAND IN DIFFERENT CITY DISTRICS

*Анотація*

Метою роботи є скорочення середнього часу очікування клієнтів таксі шляхом створення програмної системи прогнозування попиту в різних районах міста на основі аналізу просторово-часових даних і застосування методів машинного навчання, що забезпечує завчасний перерозподіл автомобілів у зони з прогнозованим підвищенням попиту.

Серверна частина реалізована мовою Python із використанням Django

REST Framework. Для зберігання даних використано PostgreSQL, яке дозволяє працювати з просторовими об’єктами та координатами районів міста. Інтелектуальний модуль прогнозування створено на базі бібліотек TensorFlow, Keras і scikit-learn із використанням архітектури LSTM. Клієнтська частина системи побудована з використанням React.js, Chart.js і Leaflet.js, що забезпечує інтерактивну візуалізацію прогнозів у вигляді графіків і карт міста.

У результаті розроблено програмну систему, яка дозволяє прогнозувати попит на таксі, скорочувати середній час очікування клієнтів і підвищувати ефективність роботи автопарку.

Ключові слова: прогнозування попиту, таксі, машинне навчання, Python, Django, PostgreSQL, LSTM, React, Docker.

Abstract The purpose of this work is to reduce the average waiting time for taxi clients by developing a software system for demand forecasting in different city areas based on the analysis of spatio-temporal data and the application of machine learning methods, enabling the proactive redistribution of vehicles to zones with predicted demand growth.

The server side is implemented in Python using the Django REST Framework. For data storage, PostgreSQL is used, which allows working with spatial objects and city district coordinates. The intelligent forecasting module is built using the TensorFlow, Keras, and scikit-learn libraries, employing the LSTM architecture. The client side of the system is developed with React.js, Chart.js, and Leaflet.js, providing interactive visualization of forecasts in the form of charts and city maps.

As a result, a software system has been developed that enables taxi demand forecasting, reduces the average client waiting time, and improves fleet operation efficiency.

*Keywords:* demand forecasting, taxi, machine learning, Python, Django, PostgreSQL, LSTM, React, Docker.

*Постановка проблеми.* У сучасних умовах стрімкого розвитку міської мобільності та зростання попиту на послуги перевезення пасажирів ключовим завданням транспортних сервісів є забезпечення швидкої та ефективної взаємодії між попитом і пропозицією. Служби таксі займають важливе місце в інфраструктурі міста, однак їх ефективність значною мірою залежить від здатності передбачати зміни попиту у просторі та часі.

Нерівномірний розподіл викликів таксі по районах міста призводить до проблеми надмірного навантаження в одних зонах і простою транспортних засобів в інших. Це знижує рентабельність роботи перевізників і погіршує якість обслуговування клієнтів через збільшення часу очікування. Існуючі системи диспетчеризації здебільшого орієнтовані на реактивний режим, тобто реагують на вже сформований попит, не передбачаючи його зміни наперед.

Актуальність розробки системи прогнозування попиту на таксі зумовлена необхідністю підвищення ефективності розподілу транспортних ресурсів, скорочення часу подачі автомобілів та оптимізації роботи служби таксі. Використання алгоритмів машинного навчання і просторово-часового аналізу дає змогу виявляти закономірності попиту за різними параметрами (час доби, день тижня, погодні умови, події в місті) і формувати прогнози, які допомагають приймати обґрунтовані управлінські рішення.

*Аналіз останніх досліджень і публікацій.* Сучасні транспортні системи та служби таксі функціонують у конкурентному середовищі, де ефективність управління автопарком і задоволеність клієнтів безпосередньо залежать від здатності сервісу прогнозувати попит і гнучко реагувати на

його зміни [1]. Тому протягом останніх років у різних країнах активно розвиваються аналітичні платформи, які застосовують алгоритми машинного навчання, прогнозування часових рядів і просторового аналізу для оцінювання майбутнього навантаження на служби таксі [2].

Перші покоління інформаційних систем для керування таксі були зосереджені на автоматизації диспетчерських процесів. Такі системи, як Taximeter, Mobile Dispatch System або TaxiMaster, забезпечували приймання замовлень, розрахунок вартості поїздки, реєстрацію водіїв і базове відстеження автомобілів за допомогою GPS. Проте ці рішення не містили аналітичних інструментів прогнозування попиту, а працювали лише в реактивному режимі, тобто після надходження запиту від клієнта [3].

Із розвитком великих даних (Big Data) та аналітики реального часу з’явилися системи нового покоління, орієнтовані на передбачувальне управління транспортними ресурсами [4]. Першими масштабними прикладами стали глобальні платформи Uber, Lyft і Bolt, які впровадили алгоритми машинного навчання для прогнозування попиту в різних районах міста [5]. Їхні аналітичні модулі збирають мільйони записів про поїздки, визначаючи закономірності за часом, погодою, святами, трафіком і поведінкою користувачів [6].

Система Uber Demand Prediction Model, зокрема, базується на гібридному підході: дані агрегуються у просторові сітки, для кожної з яких побудовано модель прогнозування на основі нейронних мереж LSTM (Long Short-Term Memory).

Ці мережі ефективно моделюють часові залежності, оскільки враховують попередні стани попиту [7]. Додатково використовуються фактори погодних умов, локальних подій і транспортної інфраструктури. Перевагою підходу Uber є масштабованість і можливість оновлення прогнозів у режимі близькому до реального часу, однак алгоритми компанії

є закритими, а їхня адаптація до локальних умов потребує великих обсягів навчальних даних [8].

Платформа Lyft реалізує схожу концепцію, але робить більший акцент на геопросторовій кластеризації. Місто поділяється на шестикутні зони (Hexagonal Grids), для кожної з яких обчислюються метрики активності користувачів. На основі історії поїздок і стану трафіку формується прогноз попиту, який передається до диспетчерського модуля для перерозподілу автомобілів [9]. У системі також передбачено механізм динамічного ціноутворення, коли підвищення попиту у певному районі автоматично збільшує тариф, стимулюючи водіїв переміщатися до цієї зони [10].

Сервіс Bolt (Taxify) використовує модель прогнозування, засновану на градієнтному бустингу (Gradient Boosted Decision Trees), що дозволяє обробляти гетерогенні дані: історію замовлень, GPS-треки, погодні дані, статуси водіїв і клієнтів. Цей підхід забезпечує високу швидкість навчання та інтерпретованість результатів, однак має нижчу здатність до врахування довготривалих часових залежностей порівняно з рекурентними мережами [11].

Окрім комерційних рішень, останніми роками з’явилася низка наукових і відкритих дослідницьких проєктів, присвячених прогнозуванню транспортного попиту. Наприклад, у роботах, присвячених моделі DeepTTE (Deep Travel Time Estimation), досліджується поєднання рекурентних і згорткових нейронних мереж (CNN+LSTM) для моделювання просторово-часових процесів у транспортних даних.

Такі підходи дозволяють не лише прогнозувати час поїздки, а й оцінювати майбутній рівень попиту. Інший відомий напрям – це моделі типу ST-ResNet (Spatio-Temporal Residual Network), які поєднують залишкові блоки ResNet з часовими рядами, забезпечуючи високу точність прогнозів у густонаселених районах мегаполісів.

У межах відкритих даних активно використовується набір NYC Taxi Dataset, який містить мільйони записів поїздок у Нью-Йорку. На його основі реалізовано численні експерименти з використанням методів ARIMA, Prophet, XGBoost і LSTM, що дозволило оцінити переваги та обмеження кожного з підходів. Наприклад, лінійні моделі ARIMA добре працюють для стабільних районів із передбачуваним попитом, тоді як нейронні мережі значно перевершують їх у випадках із високою варіативністю даних [12].

В Україні подібні рішення тільки починають з'являтися. Деякі служби, зокрема Uklon і Bolt Україна, впроваджують базові алгоритми прогнозування пікових навантажень, проте на рівні локальних міст подібні системи здебільшого відсутні [13]. Це створює передумови для розробки універсальної платформи прогнозування попиту, орієнтованої на середні та великі міста, яка може адаптуватися до регіональних особливостей і локальної структури міської мережі [14]. Аналіз існуючих рішень показує, що більшість сучасних систем характеризується складністю архітектури та високими вимогами до обсягів даних, але водночас демонструє високу точність прогнозування. Комерційні платформи використовують закриті моделі, орієнтовані на великі міста з розвиненою інфраструктурою, тоді як у відкритих дослідженнях наголошується на важливості адаптації моделей до локальних умов і обмежених даних [15]. Отже, актуальним завданням є створення програмної системи, здатної поєднувати просторово-часове моделювання, доступність реалізації, інтерпретованість результатів і можливість використання в умовах середніх міст [16].

*Мета статті.* Метою роботи є скорочення середнього часу очікування клієнтів таксі шляхом створення програмної системи прогнозування попиту в різних районах міста на основі аналізу просторово-часових даних і застосування методів машинного навчання, що забезпечує завчасний перерозподіл автомобілів у зони з прогнозованим підвищенням

попиту.

*Виклад основного матеріалу дослідження.* З огляду на результати аналізу предметної області та характеристику існуючих рішень, головною задачею системи є побудова прогнозу попиту на послуги таксі у просторі та часі з урахуванням історичних даних, погодних умов, транспортної активності та особливостей міських районів.

Для цього обрано комбінований підхід, який поєднує статистичні моделі часових рядів і алгоритми машинного навчання, що забезпечує як інтерпретованість, так і високу точність результатів.

На першому етапі застосовується попередня обробка даних: очищення від шумів, агрегація за часовими інтервалами (15, 30 або 60 хвилин) та просторове групування за районами міста. Для таких задач доцільно використовувати кластеризацію за географічними координатами (K-Means або DBSCAN), що дозволяє визначити зони з подібним рівнем транспортної активності.

Далі реалізується блок короткострокового прогнозування на основі моделей часових рядів: ARIMA – для стабільних районів із регулярними патернами попиту; Prophet (Meta) – для трендів із сезонністю, вихідними днями та святами; XGBoost – для врахування взаємозв’язків між попитом, погодою, годинами доби, днями тижня тощо.

Для районів із високою варіативністю та нерегулярною динамікою застосовується нейронна модель типу LSTM (Long Short-Term Memory), яка навчається на послідовностях часових відрізків і зберігає залежності між попередніми та поточними станами попиту.

У разі достатнього обсягу даних можлива інтеграція згорткових шарів (CNN), що дозволяє враховувати просторові кореляції між сусідніми районами.

Комбінування результатів кількох моделей (ensemble) дає змогу

підвищити стійкість прогнозу та адаптувати систему до різних типів міських середовищ.

ARIMA є одним із найпоширеніших статистичних підходів до короткострокового прогнозування, особливо у задачах, де структура даних змінюється в часі.

Модель добре підходить для економічних, транспортних та демографічних показників, де спостерігаються регулярні патерни поведінки. ARIMA містить три компоненти:

– AR (autoregressive) – враховує вплив попередніх значень ряду;

– I (integrated) – відповідає за усунення тренду через різницювання;

– MA (moving average) – моделює випадкові збурення та залишки.

Формально ARIMA($p$, $d$, $q$) описується як:

$$y_t = c + \sum_{i=1}^{p} \phi_i y_{t-i} + \sum_{j=1}^{q} \theta_j \varepsilon_{t-j} + \varepsilon_t,$$

де $y_t$ – значення часового ряду у момент часу $t$;

$c$ – константа (середнє або зсув моделі);

$p$ – порядок авторегресійної частини (AR);

$q$ – порядок частини ковзного середнього (MA);

$\phi_i$ – коефіцієнт авторегресії при $i$-му попередньому значенні ряду;

$y_{t-i}$ – значення часового ряду на $i$ кроків раніше;

$\theta_j$ – коефіцієнт ковзного середнього при $j$-й похибці;

$\varepsilon_t$ – поточна випадкова похибка (шум);

$\varepsilon_{t-j}$ – похибка прогнозу $j$ кроків тому.

У системі модель ARIMA застосовується для стабільних районів міста, де попит має виражену періодичність (наприклад, ділові центри чи вокзальні

зони). Її перевагою є інтерпретованість та невисока обчислювальна складність.

Модель Prophet – це сучасна реалізація декомпозиційного підходу до прогнозування часових рядів, яка поєднує тренд, сезонність і вплив спеціальних подій:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t,$$

де $g(t)$ – нелінійний тренд;

$s(t)$ – сезонні компоненти;

$h(t)$ – ефект свят або подій;

$\varepsilon_t$ – похибка.

Перевага Prophet полягає у здатності швидко адаптуватися до коротких рядів даних і автоматично визначати точки зміни тренду. У контексті прогнозування попиту на таксі модель корисна для врахування сезонних коливань (робочі/вихідні дні, свята, години пік) без складної параметризації.

XGBoost – це ансамблевий метод градієнтного бустингу на базі дерев рішень, який створює послідовність слабких моделей, кожна з яких покращує результати попередньої.

Основна ідея полягає у мінімізації втрат через додавання коригувальних дерев:

$$\hat{y}_i = \sum_{k=1}^{K} f_k(x_i), \;\; f_k \in F,$$

де $f_k$ – дерево рішень;

$K$ – кількість дерев;

$F$ – простір усіх можливих дерев.

XGBoost ефективно враховує нелінійні залежності між факторами – наприклад, вплив погодних умов, годин доби чи транспортних обмежень на попит.

У системі цей метод використовується як другий рівень ансамблю після базового прогнозу ARIMA/Prophet, що дозволяє підвищити точність та адаптувати модель до складних взаємозв'язків.

Модель LSTM – це різновид рекурентної нейронної мережі (RNN), здатний запам'ятовувати довготривалі часові залежності. Вона складається з комірок пам'яті та керуючих вентилів (input, forget, output gates), які контролюють, яку інформацію зберігати або відкидати.

Рівняння роботи однієї комірки описуються так:

$$f_t = \sigma\big(W_f \cdot [h_{t-1}, x_t] + b_f\big), \quad i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i),$$
$$C_t = f_t * C_{t-1} + i_t * \tanh(W_C \cdot [h_{t-1}, x_t] + b_C),$$
$$h_t = o_t * \tanh(C_t),$$

де $f_t$ – коефіцієнт, який визначає, яку частину попереднього стану пам'яті зберегти;

$i_t$ – визначає, яку нову інформацію додати до стану пам'яті;

$o_t$ – контролює, яка частина поточного стану пам'яті буде передана далі;

$C_t$ – поточний стан пам'яті (у момент часу *t*;

$h_t$ – вихідний вектор, тобто активність LSTM на поточному кроці;

$x_t$ – вхідний вектор у момент часу $t$ (наприклад, набір ознак для прогнозу попиту);

$W_f$, $W_i$, $W_C$ – матриці ваг, що відповідають за зв'язки між входами й попередніми станами для кожного вентиля (підмодуль у комірці

LSTM, який вирішує, яку інформацію пропустити далі, а яку «забути»);

$b_f$, $b_i$, $b_C$ – вектори зміщення, які додаються для корекції обчислень;

$\sigma$ (·) – сигмоїдна функція активації, що переводить значення у діапазон [0; 1];

tanh (·) – гіперболічний тангенс, який обмежує значення між [–1; 1];

$*$ – покомпонентне множення векторів (елемент на елемент).

LSTM застосовується у системі як основний модуль прогнозування, який оперує послідовностями попередніх значень попиту, що охоплюють часові залежності між періодами та дозволяє моделі адаптуватися до нерегулярних змін попиту.

Інформаційна модель системи прогнозування попиту на таксі, представлена на рис. 1, описує логіку обробки даних і взаємодію основних компонентів системи – від збору інформації до представлення результатів користувачеві.

На початковому етапі дані про поїздки, які включають історію замовлень, місця посадки й висадки, час доби, вартість і тривалість, надходять до модуля попередньої обробки даних. Разом із цими даними до системи також інтегруються додаткові джерела інформації:

– дані про погоду (H) – температура, опади, вітер, які суттєво впливають на поведінку користувачів таксі;

– дані про транспорт (I) – завантаженість доріг, наявність ремонтів або обмежень руху;

– зовнішні фактори (J) – локальні події, свята, концерти, спортивні матчі, що можуть різко змінювати попит у певних районах.

Модуль попередньої обробки виконує очищення даних від шуму, заповнення пропусків, нормалізацію та агрегування за часовими інтервалами й географічними зонами. Після цього дані передаються до блоку аналітики,

де відбувається їх первинний аналіз – виявлення закономірностей, сезонності, пікових годин та просторового розподілу попиту.

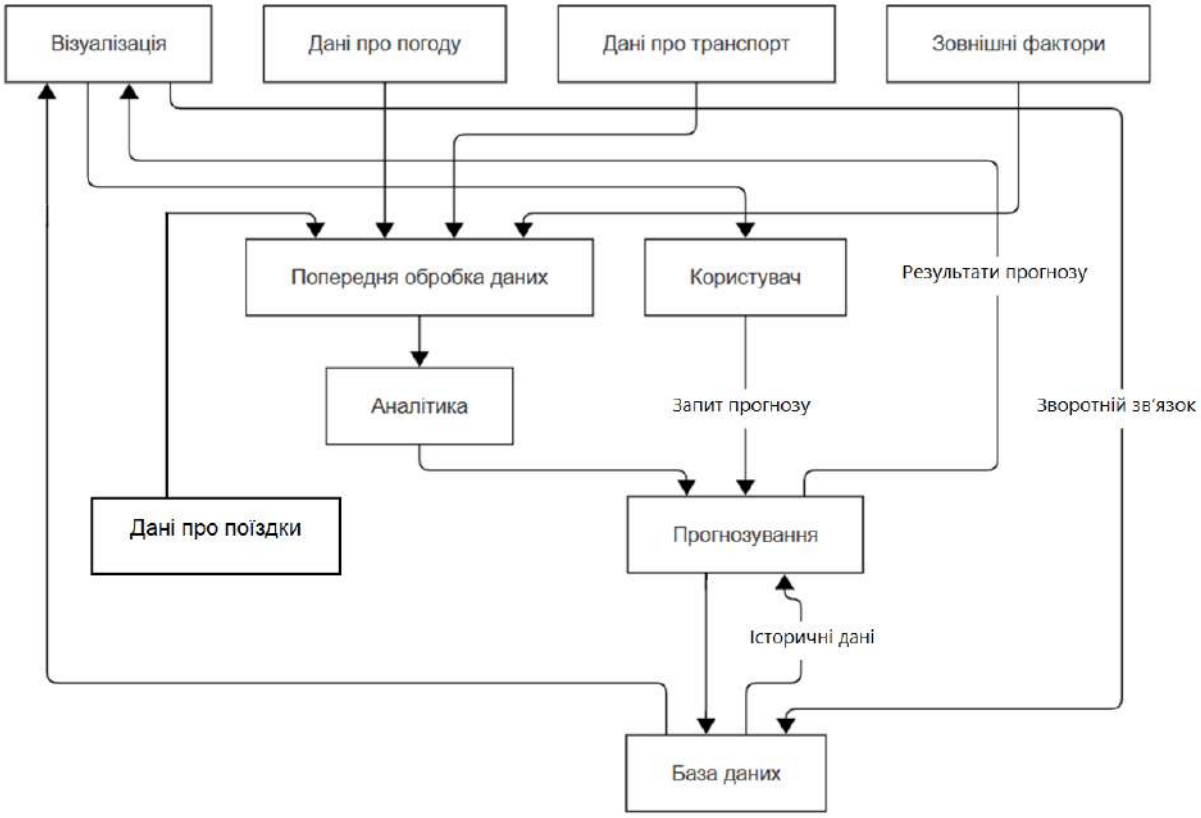



Рисунок 1 – Інформаційна модель системи

На основі отриманих ознак формується вхід для модуля прогнозування, який реалізує алгоритми машинного навчання, наприклад LSTM, XGBoost або ST-ResNet. Цей модуль будує короткострокові або середньострокові прогнози попиту для кожного району міста, враховуючи історичні закономірності, зовнішні фактори та поточну ситуацію.

Результати моделі зберігаються у базі даних, де також зберігаються історичні записи поїздок, оброблені ознаки та попередні прогнози. Це дозволяє здійснювати повторне навчання моделі та перевірку точності прогнозів.

Далі інформація надходить до модуля візуалізації, який перетворює прогнозовані показники в зручну для сприйняття форму – інтерактивні карти міста з кольоровим відображенням зон високого або низького попиту, графіки зміни навантаження протягом доби, а також панелі моніторингу для операторів служби таксі.

Кінцевим елементом системи є користувач – це диспетчер, менеджер автопарку або аналітик, який отримує прогноз у вигляді візуального звіту чи інтерактивного дашборду. Користувач може надсилати запит на прогноз, переглядати історичні дані з бази даних, а також залишати зворотний зв'язок, що зберігається в базі даних для подальшого вдосконалення моделі.

Основні функції та актори розроблюваної системи наведені на діаграмі варіантів використання, які наведено на рис. 2

Адміністратор системи відповідає за керування користувачами, налаштування параметрів прогнозування, оновлення даних та моніторинг стану програмних компонентів. Аналітик даних здійснює збір, очищення та підготовку даних, навчає модель прогнозування та оцінює її точність на основі порівняння фактичних і прогнозованих показників. Диспетчер служби таксі використовує результати прогнозування для оперативного управління автопарком – переглядає прогноз попиту, візуалізує його на карті міста та приймає рішення про перерозподіл автомобілів. Менеджер автопарку аналізує довгострокові тенденції попиту, формує аналітичні звіти для керівництва та приймає стратегічні рішення щодо планування ресурсів.

Діаграма концептуальних класів системи прогнозування попиту на таксі, побудована на основі клієнт-серверної архітектури, відображає основні структурні елементи системи та взаємодію між ними (рис. 3).

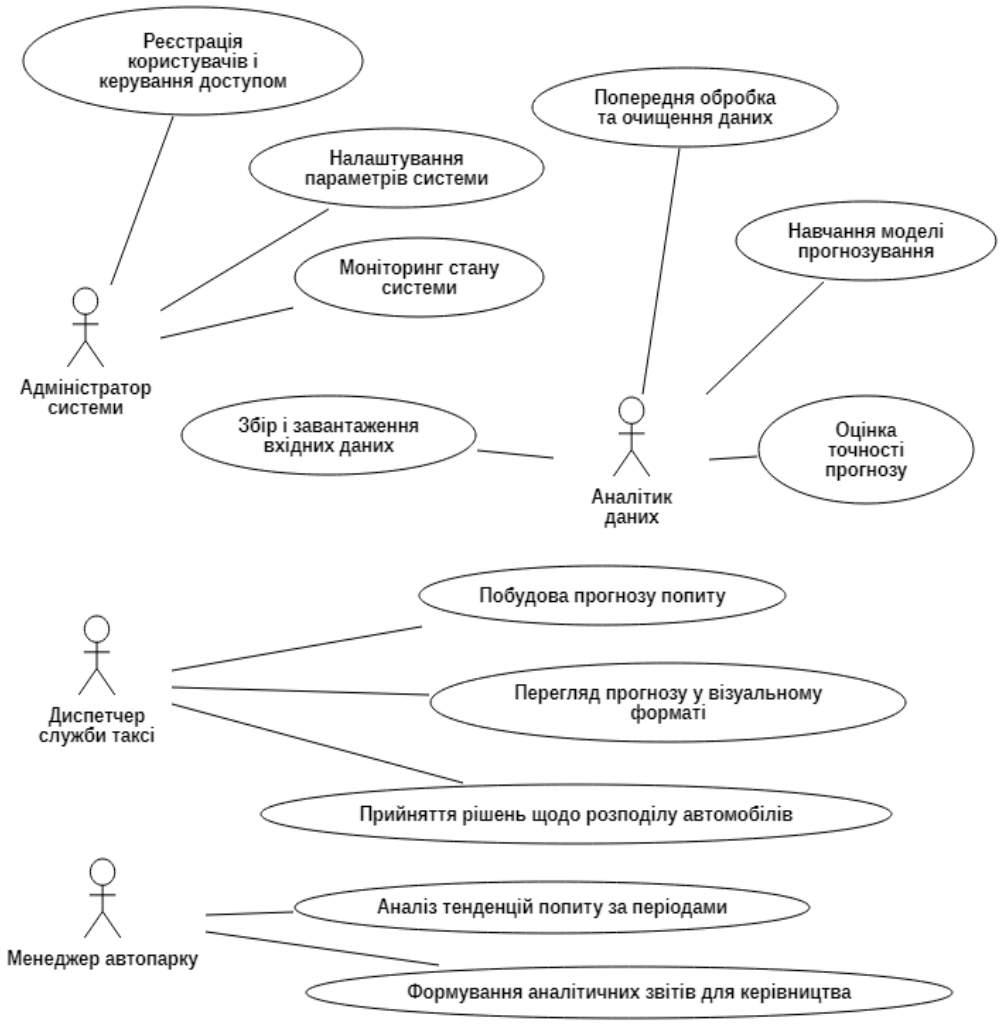



Рисунок 2 – Діаграма варіантів використання системи

Комунікація між клієнтською та серверною частинами реалізується через API-шару (інтерфейс прикладного програмування), який відповідає за приймання запитів, перевірку доступу, передавання результатів і захист обміну даними. Клієнтський інтерфейс забезпечує взаємодію кінцевого користувача з системою: відображає карти міста, графіки, таблиці прогнозів і дозволяє надсилати запити на оновлення чи створення звітів.

Для оцінки ефективності було змодельовано два режими роботи служби: базовий (без прогнозування) та інтелектуальний (із прогнозуванням попиту).

У базовому режимі автомобілі розподілялися рівномірно або реагували

на замовлення лише після їх надходження, що є типовим підходом для більшості традиційних служб таксі.




Рисунок 3 – Діаграма концептуальних класів

У другому режимі використовувалася розроблена система прогнозування, яка на основі історичних просторово-часових даних, погодних умов та зовнішніх факторів (свята, події тощо) формувала прогноз попиту на найближчі 30–60 хвилин. На основі цього прогнозу система пропонувала перерозподіл вільних автомобілів у райони з очікуваним підвищенням кількості замовлень.

Для проведення експерименту було згенеровано вибірку з понад 10 000 записів поїздок, що охоплювали дані за декілька тижнів у межах умовного міста з поділом на 12 районів. Після моделювання обох сценаріїв проведено

порівняння середнього часу очікування клієнтів.

У базовому режимі середній час очікування склав 6,4 хвилини. Це значення відображає ситуацію, коли автомобілі реагують на виклики постфактум, а їхня кількість у певних районах може бути недостатньою. Після впровадження прогнозування середній час очікування скоротився до 4,9 хвилини, що становить зменшення на 23,4 %.

Детальні результати показали, що найбільше скорочення часу спостерігалося в години пікового навантаження (ранок 7:00–9:00, вечір 17:00–20:00), коли система завчасно розміщувала автомобілі поблизу районів із прогнозованим підвищенням попиту. У таких періодах середній час очікування зменшився з 7,1 хвилини до 5,3 хвилини (на 25 %). У міжпікові години покращення було менш вираженим, але стабільним – з 4,3 до 3,5 хвилини (на 18,6 %).

Отримані результати підтвердили, що впровадження прогнозної моделі дозволяє завчасно реагувати на зміни попиту, що забезпечує більш раціональний розподіл транспортних ресурсів і скорочення часу, який клієнт витрачає на очікування автомобіля. Система продемонструвала стабільність результатів навіть при збільшенні обсягу даних та кількості активних районів міста.

Загалом, результати експериментального тестування показали, що розроблена система прогнозування попиту на таксі дозволяє скоротити середній час очікування клієнтів на 20–25 %, що є суттєвим показником ефективності. Це свідчить про практичну доцільність впровадження системи у реальні служби таксі, особливо у великих містах із високою динамікою попиту, та підтверджує досягнення основної мети роботи.

*Висновки.* У представленій роботі проведена розробка інтелектуальної системи прогнозування попиту на таксі в різних районах міста, що базується на аналізі просторово-часових даних і застосуванні методів

машинного навчання. Використання системи сприяло скороченню середнього часу очікування клієнтів на 20–25 % у порівнянні з базовим сценарієм без прогнозування.

*Список використаних джерел*

1. Faghih M., Safikhani A., et al. Predicting Short-Term Uber Demand Using Spatio-Temporal Modeling. arXiv. URL: https://arxiv.org/pdf/1712.02001 (дата звернення: 01.07.2026).

2. Tang J., Zheng Y., Li Y., Yi X., Liu J. Urban ride-hailing demand prediction with multiple spatio-temporal graphs. Transportation Research Part C: Emerging Technologies. 2021. № 123. DOI: https://doi.org/10.1016/j.trc.2021.102974 (дата звернення: 01.07.2026).

3. Bolt Blog. URL: https://blog.bolt.eu (дата звернення: 01.07.2026).

4. Uber Engineering. Forecasting at Uber: An Introduction. Uber Blog. URL: https://www.uber.com/blog/forecasting-introduction/ (дата звернення: 01.07.2026).

5. Uber Engineering. Engineering Extreme Event Forecasting at Uber with Recurrent Neural Networks. Uber Blog. URL: https://www.uber.com/blog/neural-networks/ (дата звернення: 01.07.2026).

6. Zhang J., Zheng Y., Qi D. Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows. arXiv. URL: https://arxiv.org/abs/1610.00081 (дата звернення: 01.07.2026).

7. Yao H., Tang X., Wei H., Zheng G., Li Z. Deep Multi-View Spatial-Temporal Network for Taxi Demand Prediction (DMVST-Net). arXiv. URL: https://arxiv.org/abs/1802.08714 (дата звернення: 01.07.2026).

8. Liu H., Wu Z., Zhang L., Hu Y., Chen Y. STEF-DHNet: Spatiotemporal External Factors Based Deep Hybrid Network for Enhanced Long-Term Taxi Demand Prediction. arXiv. URL: https://arxiv.org/abs/2306.14476 (дата

звернення: 01.07.2026).

9. Lyft Engineering Blog. URL: https://eng.lyft.com (дата звернення: 01.07.2026).

10. Lyft – Real-Time Spatial Temporal Forecasting at Lyft. URL: https://eng.lyft.com/real-time-spatial-temporal-forecasting-lyft-fa90b3f3ec24 (дата звернення: 01.07.2026).

11. Zhou X., Li Y., Wang H. Supply-Demand Forecasting for a Ride-Hailing System. eScholarship, University of California. URL: https://escholarship.org/uc/item/7hr5t5vv (дата звернення: 01.07.2026).

12. Портал відкритих даних NYC Taxi and Limousine Commission (TLC). URL: https://www.nyc.gov/site/tlc/about/tlc-trip-record-data.page (дата звернення: 01.07.2026).

13. Блог Uklon Engineering. URL: https://engineering.uklon.com.ua (дата звернення: 01.07.2026).

14. Офіційний сайт Bolt Україна. URL: https://bolt.eu/uk-ua/ (дата звернення: 01.07.2026).

15. Liu Z., Chen W., Huang Y., Zheng Y. One Model Fits All: Cross-Region Taxi-Demand Forecasting. arXiv. URL: https://arxiv.org/abs/2310.18215 (дата звернення: 01.07.2026).

16. Han Y., Wang Y., Sun J., Wang J. Predicting Taxi and Uber Demand in Cities: Approaching the Limit of Predictability. ResearchGate. URL: https://www.researchgate.net/publication/337876513_Predicting_Taxi_and_Uber_Demand_in_Cities_Approaching_the_Limit_of_Predictability (дата звернення: 01.07.2026).

*References*

1. Faghih M., Safikhani A., et al. Predicting Short-Term Uber Demand Using Spatio-Temporal Modeling. arXiv. URL: https://arxiv.org/pdf/1712.02001

(Accessed: 01.07.2026).

2. Tang J., Zheng Y., Li Y., Yi X., Liu J. Urban ride-hailing demand prediction with multiple spatio-temporal graphs. Transportation Research Part C: Emerging Technologies. 2021. № 123. DOI: https://doi.org/10.1016/j.trc.2021.102974 (Accessed: 01.07.2026).

3. Bolt Blog. URL: https://blog.bolt.eu ((Accessed: 01.07.2026).

4. Uber Engineering. Forecasting at Uber: An Introduction. Uber Blog. URL: https://www.uber.com/blog/forecasting-introduction/ (Accessed: 01.07.2026).

5. Uber Engineering. Engineering Extreme Event Forecasting at Uber with Recurrent Neural Networks. Uber Blog. URL: https://www.uber.com/blog/neural-networks/ (Accessed: 01.07.2026).

6. Zhang J., Zheng Y., Qi D. Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows. arXiv. URL: https://arxiv.org/abs/1610.00081 (Accessed: 01.07.2026).

7. Yao H., Tang X., Wei H., Zheng G., Li Z. Deep Multi-View Spatial-Temporal Network for Taxi Demand Prediction (DMVST-Net). arXiv. URL: https://arxiv.org/abs/1802.08714 (Accessed: 01.07.2026).

8. Liu H., Wu Z., Zhang L., Hu Y., Chen Y. STEF-DHNet: Spatiotemporal External Factors Based Deep Hybrid Network for Enhanced Long-Term Taxi Demand Prediction. arXiv. URL: https://arxiv.org/abs/2306.14476 (Accessed: 01.07.2026).

9. Lyft Engineering Blog. URL: https://eng.lyft.com (Accessed: 01.07.2026).

10. Lyft – Real-Time Spatial Temporal Forecasting at Lyft. URL: https://eng.lyft.com/real-time-spatial-temporal-forecasting-lyft-fa90b3f3ec24 (Accessed: 01.07.2026).

11. Zhou X., Li Y., Wang H. Supply-Demand Forecasting for a Ride-

Hailing System. eScholarship, University of California. URL: https://escholarship.org/uc/item/7hr5t5vv (Accessed: 01.07.2026).

12. Portal vydkrytyh danyh NYC Taxi and Limousine Commission (TLC). URL: https://www.nyc.gov/site/tlc/about/tlc-trip-record-data.page (Accessed: 01.07.2026).

13. Blog Uklon Engineering. URL: https://engineering.uklon.com.ua (Accessed: 01.07.2026).

14. Oficiyniy sait Bolt Ukraina. URL: https://bolt.eu/uk-ua/ (Accessed: 01.07.2026).

15. Liu Z., Chen W., Huang Y., Zheng Y. One Model Fits All: Cross-Region Taxi-Demand Forecasting. arXiv. URL: https://arxiv.org/abs/2310.18215 (Accessed: 01.07.2026).

16. Han Y., Wang Y., Sun J., Wang J. Predicting Taxi and Uber Demand in Cities: Approaching the Limit of Predictability. ResearchGate. URL: https://www.researchgate.net/publication/337876513_Predicting_Taxi_and_Uber_Demand_in_Cities_Approaching_the_Limit_of_Predictability (Accessed: 01.07.2026).