

DOI: <https://doi.org/10.15276/ict.02.2025.04>

УДК 004.85:339.187

Аналіз проблем створення ефективних адаптивних платіжних систем у середовищі сервісних платформ

Арсирій Олена Олександрівна¹⁾

Д-р техніч. наук, професор, завідувачка каф. Інформаційних систем

ORCID: <https://orcid.org/0000-0001-8130-9613>; e.arsiriy@gmail.com. Scopus Author ID: 54419480900

Бондар Віталій Юрійович¹⁾

Аспірант каф. Інформаційних систем

ORCID: <https://orcid.org/0000-0001-5173-0810>; bvitaly97@gmail.com

Руденко Олександр Володимирович¹⁾

Аспірант каф. Інформаційних систем

ORCID: <https://orcid.org/0009-0004-2944-4040>; alexo.rudenko@stud.op.edu.ua

¹⁾ Національний університет «Одеська політехніка», пр. Шевченка, 1. Одеса, 65044, Україна

АНОТАЦІЯ

Сучасні сервісні платформи, зокрема у сферах каршерінгу та оренди автомобілів, стикаються з викликом утримання клієнтів та максимізації прибутку через використання переважно статичних платіжних моделей. Традиційні підходи, такі як фіксована підписка або оплата за фактичне використання (pay-per-use), не враховують гетерогенність поведінки клієнтів, що призводить до зниження їхньої лояльності та втрати потенційного доходу. Це дослідження присвячене глибокому аналізу ключових науково-технічних проблем, що виникають при розробці адаптивних платіжних систем, здатних динамічно підлаштовувати тарифні плани під індивідуальні патерни поведінки користувачів. Основна ідея полягає у застосуванні методів машинного навчання для багатофакторної класифікації клієнтів та створення персоналізованих платіжних пропозицій, що оптимізують як клієнтський досвід, так і дохід компанії. У роботі системно проаналізовано основні виклики цього процесу: проблема «холодного старту» для нових користувачів; динамічність поведінкових патернів, що вимагає імплементації механізмів онлайн-навчання та відстеження дрейфу концепції; висока розмірність простору ознак та складність їх інженерії для точної сегментації; забезпечення інтерпретованості моделей (Explainable AI) для формування зрозумілих та логічних тарифів; а також архітектурні складнощі інтеграції таких систем у високонавантажені середовища. Запропоновано розширену концептуальну архітектуру адаптивної системи, що складається з модулів збору даних, інженерії ознак, ансамблевої класифікації клієнтів та динамічного ціноутворення. Для вирішення завдання класифікації детально розглянуто застосування ансамблевих методів, таких як градієнтний бустинг (XGBoost, LightGBM) та випадковий ліс, що демонструють високу точність на неоднорідних табличних даних. Проведено порівняльний аналіз ефективності кластерних алгоритмів (K-Means, DBSCAN) для первинної некерованої сегментації бази клієнтів. Результати дослідження показують, що перехід від статичних до адаптивних моделей ціноутворення, заснованих на класифікації, може значно підвищити як задоволеність клієнтів (Customer Satisfaction), так і довічну цінність клієнта (Customer Lifetime Value). Подальші дослідження можуть бути спрямовані на розробку гібридних моделей, що поєднують кероване навчання з навчанням з підкріпленням (Reinforcement Learning) для оптимізації цінкових стратегій у реальному часі.

Ключові слова: адаптивна платіжна система; сервісні платформи; машинне навчання; класифікація клієнтів; динамічне ціноутворення; інженерія ознак; дрейф концепції; MLOps; навчання з підкріпленням; каршерінг

Актуальність. Стрімкий розвиток економіки спільної участі (sharing economy) та зростання кількості сервісних платформ загострюють конкуренцію за клієнта. В умовах, коли користувачі мають широкий вибір альтернативних провайдерів, персоналізація послуг стає ключовим фактором утримання. Статичні платіжні системи, що пропонують уніфіковані тарифи, не здатні задовольнити потреби різноманітних груп клієнтів – від спорадичних користувачів до постійних клієнтів, що використовують сервіс для щоденних потреб. Це створює «тарифну прірву», коли частина клієнтів переплачує за невикористаний потенціал послуги, а інша – відмовляється від неї через завищену вартість. Економічні наслідки такого підходу включають високий відтік клієнтів (customer churn), низьку конверсію нових користувачів та недоотриманий прибуток [1]. Перехід до гіперперсоналізації, коли кожен клієнт отримує унікальну пропозицію, є наступним еволюційним кроком у розвитку клієнт-орієнтованих сервісів. Традиційні методи маркетингових досліджень та А/В тестування є занадто повільними та неточними для динамічного середовища сервісних платформ. Вони

This is an open access article under the CC BY license (<https://creativecommons.org/licenses/by/4.0/deed.uk>)

дозволяють оцінити реакцію на обмежену кількість тарифних планів, але не здатні створити справді індивідуальну пропозицію. Таким чином, розробка інтелектуальних систем, здатних адаптувати ціну та модель оплати до унікального профілю кожного клієнта, є надзвичайно актуальною науково-практичною задачею, вирішення якої може надати сервісу значну конкурентну перевагу.

Метою дослідження є створення концептуальної моделі багаторівневої архітектури адаптивної платіжної системи у середовищі сервісних платформ для системного аналізу проблем створення таких систем та визначення шляхів їх вирішення за рахунок використання методів машинного навчання для класифікації клієнтів сервісних платформ. Досягнення мети передбачає вирішення наступних завдань: аналіз існуючих підходів до ціноутворення та їхніх обмежень; ідентифікація та формалізація проблем, які виникають на кожному рівні при створенні багаторівневої архітектури адаптивної платіжної системи (від збору даних до розгортання та моніторингу); глибокий аналіз та обґрунтування вибору методів та алгоритмів для кожного компонента системи, включаючи обробку даних, кластеризацію, класифікацію та оптимізацію ціноутворення; розгляд архітектурних патернів для імплементації надійних та масштабованих MLOps-пайплайнів.

Для побудови ефективної адаптивної платіжної системи необхідно вирішити низку взаємопов'язаних завдань. Запропоновано концептуальну модель такої системи як багаторівневу архітектуру (рис. 1), де кожен рівень виконує специфічну функцію.

1. Шар збору та агрегації даних. На цьому рівні відбувається збір сирих даних про взаємодію користувача з платформою. Джерела даних включають: телематичні дані (GPS-треки, швидкість, стиль водіння), дані транзакцій (суми, час, спосіб оплати), дані з мобільного додатку (частота відкриття, переглянуті екрани), демографічні дані (вік, стать, місце проживання) та зовнішні дані (погодні умови, трафік, проведення публічних заходів). Основна проблема тут – забезпечення повноти, чистоти та консистентності даних, а також дотримання стандартів конфіденційності, таких як GDPR. Дані мають бути агреговані у часові ряди або профілі користувачів для подальшого аналізу. Технічна реалізація цього шару вимагає побудови надійних ETL/ELT-пайплайнів, що можуть обробляти як пакетні, так і потокові дані (наприклад, з використанням Apache Kafka для збору подій у реальному часі та Apache Spark або Flink для їх обробки). Важливою задачею є вирішення проблем якості даних, таких як обробка пропущених значень (за допомогою методів імпутації, наприклад, середнім, медіаною або більш складними моделями, як-от k-NN), детекція та обробка аномалій (викидів) за допомогою алгоритмів типу Isolation Forest або Local Outlier Factor, що можуть спотворити результати навчання моделей.

Сирі дані перетворюються на значущі ознаки (features), які описують поведінку клієнта. Наприклад, можуть бути розраховані такі показники: середня тривалість поїздки, співвідношення поїздок у будні та вихідні дні, коефіцієнт використання в пікові години, загальна сума витрат за місяць, індекс варіативності маршрутів, час з моменту останньої активності. Крім простих агрегатів, важливу роль відіграють складніші ознаки, наприклад, похідні від RFM-аналізу (Recency, Frequency, Monetary) [2]. Для більш глибокого аналізу можуть створюватися ознаки, що відображають послідовність дій користувача. Висока розмірність простору ознак вимагає застосування методів її зниження, таких як аналіз головних компонент (PCA) або використання автокодувальників для отримання щільних векторних представлень (embeddings) поведінки користувача. Створення централізованого реєстру ознак (Feature Store) дозволяє стандартизувати та повторно використовувати ознаки для різних моделей, забезпечуючи консистентність між середовищами навчання та експлуатації моделі (training-serving skew) та вирішуючи проблему дублювання логіки підготовки даних.

2. Шар класифікації клієнтів. Це ядро системи, де застосовуються моделі машинного навчання.

Процес можна розділити на два підходи:

– Некероване навчання (Clustering): Для існуючої бази клієнтів застосовуються алгоритми кластеризації (напр., K-Means, DBSCAN, ієрархічна кластеризація, Gaussian Mixture Models) для виявлення природних сегментів користувачів [3]. Наприклад, можуть бути виявлені такі групи: «Водії вихідного дня», «Щоденні користувачі», «Корпоративні клієнти», «Туристи», «Економні користувачі». Вибір оптимальної кількості кластерів (для K-Means) та параметрів (для DBSCAN) є нетривіальною задачею, що вимагає застосування метрик якості кластеризації (напр., індекс силуету, індекс Девіса-Болдіна) та валідації стабільності отриманих сегментів. Важливим етапом є бізнес-інтерпретація кластерів та створення їхніх персон.




Рис. 1. Концептуальна модель багаторівневої архітектури адаптивної платіжної системи у середовищі сервісних платформ

– Кероване навчання (Supervised Learning): Після визначення сегментів будується модель класифікації (напр., Gradient Boosting (XGBoost, LightGBM), Random Forest, SVM, або нейронні мережі типу TabNet) [4, 5, 6], які навчаються на розмічених даних. Ця модель здатна в реальному часі присвоювати відповідний клас новим користувачам. Особливою проблемою тут є «холодний старт» – класифікація нового користувача, для вирішення якої можуть застосовуватись методи, що базуються на початкових даних або використанні спрощеної моделі. Для підвищення точності можна використовувати ансамблі моделей, що поєднують результати декількох алгоритмів. Також необхідно враховувати проблему незбалансованих класів, застосовуючи техніки, як от SMOTE або використання зважених функцій втрат.

3. Шар динамічного ціноутворення. На основі класу, присвоєного клієнту, цей модуль формує персоніфіковану платіжну пропозицію. Це може бути динамічна зміна тарифу, гібридна підписка або пакетні пропозиції. Для оцінки ефективності різних стратегій ціноутворення доцільно використовувати A/B тестування. Більш просунутим підходом є застосування навчання з підкріпленням (Reinforcement Learning) [7], де агент (система) вчиться обирати оптимальну цінову політику для максимізації довгострокової винагороди (напр., Customer Lifetime Value). У такій постановці задачі станом є профіль клієнта та ринкові умови, дією – запропонований тариф, а винагородою — комбінація з доходу від клієнта та ймовірності його утримання. Для вирішення цієї задачі можуть бути застосовані алгоритми Q-learning, Deep Q-Networks (DQN) або контекстуальні бандити, що є компромісом між A/B тестуванням та повноцінним RL.

Основні виклики та шляхи їх вирішення:

- Динамічність поведінки: поведінка клієнта не є статичною. Система повинна передбачати механізми регулярного перенавчання моделей та відстеження дрейфу концепції (concept drift) [8], використовуючи статистичні методи моніторингу розподілу вхідних даних та вихідних прогнозів (напр., Kolmogorov-Smirnov test, Population Stability Index). При виявленні дрейфу запускається автоматичне перенавчання моделі на свіжих даних.

- Інтерпретованість моделі: для бізнесу важливо розуміти, чому клієнт був віднесений до того чи іншого сегмента. Використання таких методів, як SHAP або LIME, дозволяє пояснити рішення моделі [9], що є критичним для довіри до системи та її відповідності регуляторним вимогам (напр., «право на пояснення» в GDPR). Це також допомагає виявляти помилки в логіці моделі.

- Масштабованість та продуктивність (MLOps): система повинна обробляти запити в режимі, близькому до реального часу. Це вимагає впровадження практик MLOps [10]: контейнеризація моделей (Docker), оркестрація (Kubernetes), створення CI/CD/CT-пайплайнів для автоматичного тестування, розгортання, моніторингу та перенавчання моделей. Важливою складовою є моніторинг не тільки технічних метрик (затримка, помилки), але й якості моделі в продакшені (точність, дрейф даних).

- Етичні аспекти: персоналізоване ціноутворення може межувати з ціновою дискримінацією. Необхідно проводити аудит моделей на наявність упередженості (bias) та впроваджувати методи «справедливого» машинного навчання (Fairness-aware ML) [11], щоб уникнути несправедливого ставлення до окремих груп користувачів на основі захищених ознак (стать, раса, вік). Це може включати модифікацію даних, алгоритмів навчання або постобробку результатів.

Розглянемо деякі з вищезазначених викликів більш детально, оскільки саме в них криються основні ризики при реалізації проекту.

Для нових користувачів, про яких ще не зібрано достатньо даних, точна класифікація є неможливою. Це створює дилему: яку тарифну пропозицію надати? Неправильний вибір може відлякати потенційного клієнта назавжди. Існує кілька гібридних стратегій для мінімізації цього ризику.

Початкова сегментація на основі даних реєстрації: використання демографічних даних (якщо вони збираються згідно з політикою конфіденційності) та даних про джерело залучення клієнта (рекламна кампанія, реферальна програма) може дати первинне уявлення про його можливі потреби.

Застосування евристичних правил: на перших етапах взаємодії система може пропонувати усереднений, найбільш популярний або спеціальний «вітальний» тариф. Після перших 3-5 взаємодій, коли накопичується мінімальний обсяг даних, запускається попередня класифікація.

Інтерактивна анкета: пропозиція користувачу короткого опитування про його очікувані сценарії використання сервісу (наприклад, «Планую їздити на роботу щодня» або «Потрібна машина для поїздок за місто на вихідних») може одразу віднести його до відповідного сегмента.

Моделі на основі схожих користувачів (Look-alike models): система може знайти групу існуючих клієнтів з подібними початковими характеристиками та запропонувати тариф, який є найпопулярнішим у цій групі.

Застосування RL для динамічного ціноутворення є передовим підходом, але вимагає чіткої формалізації.

У контексті сервісної платформи задача може бути декомпозована наступним чином:

- 1) Агент (Agent): сама платіжна система, що приймає рішення;
- 2) Середовище (Environment): ринок, що включає клієнта, конкурентів, поточний попит і пропозицію;
- 3) Стан (State, S): вектор ознак, що описує поточну ситуацію. Він включає профіль клієнта (його сегмент, історію поїздок, LTV), контекстуальні дані (час доби, день тижня, погода, завантаженість доріг) та стан системи (кількість вільних автомобілів у районі);
- 4) Дія (Action, A): конкретна цінова пропозиція, яку агент робить клієнту. Це може бути вибір з кількох дискретних тарифів (наприклад, «Пакет на 5 годин», «Підписка на місяць зі знижкою 15 %», «Стандартний тариф pay-per-use»);
- 5) Винагорода (Reward, R): числова оцінка результату дії. Це найскладніша частина для визначення. Проста винагорода, що дорівнює доходу від транзакції, є короткозорою. Більш ефективна функція винагороди має бути композитною.

Такий підхід дозволяє системі балансувати між миттєвим прибутком та довгостроковою цінністю клієнта, навчаючись на тисячах щоденних взаємодій.

Ключові показники ефективності (KPIs). Для об'єктивної оцінки успішності системи необхідно відстежувати набір бізнес-метрик та технічних показників.

Бізнес-метрики:

- 1) Customer Churn Rate: зниження відсотка клієнтів, що припиняють користуватися сервісом;
- 2) Customer Lifetime Value (LTV): зростання загального прибутку, який клієнт приносить за весь час співпраці;
- 3) Average Revenue Per User (ARPU): зростання середнього доходу на одного користувача;
- 4) Conversion Rate: підвищення відсотка нових користувачів, що здійснюють першу оплату.

Технічні метрики:

- 1) Точність класифікації: Стабільність метрик якості моделі (Accuracy, F1-score, ROC-AUC) на реальних даних;
- 2) Затримка (Latency): Час, необхідний системі для надання тарифної рекомендації;
- 3) Стабільність системи (Uptime): Відсоток часу, коли система доступна і працює без збоїв.

Такий підхід, заснований на даних, дозволяє не просто впровадити технологію, а довести її економічну доцільність для бізнесу.

Аналіз показав, що створення адаптивних платіжних систем є комплексною задачею, що вимагає глибокої експертизи на стику аналізу даних, машинного навчання та програмної інженерії. Запропонована концептуальна модель, що базується на багаторівневій архітектурі та класифікації клієнтів, дозволяє системно підійти до вирішення ключових проблем. Впровадження таких систем на сервісних платформах відкриває шлях до справжньої персоналізації послуг, що сприятиме підвищенню лояльності клієнтів та економічній ефективності бізнесу. Успішна реалізація вимагає не лише розробки точних моделей, але й побудови надійної MLOps інфраструктури та впровадження чіткої стратегії валідації через A/B тестування. Подальші дослідження будуть зосереджені на розробці та тестуванні конкретних моделей класифікації на реальних анонімізованих даних сервісів оренди авто, а також на дослідженні застосування методів навчання з підкріпленням для автоматичного пошуку оптимальних цінових політик таких систем.

СПИСОК ЛІТЕРАТУРИ

1. Kumar V. "Customer relationship management: Concept, strategy and tools". *Springer*. 2018.
2. Berry M. J. A., Linoff G. S. "Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management". *John Wiley & Sons*. 2011.
3. Jain A. K. "Data clustering: 50 years beyond K-means". *Pattern Recognition Letters*. 2010; 31 (8): 651–666.
4. Chen T., Guestrin C. "XGBoost: A Scalable Tree Boosting System". In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016. p. 785–794.
5. Breiman L. "Random forests". *Machine learning*. 2001; 45 (1): 5–32.
6. Arik S. O., Pfister T. "TabNet: Attentive Interpretable Tabular Learning". *arXiv*. 2019. DOI: <https://doi.org/10.48550/arXiv.1908.07442>.
7. Sutton R. S., Barto A. G. "Reinforcement learning: An introduction". *MIT press*. 2018.
8. Gama J., Žliobaitė I., Bifet A., Pechenizkiy M., Bouchachia A. "A survey on concept drifts adaptation". *ACM Computing Surveys (CSUR)*. 2014; 46 (4): 1–37.
9. Molnar C. "Interpretable Machine Learning: A Guide for Making Black Box Models Explainable". 2020.
10. Kreuzberger D., Kühl N., Hirschl S. "Machine Learning Operations (MLOps): A Survey and Maturity Model". *arXiv*. 2023. URL: <https://arxiv.org/pdf/2205.02302>.
11. Mehrabi N., Morstatter F., Saxena N., Lerman K., Galstyan A. "A Survey on Bias and Fairness in Machine Learning". *ACM Computing Surveys (CSUR)*. 2021; 54 (6): 1–35.

DOI: <https://doi.org/10.15276/ict.02.2025.04>

UDC 004.85:339.187

Analysis of the problems of creating effective adaptive payment systems in the environment of service platforms

Olena O. Arsirii¹⁾

Doctor of Engineering Sciences, Professor, Head of the Department of Information Systems
ORCID: <https://orcid.org/0000-0001-8130-9613>; e.arsirii@gmail.com. Scopus Author ID: 54419480900

Vitalii Y. Bondar¹⁾

Postgraduate Student of the Department of Information Systems
ORCID: <https://orcid.org/0000-0001-5173-0810>; bvitaly97@gmail.com

Olexander V. Rudenko¹⁾

Postgraduate Student of the Department of Information Systems
ORCID: <https://orcid.org/0009-0004-2944-4040>; alexo.rudenko@stud.op.edu.ua

¹⁾ Odesa Polytechnic National University, 1, Shevchenko Ave. Odesa, 65044, Ukraine

ABSTRACT

Modern service platforms, particularly in car sharing and micromobility, face the challenge of customer retention and profit maximization due to their reliance on predominantly static payment models. Traditional approaches, such as fixed subscriptions or pay-per-use, fail to account for the heterogeneity of customer behavior, leading to reduced loyalty and loss of potential revenue. This study provides an in-depth analysis of the key scientific and technical problems arising in the development of adaptive payment systems capable of dynamically adjusting tariff plans to individual user behavior patterns. The core idea is to apply machine learning methods for multi-factor customer classification to create personalized payment offers that optimize both customer experience and company revenue. The paper systematically analyzes the main challenges of this process: the "cold start" problem for new users; the dynamic nature of behavioral patterns requiring the implementation of online learning mechanisms and concept drift detection; the high dimensionality of the feature space and the complexity of their engineering for accurate segmentation; ensuring model interpretability (Explainable AI) to form understandable and logical tariffs; and the architectural complexities of integrating such systems into high-load production environments. An expanded conceptual architecture for an adaptive system is proposed, consisting of modules for data collection, feature engineering, ensemble customer classification, and dynamic pricing. To solve the classification task, the application of ensemble methods such as Gradient Boosting (XGBoost, LightGBM) and Random Forest is considered in detail, as they demonstrate high accuracy on heterogeneous tabular data. A comparative analysis of the effectiveness of clustering algorithms (K-Means, DBSCAN) for initial unsupervised segmentation of the customer base is conducted. The research findings indicate that transitioning from static to adaptive pricing models based on classification can significantly enhance both Customer Satisfaction and Customer Lifetime Value. Future research will focus on developing hybrid models that combine supervised learning with Reinforcement Learning for real-time optimization of pricing strategies.

Keywords: adaptive payment system; service platforms; machine learning; customer classification; dynamic pricing; feature engineering; concept drift; MLOps; reinforcement learning; car sharing