



DOI 10.28925/2663-4023.2025.28.794

УДК 004.8

Коротін Денис Сергійович

аспірант 3 курсу, групи АКСМ-31

Державний університет інформаційно-комунікаційних технологій, Київ, Україна

ORCID ID: 0000-0001-7239-2101

d.korotin@stud.duikt.edu.ua**Лашевська Наталія Олександрівна**

кандидат технічних наук, доцент

Державний університет інформаційно-комунікаційних технологій, Київ, Україна

ORCID ID: 0000-0003-2148-115X

n.lashchevska@duikt.edu.ua

ВИКОРИСТАННЯ МАШИННОГО НАВЧАННЯ В СТАВКАХ У РЕАЛЬНОМУ ЧАСІ

Анотація. Актуальність дослідження зумовлена необхідністю автоматизованого й оперативного прийняття рішень у системах ставок у реальному часі (RTB — real-time bidding), що функціонують у динамічному середовищі цифрової реклами на основі великої кількості користувацьких і контекстних параметрів. Зважаючи на зростання обсягів даних і високі вимоги до персоналізованості контенту, виникає потреба у впровадженні більш гнучких і адаптивних алгоритмів. Метою статті є дослідження потенціалу інтеграції методів машинного навчання (ML — machine learning) у процеси управління рекламними ставками з метою підвищення релевантності оголошень та ефективності рекламних кампаній в умовах нестабільної ринкової кон'юнктури. У межах дослідження застосовано структурно-функціональний, аналітичний і порівняльний підходи до вивчення архітектури RTB-систем, а також моделювання алгоритмів рекомендаційних рішень у реальному часі. Особливу увагу приділено таким факторам, як якість вхідних даних, частота оновлення моделей, адаптивність систем та інтеграція інтерфейсів прикладного програмування (API — application programming interface). Виявлено, що найбільш поширеними в практиці є логістична регресія, градієнтний бустинг, глибокі нейронні мережі та навчання з підкріпленням (reinforcement learning — метод, за якого модель навчається через послідовне прийняття рішень із отриманням винагороди або покарання). Доведено, що ефективність рекламних стратегій істотно зростає при використанні таких показників, як ключові індикатори ефективності (KPI — key performance indicators) та показник життєвого циклу клієнта (LTV — lifetime value). Установлено основні обмеження впровадження ML у RTB-системах: недостатність обчислювальних ресурсів, низька інтерпретованість алгоритмів і ризики надмірної автоматизації. Обґрунтовано доцільність застосування гібридних моделей із поєднанням офлайн-і онлайн-аналізу, а також використання пояснюваного штучного інтелекту (explainable AI) для підвищення прозорості прийняття рішень. Наукова новизна полягає в систематизації факторів, що критично впливають на точність прогнозів у динамічному рекламному середовищі. Перспективою подальших досліджень є створення моделей, стійких до обмежень персоналізованих даних і здатних до контекстно-залежного самооновлення.

Ключові слова: цифрова реклама; алгоритми прогнозування; адаптивні моделі; оброблення поведінкових даних; динамічне ціноутворення; персоналізований контент; обчислювальна оптимізація.

ВСТУП

З огляду на трансформацію рекламного ринку в умовах цифровізації особливого значення набувають автоматизовані системи купівлі медійної реклами, які функціонують на основі миттєвого аналізу великих обсягів даних. Реалізація концепції



Real-Time Bidding (RTB) дала змогу здійснювати аукціонні торги за рекламні покази в режимі реального часу, що докорінно змінило підходи до планування й розміщення рекламних кампаній. У таких умовах виникає потреба у використанні інтелектуальних рішень, здатних забезпечити адаптивність, прогностичність і оптимізацію витрат у надзвичайно швидкісному середовищі. Застосування машинного навчання стає ключовим фактором підвищення ефективності таких процесів.

Постановка проблеми. У сучасних умовах цифрової економіки реклама набуває нових форм і механізмів реалізації, що вимагає відповідного вдосконалення інструментів прийняття рішень. Однією з найбільш динамічних і технологічно складних моделей є система ставок у реальному часі (RTB), що забезпечує миттєвий аукціонний розподіл рекламного простору на основі даних про користувача. Однак, попри значні досягнення в галузі автоматизації рекламних торгів, актуальним залишається питання підвищення ефективності прийняття рішень у межах мілісекундного інтервалу, що потребує впровадження інтелектуальних методів аналізу великих обсягів даних.

Машинне навчання як напрям штучного інтелекту відкриває нові можливості для побудови прогнозних моделей, які здатні адаптивно реагувати на поведінкові патерни користувачів та ринкові коливання в режимі реального часу. Проблема полягає не лише в точності прогнозів, а й у здатності алгоритмів до самооптимізації у високочастотному середовищі цифрових аукціонів. Науковий інтерес зосереджений на пошуку моделей, які би поєднували високу швидкодію, точність оцінювання цільових показників і здатність до контекстного навчання. Практичне значення полягає в зменшенні рекламних витрат, підвищенні конверсій та забезпеченні релевантності рекламного контенту для кінцевого споживача. Саме тому дослідження потенціалу машинного навчання в RTB-системах є важливим як для науки, так і для практики цифрового маркетингу.

Аналіз останніх досліджень і публікацій. Огляд наукових досліджень щодо використання машинного навчання в ставках у реальному часі (RTB) дає змогу виокремити чотири ключові змістовні напрями, які формують сучасну парадигму розвитку рекламних стратегій на основі інтелектуальних алгоритмів.

Перший напрям пов'язаний із впровадженням навчання з підкріпленням як основи адаптивного управління ставками. У дослідженні С. Чен (C. Chen), Дж. Ванг (G. Wang), Б. Лю (B. Liu), Т. Лю (T. Liu), Г. Чжанг (H. Zhang), Л. Хе (L. He), З. Ву (Z. Wu), З. Янг (Z. Yang), Д. Дю (D. Du) та Ю. Чжанг (Y. Zhang) проаналізовано застосування мультиагентного навчання з підкріпленням для координації дій у мультиканальному середовищі RTB, що підвищує ефективність взаємодії між агентами [1]. Г. К'ю (H. Qiu), Ю. Фенг (Y. Feng), Г. Янг (G. Yang), С. Фан (C. Fan) і Х. Чжу (H. Zhu) дослідили застосування TD3-алгоритму для оптимізації ставок у часових слотах, адаптуючи стратегічні рішення до динаміки аукціонного середовища [2]. У роботі С. Чен (S. Chen), М. Чжоу (M. Zhou), Ю. Лю (Y. Liu), Л. Гао (L. Gao) і Ю. Чжанг (Y. Zhang) запропоновано модельне навчання з підкріпленням, що дозволяє формувати ефективні автоторги на основі симуляцій [3]. П. Шарма (P. Sharma) обґрунтував ефективність поєднання процесів Маркова з машинним навчанням для створення стратегій ставок, що враховують стохастичну природу ринкових змін [4]. У дослідженні Л. Кай (L. Cai), Й. Хе (J. He), Ю. Лі (Y. Li), Й. Лян (J. Liang), Ю. Лін (Y. Lin), З. Кван (Z. Quan), Ю. Зенг (Y. Zeng) і Й. Ксю (J. Xu) представлено систему RTB Agent, яка поєднує підхід агентного моделювання з використанням великих мовних моделей для формування складних стратегій у реальному часі [5]. Подальше дослідження цього напрямку має бути спрямоване на розроблення стійких стратегій RL у мультиагентних середовищах із високим рівнем непередбачуваності поведінки користувачів і конкурентів.



Другий напрям охоплює використання персоналізованих моделей і динамічного таргетингу для підвищення точності ставок. Л. Міралес-Печуан (L. Miralles-Pechuán), М. Кюреши (M. Qureshi) і Б. М. Намі (B. M. Namee) дослідили оптимізацію рекламних кампаній шляхом урахування індивідуальних налаштувань користувачів, що демонструє ефективність ML-моделей для поведінкової адаптації ставок [6]. У роботі С. Квін (C. Qin), С. Гу (C. Hu) і Ю. Фенг (Y. Feng) запропоновано інноваційний підхід до динамічного таргетингу, який реагує на змінний контекст показів реклами в режимі реального часу [7]. А. С. Чіаппа (A. S. Chiappa), Б. Гангопадхай (B. Gangopadhyay), З. Ванг (Z. Wang) і С. Такамацу (S. Takamatsu) розробили метод імітаційного навчання, який дозволяє системам автоставок копіювати ефективні стратегії на основі даних Oracle [8]. Цей напрям вимагає подальшого дослідження з метою поєднання глибоких моделей поведінки користувачів із динамічним коригуванням ставок для підвищення рівня релевантності реклами.

Третій напрям охоплює аналітику та узагальнення наявних підходів до ML-оптимізації ставок. В. Оу (W. Ou), Б. Чен (B. Chen), Кс. Дай (X. Dai), В. Чжанг (W. Zhang), В. Лю (W. Liu), Р. Танг (R. Tang) та Ю. Йу (Y. Yu) провели масштабне узагальнення досліджень з оптимізації ставок, систематизувавши підходи на основі градієнтного бустингу, глибоких нейромереж, стохастичних моделей і гібридних архітектур [9]. А. Джа (A. Jha), Г. Джайн (H. Jain), П. Шарма (P. Sharma), Ю. Шарма (Y. Sharma) і К. Тіварі (K. Tiwari) здійснили експериментальне порівняння різних моделей машинного навчання і reinforcement learning (метод навчання, за якого агент навчається через підкріплення за допомогою винагороди або покарання) для виявлення найбільш ефективних стратегій за умов нестабільного аукціонного середовища [10]. Подальший розвиток цього наукового напрямку доцільно спрямовувати на автоматизоване калібрування гібридних моделей, які комбінують переваги різних підходів до прогнозування CTR і управління ставками.

Четвертий напрям досліджень сфокусовано на викликах прозорості, довіри та стійкості до похибок у прогнозних алгоритмах. Кс. Танг (X. Tang) і Г. Йу (H. Yu) окреслюють концептуальні засади «довіреного» RTB, де особливу увагу приділено прозорості прийняття рішень, етичному використанню даних і відповідальності систем штучного інтелекту [11]. В.-Ю. Шиг (W.-Y. Shih), Г.-С. Лай (H.-C. Lai) та Й.-Л. Хуанг (J.-L. Huang) запропонували стратегію ставок, яка враховує похибки прогнозів CTR завдяки кластеризації показників очікуваного виграшу, що знижує ризик переоцінювання релевантності показу [12]. М. Афзалі (M. Afzali), К. Хосравані (K. Khosravan) та М. Бабазаде (M. Babazadeh) розробили модель оптимального розподілу бюджету в умовах реального часу, яка дозволяє забезпечити збалансовану витрату ресурсів без втрати конкурентоспроможності кампанії [13]. Цей напрям потребує подальшого вивчення методів підвищення інтерпретованості алгоритмів ставок і побудови захищених моделей проти маніпуляцій і спотворень у даних.

Попри активне впровадження машинного навчання в RTB-системи, окремі аспекти залишаються не досить дослідженими. Зокрема, не сформовано узагальненої моделі взаємодії між компонентами RTB-архітектури з урахуванням ролі інтелектуальних алгоритмів у прийнятті рішень у реальному часі. Також бракує комплексного аналізу ефективності різних типів моделей не лише за точністю, а й за критеріями швидкодії, адаптивності та економічної доцільності. Відсутність стандартизованих підходів до оцінювання якості вхідних даних і частоти оновлення моделей обмежує практичну оптимізацію кампаній у швидкоплинному цифровому середовищі.

Крім того, залишається відкритим питання прозорості та інтерпретованості алгоритмів, що використовуються в RTB, особливо в умовах посилення вимог до



етичності цифрових сервісів. Потребують подальшого дослідження ризику надмірної автоматизації, зокрема дублювання упереджених рішень та зниження контролю з боку користувачів. Запропоноване дослідження спрямоване на заповнення цих прогалин шляхом структурного аналізу архітектури RTB, узагальнення алгоритмічних рішень та формулювання практичних рекомендацій щодо підвищення ефективності й прозорості таких систем.

Мета статті. Мета статті полягає у визначенні можливостей застосування методів машинного навчання для підвищення ефективності систем ставок у реальному часі (RTB) у контексті динамічного цифрового ринку.

Для досягнення цієї мети поставлено такі наукові завдання:

- 1) проаналізувати функціональну архітектуру RTB-систем і визначити роль машинного навчання в процесах прогнозування кліків, конверсій і динамічного ціноутворення;
- 2) оцінити вплив якості вхідних даних, частоти оновлення моделей та адаптивності алгоритмів на ефективність рекламних кампаній у режимі реального часу;
- 3) виявити ключові проблеми впровадження машинного навчання в RTB-системах і сформулювати практичні рекомендації щодо оптимізації їх структури.

МЕТОДИКА ДОСЛІДЖЕННЯ

У процесі дослідження застосовано структурно-функціональний підхід для аналізу архітектури RTB-систем та визначення ролі машинного навчання в їх основних модулях. Для характеристики алгоритмів використано метод порівняльного аналізу з урахуванням параметрів точності, швидкодії та масштабованості. Оцінювання впливу вхідних факторів здійснювалося шляхом логіко-аналітичного узагальнення на основі доступних прикладних рішень й емпіричних прикладів із практики провідних рекламних платформ. Розроблення рекомендацій базувалося на методах систематизації та критичного оцінювання ефективності алгоритмів у контексті обмежень цифрового ринку.

РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

Системи ставок у реальному часі (Real-Time Bidding, далі — RTB) становлять складну інфраструктуру, яка забезпечує динамічне розміщення рекламних оголошень на цифрових платформах з огляду на поведінкові характеристики користувача, тип контенту та історію переглядів. В основі RTB лежить архітектура, яка дозволяє здійснювати мікроаукціони за рекламні покази в межах кількох мілісекунд, при цьому рішення про участь у торгах та розмір ставки формується на основі аналізу великої кількості вхідних сигналів. У цих умовах машинне навчання відіграє ключову роль, оскільки дозволяє здійснювати прогнозну аналітику, ранжування цільової аудиторії, оцінювання ймовірності кліку (CTR) або конверсії (CVR) та адаптацію ставок у режимі реального часу (табл. 1).



Таблиця 1

**Функціональна структура RTB-систем та застосування
машинного навчання на ключових етапах рекламного аукціону**

Компонент архітектури RTB-системи	Основні функції	Роль машинного навчання
SSP (Supply Side Platform)	Забезпечує підключення сайтів і мобільних додатків до рекламної біржі; передає запити на показ реклами	Формує контекстну інформацію для аналізу; машинне навчання використовується для фільтрації неякісного трафіку
Ad Exchange	Платформа для проведення аукціонів у реальному часі між попитом і пропозицією	Оптимізація алгоритмів торгів; передача результатів моделей ML DSP-системам
DSP (Demand Side Platform)	Приймає рішення про участь у торгах і розмір ставки на основі вхідних даних	Основний осередок використання ML: прогнозування CTR, CVR, динамічна оптимізація ставок
Data Management Platform (DMP)	Збирає, об'єднує та структурує дані про користувачів	Машинне навчання аналізує поведінкові патерни та кластеризує аудиторію
Decision Engine	Формує остаточне рішення на основі прогнозів ML-моделей та бізнес-правил	Застосування нейромереж, градієнтного бустингу, регресійних моделей для розрахунку ставки

Джерело: сформовано автором на підставі [1], [4], [5], [6], [9]

Представлена таблиця містить узагальнення основних компонентів архітектури RTB-систем і демонструє, яким чином методи машинного навчання інтегруються на кожному з етапів оброблення запиту на рекламний показ. У межах сучасної рекламної екосистеми SSP-модулі (Supply Side Platform — платформа пропозиції) забезпечують фільтрацію вхідного трафіку та визначають потенційно цінні рекламні можливості, передаючи дані до рекламної біржі. Ad Exchange (реklamна біржа) координує миттєвий аукціон і передає інформацію в DSP (Demand Side Platform — платформа попиту), де відбувається основний аналітичний процес. Саме тут алгоритми машинного навчання здійснюють прогнозування показників ефективності, зокрема CTR (Click-Through Rate — ймовірність кліку) та CVR (Conversion Rate — ймовірність конверсії), визначають доцільність участі в торгах і обчислюють оптимальну ставку. Своєю чергою DMP-платформи (Data Management Platform — платформа керування даними) накопичують та обробляють великі масиви даних про поведінку користувачів, забезпечуючи персоналізацію рекламних рішень і підтримуючи контекстуальну релевантність оголошень. Усі ці модулі поєднуються в єдину систему ухвалення рішень, де алгоритми машинного навчання виконують функції адаптивного прогнозування, оптимізації ставок і підвищення загальної результативності рекламної кампанії. Так, машинне навчання не є лише допоміжним інструментом, а виступає критично важливою технологічною основою сучасних RTB-систем.

Моделі машинного навчання, що використовуються в системах ставок у реальному часі, відіграють ключову роль у формуванні рішень щодо розміщення реклами, зокрема в прогнозуванні ймовірності кліку на оголошення (CTR), ймовірності конверсії (CVR), а також у динамічному визначенні ставок відповідно до обчисленої цінності показу. На відміну від традиційних евристичних методів, сучасні підходи базуються на статистичному навчанні з використанням історичних даних та багатовимірних поведінкових ознак. Вибір конкретного алгоритму залежить від вимог до швидкодії, точності, стабільності та масштабованості. Найбільш поширеними в практиці RTB є моделі логістичної регресії, градієнтного бустингу, випадкового лісу, а також нейронні



мережі, включаючи глибоке навчання. Кожна з них має певні архітектурні переваги, що визначають її доцільність у конкретних елементах рекламної інфраструктури (табл. 2).

Таблиця 2

Поширені алгоритми машинного навчання для прогнозування в RTB-середовищі: архітектура, принципи роботи та прикладне використання

Алгоритм машинного навчання	Основні архітектурні характеристики	Принцип дії	Особливості використання в RTB
Логістична регресія	Лінійна модель з імовірнісним виходом	Обчислює ймовірність кліку або конверсії на основі вагових коефіцієнтів	Використовується як базова модель у DSP для швидких розрахунків CTR/CVR у режимі реального часу
Гرادієнтний бустинг (наприклад, XGBoost)	Комбінація слабких моделей (дерев рішень), що коригуються ітеративно	Мінімізує функцію втрат шляхом побудови послідовних дерев в офлайн-навчанні	Забезпечує високу точність прогнозу; застосовується у великих DSP при попередньому офлайн-навчанні
Випадковий ліс	Сукупність дерев рішень з випадковими підвбірками ознак	Генерує колективне рішення шляхом голосування дерев	Добре працює за великої кількості ознак; менш ефективний у високочастотному онлайн-середовищі
Моделі багаторозмірного ранжування (наприклад, DeepFM)	Інтеграція факторизаційних моделей і нейронних мереж	Поєднує автоматичне виділення ознак і глибоке навчання	Підходить для складних сценаріїв персоналізації; ефективна для великих DMP

Джерело: сформовано автором на підставі [3], [4], [6], [9], [10]

У табл. 2 наведено приклади найчастіше застосовуваних алгоритмів машинного навчання, які виконують функції прогнозування ймовірності кліку, ймовірності конверсії та обґрунтування рівня ставки в системах RTB. Так, логістична регресія використовується в сервісі Google Ads [14] як базовий метод для оперативного оброблення сигналів із DSP за високої швидкості прийняття рішень. Градієнтний бустинг, зокрема XGBoost, широко застосовується в програматичних платформах Meta (Facebook Ads) [15], де потрібна точність у сегментації користувачів за глибинними ознаками. Випадковий ліс актуальний для ретаргетингових кампаній, наприклад, у Criteo, де важливо враховувати попередню взаємодію користувача з оголошеннями. Глибокі нейромережі (DNN) є складовою частиною архітектури Amazon DSP [16] і TikTok Ads [17], які використовують багаторівневу поведінкову інформацію для персоналізованих рекомендацій [7]. Моделі ранжування на основі гібридних нейронно-факторизаційних структур, як-от DeepFM, активно впроваджуються в Alibaba RTB-платформі [18], де оптимізація результатів відбувається з урахуванням багатовимірних комерційних і контекстуальних параметрів [2]. Таким чином, наведені моделі демонструють прикладну адаптацію алгоритмів до специфіки даних, цілей таргетингу та особливостей рекламного середовища.

У контексті систем ставок у реальному часі (RTB) результативність рекламних кампаній значною мірою залежить не лише від вибраного алгоритму машинного навчання, а й від якості вхідних даних, частоти оновлення моделей та рівня їх адаптивності до змін середовища. Дані, що надходять до системи під час кожного запиту, містять численні параметри: технічні характеристики пристрою, часовий контекст, поведінкові сигнали



користувача, історію переглядів, геолокацію тощо. Наявність неповних, застарілих або неконсистентних даних знижує точність прогнозу й безпосередньо впливає на ефективність розміщення реклами. Частота оновлення моделей визначає, наскільки швидко алгоритм реагує на зміну поведінки аудиторії або умов ринку. Водночас адаптивність алгоритму — це здатність коригувати свою структуру або параметри на основі нових даних без повного перенавчання. Ці три компоненти формують основу динамічної стійкості рекламної системи, що функціонує у швидкоплинному цифровому середовищі (табл. 3).

Таблиця 3

**Фактори, що впливають на ефективність роботи
моделей машинного навчання в RTB-середовищі**

Фактор	Сутність впливу	Наслідки для RTB-реклами
Якість вхідних даних	Рівень деталізації, достовірність і часова актуальність вхідних параметрів	Визначає здатність моделі правильно ідентифікувати цільову аудиторію та прогнозувати ефективність
Частота оновлення моделі	Інтервали оновлення параметрів моделі або параметрів на основі нових даних	Впливає на здатність реагувати на короткострокові зміни попиту, сезонність й інформаційні сплески
Адаптивність алгоритму	Механізми швидкої самокорекції моделей у відповідь на зміну поведінкових патернів	Забезпечує стійкість до непередбачених змін і зниження ефекту «старіння» моделі в реальному часі

Джерело: сформовано автором на підставі [2], [5], [7], [10], [13]

Практичне значення кожного з наведених факторів полягає в їх безпосередньому впливі на ефективність цифрових рекламних кампаній у висококонкурентному середовищі. Низька якість вхідних даних, зокрема затримка сигналів або неповні профілі користувачів, призводить до зменшення точності таргетингу. Наприклад, платформа The Trade Desk [19] фіксувала різке зниження результативності кампаній, коли трекінгові події з мобільних додатків оброблялися із затримкою понад 100 мс, що унеможливлювало врахування актуального контексту [2]. Частота оновлення моделі є критично важливою в кампаніях, чутливих до часу, як-от розпродажі або запуск нових продуктів. Так, рекламна система Taboola [20] застосовує гнучкі оновлення на основі географічної та часової активності аудиторії: у періоди політичних подій або спортивних трансляцій моделі оновлюються до кількох разів на годину [5]. Адаптивність своєю чергою дозволяє зберегти стабільну якість рекламних показів у разі різкої зміни поведінки користувачів, як це було зафіксовано в кампаніях на платформі AppLovin [21] під час пандемії COVID-19, коли типова взаємодія з мобільними додатками зазнала нетипових змін упродовж кількох днів. Таким чином, ці фактори мають не лише технічну, а і стратегічну значущість для досягнення рекламних KPI (Key Performance Indicators) та оптимального розподілу бюджетів [6].

Попри зростання ефективності й точності прогнозування в RTB-середовищі завдяки застосуванню машинного навчання, практичне впровадження таких алгоритмів супроводжується низкою системних проблем, що обмежують їх функціональність і довготривалу стійкість. Одним із найважливіших обмежень є високе навантаження на обчислювальні ресурси, особливо в умовах необхідності ухвалення рішень протягом кількох мілісекунд. Використання складних моделей, зокрема глибоких нейронних мереж, вимагає значних обчислювальних потужностей як на етапі навчання, так і під час прогнозування, що призводить до високих витрат на інфраструктуру та потребує оптимізації швидкодії без втрати точності [9].



Додатковою проблемою є обмежена прозорість функціонування алгоритмів, яка ускладнює верифікацію прийнятих рішень та викликає труднощі в поясненні логіки дій моделі для рекламодавців і регуляторів [11]. У ситуаціях, коли алгоритм помилково ідентифікує користувача або неадекватно оцінює важливість рекламного показу, відсутність механізмів інтерпретації унеможливорює оперативне виявлення причин збоїв і створює ризики для довіри до автоматизованих систем.

Ще одним викликом є надмірна автоматизація рекламних процесів, яка може призводити до втрати стратегічного контролю з боку маркетологів. Алгоритми, що навчаються виключно на основі історичних даних, часто схильні до відтворення вже закладених упереджень і не здатні коректно реагувати на нетипові або виняткові ситуації [4]. Це особливо критично в періоди кризових змін ринку, коли адаптація моделей без людського втручання може призводити до нераціонального використання рекламного бюджету.

Оптимізація структури RTB-рішень на основі машинного навчання потребує комплексного підходу, який враховує як технологічні аспекти моделювання, так і організаційні умови їх впровадження. Передусім доцільно впроваджувати багаторівневу архітектуру прогнозування, в якій поєднуються офлайн- і онлайн-моделі. Офлайн-компоненти можуть бути зосереджені на навчанні таких складних моделей, як градієнтний бустинг або глибокі нейромережі, з використанням великих масивів історичних даних. Їх результати можуть бути інтегровані у високошвидкісні онлайн-системи через API (Application Programming Interface) або за допомогою полегшених версій моделей для оперативного оброблення запитів у реальному часі. Така комбінація дозволяє досягти балансу між точністю прогнозу і швидкістю системи.

Для підвищення релевантності рекламного контенту рекомендовано впроваджувати динамічні механізми сегментації користувачів на основі кластерного аналізу, що регулярно оновлюється. Це забезпечує точніше відображення змін у поведінкових паттернах і дозволяє створювати персоналізовані стратегії показу. Економічна доцільність рекламного процесу може бути підвищена шляхом адаптивного коригування ставок на основі прогнозованої цінності користувача з урахуванням LTV (lifetime value) і поточних KPI кампанії. У цьому контексті ефективною є інтеграція механізмів A/B-тестування, які дозволяють у режимі реального часу виявляти найбільш результативні конфігурації моделей.

Особливу увагу слід приділяти побудові прозорої системи моніторингу моделей, що включає метрики точності, швидкодії, відгуку користувача і фінансових результатів. Це дозволяє вчасно ідентифікувати зниження ефективності моделі та здійснити її перенавчання або модифікацію. Крім того, важливим напрямом оптимізації є впровадження explainable AI (пояснюваного штучного інтелекту) для підвищення довіри до систем автоматичного прийняття рішень і забезпечення відповідності регуляторним вимогам. У сукупності ці підходи сприяють формуванню ефективного, контрольованого та гнучкого RTB-середовища, здатного адаптуватися до динаміки ринку та поведінки цифрової аудиторії.

ВИСНОВКИ ТА ПЕРСПЕКТИВИ ПОДАЛЬШИХ ДОСЛІДЖЕНЬ

У ході дослідження встановлено, що машинне навчання є ключовим інструментом підвищення ефективності RTB-систем, забезпечуючи точне прогнозування кліків, релевантність показів та динамічне ціноутворення. Найбільш ефективними є моделі логістичної регресії, градієнтного бустингу та глибокі нейронні мережі, які реалізуються в багаторівневих архітектурах. Практична результативність таких систем залежить від



якості вхідних даних, частоти оновлення моделей і здатності алгоритмів адаптуватися до змін у реальному часі.

Серед основних проблем впровадження виявлено високе навантаження на обчислювальні ресурси, обмежену інтерпретованість моделей та ризики неконтрольованої автоматизації. З огляду на це рекомендовано впроваджувати гібридні системи прогнозування з поєднанням офлайн- і онлайн-моделей, розширювати використання пояснюваного штучного інтелекту (explainable AI) для підвищення прозорості ухвалення рішень, а також здійснювати регулярне тестування моделей для забезпечення їх актуальності.

Перспективи подальших досліджень охоплюють розроблення адаптивних алгоритмів із контекстним зважуванням ознак, вивчення ефективності RTB у мультиплатформному середовищі та аналіз впливу обмежень щодо приватності даних на точність прогнозування.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Chen, C., Wang, G., Liu, B., Liu, T., Zhang, H., He, L., Wu, Z., Yang, Z., Du, D., & Zhang, Y. (2025). Real-time bidding with multi-agent reinforcement learning in multi-channel display advertising. *Neural Computing and Applications*, 37, 499–511. <https://doi.org/10.1007/s00521-024-10649-6>
2. Qiu, H., Feng, Y., Yang, G., Fan, C., & Zhu, H. (2024). Time Slot Bidding Optimization Strategy Based on TD3 in Real-Time Bidding. *2024 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 4745–4750. <https://doi.org/10.1109/SMC54092.2024.10831596>
3. Chen, S., Zhou, M., Liu, Y., Gao, L., & Zhang, Y. (2023). Model-based reinforcement learning for auto-bidding in display advertising. *Proceedings of the 2023 International Conference on Autonomous Agents and Multiagent Systems*, 1560–1568. <https://www.ifaamas.org/Proceedings/aamas2023/pdfs/p1560.pdf>
4. Sharma, P. (2023). *Improving Real-Time Bidding in Online Advertising Using Markov Decision Processes and Machine Learning Techniques*. arXiv preprint. <https://doi.org/10.48550/arXiv.2305.04889>
5. Cai, L., He, J., Li, Y., Liang, J., Lin, Y., Quan, Z., Zeng, Y., & Xu, J. (2025). *RTB Agent: A LLM-based Agent System for Real-Time Bidding*. arXiv preprint. <https://doi.org/10.48550/arXiv.2502.00792>
6. Miralles-Pechuán, L., Qureshi, M. A., & Namee, B. M. (2023). Real-time bidding campaigns optimization using user profile settings. *Electronic Commerce Research*, 23, 1297–1322. <https://doi.org/10.1007/s10660-021-09513-9>
7. Qin, C., Hu, C., & Feng, Y. (2025). A novel bidding strategy based on dynamic targeting in real-time bidding market. *Electronic Commerce Research*, 25, 1067–1088. <https://doi.org/10.1007/s10660-023-09714-4>
8. Chiappa, A. S., Gangopadhyay, B., Wang, Z., & Takamatsu, S. (2024). *Auto-bidding in real-time auctions via Oracle Imitation Learning*. arXiv preprint. <https://doi.org/10.48550/arXiv.2412.11434>
9. Ou, W., Chen, B., Dai, X., Zhang, W., Liu, W., Tang, R., & Yu, Y. (2023). A survey on bid optimization in real-time bidding display advertising. *ACM Transactions on Knowledge Discovery from Data*, 18(3), 1–31. <https://doi.org/10.1145/3628603>
10. Jha, A., Jain, H., Sharma, P., Sharma, Y., & Tiwari, K. (2024). Optimizing Real-Time Bidding Strategies: An Experimental Analysis of Reinforcement Learning and Machine Learning Techniques. *Procedia Computer Science*, 235, 2017–2026. <https://doi.org/10.1016/j.procs.2024.04.191>
11. Tang, X., & Yu, H. (2025). Towards trustworthy AI-empowered real-time bidding for online advertisement auctioning. *ACM Computing Surveys*, 57(6), 1–36. <https://doi.org/10.1145/370174>
12. Shih, W.-Y., Lai, H.-C., & Huang, J.-L. (2023). A Robust Real Time Bidding Strategy Against Inaccurate CTR Predictions by Using Cluster Expected Win Rate. *IEEE Access*, 11, 126917–126926. <https://doi.org/10.1109/ACCESS.2023.3332029>
13. Afzali, M., Khosravani, K., & Babazadeh, M. (2023). Optimal Bidding Strategy with Smooth Budget Delivery in Online Advertising. *2023 31st International Conference on Electrical Engineering (ICEE)*, 315–321. <https://doi.org/10.1109/ICEE59167.2023.10334752>
14. Google Display Network. (n.d.). <https://ads.google.com/home/campaigns/display-ads/>
15. Meta for Business. (n.d.). <https://www.facebook.com/business/ads>
16. Amazon DSP. (n.d.). <https://advertising.amazon.com/en/products/dsp>



17. *TikTok Ads.* (n.d.). <https://ads.tiktok.com/>
18. *Alibaba DAMO Academy –DeepFM.* (n.d.). <https://damo.alibaba.com/labs/ai/>
19. *The Trade Desk.* (n.d.). *The Trade Desk: A media buying platform.* <https://www.thetradedesk.com/>
20. *Taboola.* (n.d.). *Taboola: Native advertising platform.* <https://www.taboola.com/>
21. *AppLovin.* (n.d.). *AppLovin: Mobile app monetization and marketing.* <https://www.applovin.com/>

**Denys Korotin**

3rd year Postgraduate Student, Group AKSM-31

State University of Information and Communication Technologies: Kyiv, Ukraine

ORCID ID: 0000-0001-7239-2101

d.korotin@stud.duikt.edu.ua**Natalia Lashchevska**

Doctor (Candidate) of Technical Sciences, Associate Professor

State University of Information and Communication Technologies: Kyiv, Ukraine

ORCID ID: 0000-0003-2148-115X

n.lashchevska@duikt.edu.ua**USING MACHINE LEARNING IN REAL-TIME BIDDING**

Abstract. The relevance of the study is stipulated by the need for automated and prompt decision-making in real-time bidding systems (RTB) operating in the dynamic environment of digital advertising based on a large number of user and contextual parameters. Given the growth of data volumes and high requirements for content personalization, there is a need to implement more flexible and adaptive algorithms. The purpose of the article is to study the potential of integrating machine learning (ML) methods into the processes of managing advertising rates in order to increase the relevance of ads and the effectiveness of advertising campaigns in an unstable market environment. The study applies structural-functional, analytical and comparative approaches to studying the architecture of RTB systems, as well as modeling algorithms for real-time recommendation decisions. Particular attention is paid to such factors as input data quality, model update frequency, system adaptability, and application programming interface (API) integration. It is found that the most commonly used methods in practice are logistic regression, gradient boosting, deep neural networks, and reinforcement learning (reinforcement learning is a method in which a model is trained through successive decision-making with reward or punishment). It is proved that the effectiveness of advertising strategies increases significantly when using such indicators as key performance indicators (KPIs) and customer lifetime value (LTV). The main limitations of ML implementation in RTB systems are identified: insufficient computing resources, low interpretability of algorithms, and risks of over-automation. The expediency of applying hybrid models with a combination of offline and online analysis, as well as the use of explainable AI to increase the transparency of decision-making is substantiated. The scientific novelty lies in the systematization of factors that critically affect the accuracy of forecasts in a dynamic advertising environment. The prospect of further research is the creation of models that are resistant to the limitations of personalized data and capable of context-dependent self-updating.

Keywords: digital advertising; forecasting algorithms; adaptive models; behavioral data processing; dynamic pricing; personalized content; computational optimization.

REFERENCES (TRANSLATED AND TRANSLITERATED)

1. Chen, C., Wang, G., Liu, B., Liu, T., Zhang, H., He, L., Wu, Z., Yang, Z., Du, D., & Zhang, Y. (2025). Real-time bidding with multi-agent reinforcement learning in multi-channel display advertising. *Neural Computing and Applications*, 37, 499–511. <https://doi.org/10.1007/s00521-024-10649-6>
2. Qiu, H., Feng, Y., Yang, G., Fan, C., & Zhu, H. (2024). Time Slot Bidding Optimization Strategy Based on TD3 in Real-Time Bidding. *2024 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 4745–4750. <https://doi.org/10.1109/SMC54092.2024.10831596>
3. Chen, S., Zhou, M., Liu, Y., Gao, L., & Zhang, Y. (2023). Model-based reinforcement learning for auto-bidding in display advertising. *Proceedings of the 2023 International Conference on Autonomous Agents and Multiagent Systems*, 1560–1568. <https://www.ifaamas.org/Proceedings/aamas2023/pdfs/p1560.pdf>
4. Sharma, P. (2023). *Improving Real-Time Bidding in Online Advertising Using Markov Decision Processes and Machine Learning Techniques*. arXiv preprint. <https://doi.org/10.48550/arXiv.2305.04889>
5. Cai, L., He, J., Li, Y., Liang, J., Lin, Y., Quan, Z., Zeng, Y., & Xu, J. (2025). *RTBAgent: A LLM-based Agent System for Real-Time Bidding*. arXiv preprint. <https://doi.org/10.48550/arXiv.2502.00792>



6. Miralles-Pechuán, L., Qureshi, M. A., & Namee, B. M. (2023). Real-time bidding campaigns optimization using user profile settings. *Electronic Commerce Research*, 23, 1297–1322. <https://doi.org/10.1007/s10660-021-09513-9>
7. Qin, C., Hu, C., & Feng, Y. (2025). A novel bidding strategy based on dynamic targeting in real-time bidding market. *Electronic Commerce Research*, 25, 1067–1088. <https://doi.org/10.1007/s10660-023-09714-4>
8. Chiappa, A. S., Gangopadhyay, B., Wang, Z., & Takamatsu, S. (2024). *Auto-bidding in real-time auctions via Oracle Imitation Learning*. arXiv preprint. <https://doi.org/10.48550/arXiv.2412.11434>
9. Ou, W., Chen, B., Dai, X., Zhang, W., Liu, W., Tang, R., & Yu, Y. (2023). A survey on bid optimization in real-time bidding display advertising. *ACM Transactions on Knowledge Discovery from Data*, 18(3), 1–31. <https://doi.org/10.1145/3628603>
10. Jha, A., Jain, H., Sharma, P., Sharma, Y., & Tiwari, K. (2024). Optimizing Real-Time Bidding Strategies: An Experimental Analysis of Reinforcement Learning and Machine Learning Techniques. *Procedia Computer Science*, 235, 2017–2026. <https://doi.org/10.1016/j.procs.2024.04.191>
11. Tang, X., & Yu, H. (2025). Towards trustworthy AI-empowered real-time bidding for online advertisement auctioning. *ACM Computing Surveys*, 57(6), 1–36. <https://doi.org/10.1145/370174>
12. Shih, W.-Y., Lai, H.-C., & Huang, J.-L. (2023). A Robust Real Time Bidding Strategy Against Inaccurate CTR Predictions by Using Cluster Expected Win Rate. *IEEE Access*, 11, 126917–126926. <https://doi.org/10.1109/ACCESS.2023.3332029>
13. Afzali, M., Khosravani, K., & Babazadeh, M. (2023). Optimal Bidding Strategy with Smooth Budget Delivery in Online Advertising. *2023 31st International Conference on Electrical Engineering (ICEE)*, 315–321. <https://doi.org/10.1109/ICEE59167.2023.10334752>
14. Google Display Network. (n.d.). <https://ads.google.com/home/campaigns/display-ads/>
15. Meta for Business. (n.d.). <https://www.facebook.com/business/ads>
16. Amazon DSP. (n.d.). <https://advertising.amazon.com/en/products/dsp>
17. TikTok Ads. (n.d.). <https://ads.tiktok.com/>
18. Alibaba DAMO Academy –DeepFM. (n.d.). <https://damo.alibaba.com/labs/ai/>
19. The Trade Desk. (n.d.). *The Trade Desk: A media buying platform*. <https://www.thetradedesk.com/>
20. Taboola. (n.d.). *Taboola: Native advertising platform*. <https://www.taboola.com/>
21. AppLovin. (n.d.). *AppLovin: Mobile app monetization and marketing*. <https://www.applovin.com/>

