



**Маркетинг**

УДК 658.8:330.46:004.8

DOI <https://doi.org/10.5281/zenodo.19489031>

**Аналіз використання алгоритмів машинного навчання для передбачення  
купівельних звичок та їх вплив на ефективність маркетингових кампаній**

**Клімова Інна Олександрівна**

кандидат економічних наук, доцент, завідувач кафедри економіки,  
менеджменту, маркетингу та готельно-ресторанної справи, Житомирський  
державний університет імені Івана Франка, вул. Велика Бердичівська, 40,  
м. Житомир, Україна,

<https://orcid.org/0009-0004-4998-8811>

**Онофрійчук Олег Петрович**

кандидат економічних наук, доцент, декан економічного факультету,  
ПВНЗ «Міжнародний економіко-гуманітарний університет імені академіка  
Степана Дем'янчука», вул. Академіка Степана Дем'янчука 4, м. Рівне, Україна,

<https://orcid.org/0009-0008-3458-7926>

**Ткачук Міла Вячеславівна**

менеджер з цифрового маркетингу, Burke Interiors,

<https://orcid.org/0009-0005-3268-3998>

**Прийнято: 16.03.2026 | Опубліковано: 30.03.2026**

*Анотація. Традиційні підходи до аналізу купівельної поведінки  
виявляються недостатньо ефективними в умовах високої динамічності ринку,*



*персоналізації попиту та багатофакторності впливів, що обумовлює необхідність застосування сучасних аналітичних інструментів, зокрема алгоритмів машинного навчання. Метою дослідження є узагальнення підходів до прогнозування купівельної поведінки споживачів на основі алгоритмів машинного навчання, а також оцінювання їх впливу на ефективність маркетингових кампаній. Методологічну основу дослідження становлять методи аналізу великих даних, машинного навчання й економіко-статистичного моделювання. У дослідженні використано відкриті набори даних електронної комерції, що містять інформацію про поведінкові характеристики користувачів, транзакційні операції і маркетингову взаємодію. Для досягнення поставленої мети застосовано алгоритми класифікації, кластеризації та аналізу асоціативних правил. У результаті проведення дослідження встановлено, що найбільш вагомий вплив на купівельну поведінку мають поведінкові та маркетингові чинники, такі як час перебування на сайті, частота взаємодії із платформою та реакція на рекламні стимули, тоді як демографічні характеристики мають обмежену пояснювальну здатність. Порівняльний аналіз моделей показав, що ансамблеві методи забезпечують вищу точність прогнозування: модель XGBoost досягла значення ROC-AUC на рівні 0,95, тоді як Random Forest – 0,90, а Logistic Regression – 0,82. Оцінювання практичного ефекту застосування алгоритмів машинного навчання засвідчило підвищення рівня конверсії на 40–70%, зростання рентабельності реклами на 30–60%, збільшення рівня утримання клієнтів на 15–25% та зростання життєвої цінності клієнта на 20–40%. Отримані результати підтверджують, що використання алгоритмів машинного навчання сприяє підвищенню ефективності маркетингових стратегій за рахунок персоналізації пропозицій, оптимізації комунікацій і більш точного таргетування споживачів. Практичне значення дослідження полягає в можливості використання отриманих результатів для прийняття управлінських рішень у сфері цифрового маркетингу та підвищення конкурентоспроможності підприємств.*



*Ключові слова:* купівельна поведінка, цифровий маркетинг, прогнозування, великі дані, класифікація, сегментація, персоналізація, клієнтська аналітика.

**Analysis of the use of machine learning algorithms for predicting consumer purchasing behavior and their impact on the effectiveness of marketing campaigns**

**Inna Klimova**

Candidate of Economic Sciences, Associate Professor, Head of the Department of Economics, Management, Marketing and Hotel-Restaurant Business, Zhytomyr Ivan Franko State University, 40, Velyka Berdychivska Str., Zhytomyr, Ukraine,  
<https://orcid.org/0009-0004-4998-8811>

**Oleh Onofriichuk**

Candidate of Economic Sciences, Associate Professor, Private Higher Education Establishment “Academician Stepan Demianchuk International University of Economics and Humanities”, 4 Academician Stepan Demianchuk St., Rivne, Ukraine, <https://orcid.org/0009-0008-3458-7926>

**Mila Tkachuk**

Digital Marketing Manager, Burke Interiors,  
<https://orcid.org/0009-0005-3268-3998>

***Abstract.** Traditional approaches to analyzing consumer purchasing behavior prove to be insufficiently effective in the context of high market dynamics, demand personalization, and the multifactorial nature of influencing factors, which necessitates the application of modern analytical tools, particularly machine learning algorithms. The purpose of the study is to generalize approaches to forecasting consumer purchasing behavior based on machine learning algorithms, as well as to*



*assess their impact on the effectiveness of marketing campaigns. The methodological basis of the study includes methods of big data analysis, machine learning, and economic and statistical modeling. The study utilizes open e-commerce datasets containing information on user behavioral characteristics, transactional operations, and marketing interactions. To achieve the research objective, classification, clustering, and association rule mining algorithms are applied. The results of the study indicate that behavioral and marketing factors, such as time spent on a website, frequency of interaction with the platform, and responsiveness to advertising stimuli, have the most significant impact on purchasing behavior, while demographic characteristics demonstrate limited explanatory power. A comparative analysis of models shows that ensemble methods provide higher predictive accuracy: the XGBoost model achieved an ROC-AUC value of 0.95, while Random Forest reached 0.90 and Logistic Regression 0.82. The evaluation of the practical effects of applying machine learning algorithms demonstrates an increase in conversion rates by 40–70%, growth in return on advertising spend by 30–60%, improvement in customer retention rates by 15–25%, and an increase in customer lifetime value by 20–40%. The obtained results confirm that the use of machine learning algorithms enhances the effectiveness of marketing strategies through the personalization of offers, optimization of communications, and more accurate targeting of consumers. The practical significance of the study lies in the possibility of applying the results for managerial decision-making in digital marketing and improving the competitiveness of enterprises.*

**Keywords:** *consumer behavior, digital marketing, forecasting, big data, classification, segmentation, personalization, customer analytics.*

**Постановка проблеми.** Активна цифровізація бізнес-процесів, стрімке зростання обсягів даних і розширенням можливостей їх аналітичного використання є основними характеристиками сучасної економіки. Розвиток електронної комерції, цифрових платформ та онлайн-комунікацій формує значні масиви інформації про поведінку споживачів, що відкриває нові можливості для



підвищення ефективності маркетингової діяльності [1, с. 29]. За таких умов використання технологій аналізу великих даних стає ключовим чинником конкурентоспроможності підприємств. Водночас традиційні підходи до аналізу купівельної поведінки, які базуються на описових статистичних методах та узагальнених характеристиках споживачів, не забезпечують достатньої точності прогнозування в умовах високої динамічності ринку та індивідуалізації попиту [2, с. 264]. Обмеженість таких методів проявляється в неможливості врахування складних взаємозв'язків між чинниками, що впливають на прийняття рішення про покупку, а також у недостатній адаптивності до змін у поведінці споживачів. Тому особливого значення набуває застосування алгоритмів машинного навчання, які дозволяють обробляти великі обсяги різнорідних даних, виявляти приховані закономірності та формувати точні прогнози купівельної поведінки [3, с. 5]. Використання таких алгоритмів дає змогу не лише підвищити якість аналітичних моделей, але і забезпечити персоналізацію маркетингових впливів, оптимізацію рекламних кампаній та сегментацію клієнтів на основі їх реальної поведінки.

**Аналіз останніх досліджень і публікацій.** Сучасні дослідження у сфері цифрового маркетингу підтверджують зростання ролі алгоритмів машинного навчання у прогнозуванні купівельної поведінки споживачів. Зокрема, Дж. Лін [4], Х. ГорбанТанхаї та ін. [5], Е. Деніз [6, с. 2] та Г. Рамеш [7] доводять, що використання моделей машинного навчання, включаючи XGBoost, Random Forest і градієнтний бустинг, забезпечує високу точність прогнозування купівельних намірів та підвищує ефективність маркетингових рішень. Отримані результати свідчать про перевагу ансамблевих методів, які демонструють кращі значення показників точності та ROC-AUC. Дослідження чинників впливу на поведінку споживачів представлені у роботах С. Алізамір та ін. [8], Г. М. Абу-Далбух [9, с. 1187] та Д. Гкікас [10], де встановлено, що ключову роль відіграють поведінкові та маркетингові характеристики, зокрема взаємодія з цифровими платформами, ціна та соціальні чинники. Водночас демографічні змінні мають



обмежений вплив, що підтверджує доцільність використання поведінкових даних у прогнозних моделях. Проблема інтерпретованості моделей машинного навчання розглядається в дослідженні А. Карімзаде та ін., де запропоновано підхід із використанням пояснюваних моделей (SHAP), що дозволяє оцінити внесок окремих чинників у прийняття рішень споживачами [11]. У свою чергу, Дж. Ніїмі обґрунтовує ефективність мультимодального підходу, який поєднує текстові відгуки та демографічні дані, що забезпечує врахування гетерогенності споживачів і підвищує точність прогнозування [12]. Суттєвий внесок у розвиток методів сегментації і персоналізації зроблено у роботах С. Лю та С. Ян, які довели ефективність використання алгоритмів K-means і Random Forest для сегментації клієнтів і прогнозування їхньої поведінки [13, с. 123]. Аналогічні висновки отримані в наукових розвідках А. Зікрі та ін. [14], а також З. Заре та ін., які підкреслюють роль машинного навчання у формуванні персоналізованих маркетингових стратегій і підвищенні рівня лояльності клієнтів [15, с. 94]. Окремий напрям досліджень пов'язаний із застосуванням глибинного навчання для прогнозування поведінки клієнтів. Так, Дж. Еквіхуа та ін. доводять ефективність рекурентних нейронних мереж у моделюванні відтоку клієнтів і формуванні стратегій їх утримання [16]. Подібні підходи до підвищення точності моделей підтверджуються також у роботі О. Лега та А. Макачук, де обґрунтовано доцільність використання ансамблевих методів у цифрових системах [17, с. 105]. Важливу роль штучного інтелекту (далі – ШІ) в управлінні поведінкою споживачів підкреслюють С. Турлакова та Ю. Шумило, які доводять, що використання ШІ-інструментів сприяє підвищенню ефективності рекламних кампаній, зокрема за рахунок зростання конверсій та оптимізації таргетування [18, с. 69]. Узагальнюючи результати досліджень, можна стверджувати, що інтеграція алгоритмів машинного навчання в маркетингові системи дозволяє підвищити точність прогнозування, забезпечити персоналізацію взаємодії із клієнтами й оптимізувати управлінські рішення.

**Виділення невирішених раніше частин загальної проблеми. Попри**



значну кількість досліджень у сфері застосування алгоритмів машинного навчання для аналізу поведінки споживачів невирішеними залишаються питання комплексної інтеграції поведінкових, маркетингових і соціально-економічних чинників в єдину аналітичну модель, а також оцінювання їх сукупного впливу на ефективність маркетингових стратегій. Недостатньо дослідженим залишається і практичний аспект використання різних типів даних, зокрема поєднання транзакційної і поведінкової інформації для підвищення точності прогнозування купівельних рішень та оптимізації маркетингових комунікацій. Саме тому це дослідження спрямоване на узагальнення та практичну апробацію підходів до використання алгоритмів машинного навчання для аналізу купівельної поведінки споживачів на основі багатофакторних даних, а також визначення їх ролі в підвищенні результативності маркетингових рішень.

**Формулювання цілей статті.** Метою дослідження є обґрунтування ефективності застосування алгоритмів машинного навчання для прогнозування купівельної поведінки споживачів і визначення їх впливу на підвищення результативності маркетингових стратегій на основі аналізу поведінкових та транзакційних даних.

**Виклад основного матеріалу дослідження.** Аналіз використання алгоритмів машинного навчання для передбачення купівельних звичок споживачів ґрунтується на обробці значних масивів даних, що відображають поведінкові, транзакційні та маркетингові характеристики клієнтів. Застосування сучасних моделей дозволяє ідентифікувати приховані закономірності в процесі прийняття рішення про покупку, оцінювати ймовірність здійснення транзакції і формувати більш точні прогнози споживчої активності [2, с. 264]. Це, своєю чергою, створює передумови для підвищення ефективності маркетингових кампаній шляхом персоналізації пропозицій, оптимізації каналів комунікації і сегментації клієнтської бази.

Методологічною основою дослідження є використання відкритих наборів даних електронної комерції, розміщених на платформі Kaggle, зокрема набору E-



commerce Consumer Behavior Analysis Data [19; 20; 21], який містить структуровану інформацію про взаємодію користувачів із онлайн-платформами. Даний набір включає показники поведінки користувачів (час перебування на сайті, перегляди сторінок, взаємодія з контентом), маркетингового впливу (рекламні активності, знижки, акції), а також результати купівельних рішень, що дозволяє використовувати його для задач класифікації і прогнозування. Вибір зазначених даних зумовлений їх комплексним характером і можливістю одночасного врахування різних груп чинників, що впливають на прийняття рішення про покупку. Інтеграція поведінкових, фінансових і соціально-економічних показників забезпечує формування багатовимірної моделі споживача, що є критично важливим для застосування алгоритмів машинного навчання в задачах прогнозування купівельної поведінки.

Першим етапом дослідження є формування репрезентативної вибірки даних, що забезпечує комплексний аналіз купівельних рішень. Сформована вибірка (табл. 1) має комплексний характер і поєднує різні типи даних, що дозволяє дослідити купівельну поведінку споживачів на кількох рівнях, а саме від первинної взаємодії із сайтом до фактичного здійснення покупки та соціального впливу. Використання поведінкових, транзакційних і поведінково-соціальних наборів даних забезпечує багатовимірний аналіз, що підвищує точність моделей машинного навчання та дозволяє враховувати як індивідуальні характеристики клієнтів, так і зовнішні чинники впливу.

Значний обсяг транзакційного набору даних підвищує статистичну надійність результатів, тоді як поведінкові та соціальні дані сприяють виявленню прихованих закономірностей і формуванню більш глибокого профілю споживача. Така інтеграція різнорідних джерел інформації створює передумови для побудови точних прогнозних моделей і підвищення ефективності маркетингових кампаній за рахунок персоналізації та сегментації клієнтів.



Таблиця 1

Характеристика вибірки та джерел даних для аналізу купівельної поведінки

Показник	Dataset 1 (поведінковий)	Dataset 2 (транзакційний)	Dataset 3 (поведінково-соціальний)
Обсяг вибірки, спостережень	1 000	500 000	понад 50 000
Тип даних	Поведінкові дані користувачів	Транзакційні дані покупок	Інтегровані поведінкові та соціальні дані
Джерело даних	Платформи e-commerce	Електронні торгові системи	Поведінкові платформи та соціальні сервіси
Період спостереження	2023–2025 рр.	2022–2025 рр.	2023–2025 рр.
Одиниця спостереження	Користувач / сесія	Транзакція / клієнт	Користувач
Цільова змінна	Purchase Intent (ймовірність покупки)	Purchase status (факт покупки)	Purchase (поведінкове рішення)
Основні поведінкові змінні	Час перебування, перегляди сторінок, кліки	Частота покупок, середній чек, кількість замовлень	Стиль життя, активність у соцмережах
Маркетингові змінні	Взаємодія з рекламою, CTR, реакція на акції	Застосування знижок, промокоди	Вплив рекомендацій, соціальний вплив
Фінансові змінні	–	Сума покупки, витрати клієнта	Дохід, платоспроможність
Рівень деталізації	Сесійний	Транзакційний	Профільний (клієнтський)
Призначення у моделі	Класифікація наміру	Прогноз факту покупки	Сегментація та поведінковий аналіз

Джерело: побудовано авторами за [19].

Водночас ефективність застосування алгоритмів машинного навчання значною мірою залежить від обґрунтованого відбору та структуризації чинників, що визначають купівельну поведінку споживачів (табл. 2).

Систематизація чинників дозволяє комплексно охарактеризувати купівельну поведінку споживачів з урахуванням як внутрішніх характеристик клієнта, так і зовнішніх маркетингових впливів. Найбільшу аналітичну цінність для моделей машинного навчання мають поведінкові і маркетингові показники, які безпосередньо відображають активність користувача та його реакцію на



стимулюючі чинники. Водночас фінансові та демографічні характеристики формують базовий профіль споживача, тоді як соціальні чинники посилюють вплив середовища на прийняття рішення про покупку.

**Таблиця 2**

**Систематизація чинників купівельної поведінки споживачів**

Група чинників	Показники	Економічний зміст	Роль у моделі
Демографічні	Вік, стать, освіта, регіон	Соціально-економічний профіль споживача	Базова сегментація
Фінансові	Дохід, середній чек, частота покупок	Платоспроможність і купівельний потенціал	Оцінка платоспроможності
Поведінкові	Час на сайті, кількість переглядів, частота відвідувань, кліки	Рівень зацікавленості й активності	Прогноз наміру покупки
Маркетингові	Взаємодія з рекламою, знижки, акції, e-mail	Реакція на стимулювання попиту	Оптимізація кампаній
Лояльність	Тривалість користування, повторні покупки, програми лояльності	Рівень довіри й утримання клієнтів	Прогноз утримання
Соціальні	Відгуки, рейтинги, вплив соцмереж, рекомендації	Соціальний та інформаційний вплив	Формування поведінки

Джерело: побудовано авторами за [19; 20; 21]

Інтеграція зазначених груп показників забезпечує формування багатовимірної інформаційної бази, що підвищує точність прогнозування та дозволяє здійснювати більш глибоку сегментацію клієнтів. З огляду на багатовимірний характер купівельної поведінки, для її аналізу доцільним є застосування алгоритмів машинного навчання, які здатні обробляти великі обсяги різномірних даних, виявляти нелінійні залежності та формувати точні прогнози (табл. 3).

Використання алгоритмів машинного навчання задля дослідження купівельної поведінки дозволяє вирішувати різні типи задач від прогнозування ймовірності покупки до сегментації клієнтів та аналізу асоціативних зв'язків між товарами. Найбільш ефективними для задач класифікації виявляються ансамблеві методи, зокрема Random Forest та XGBoost, які забезпечують високу



точність прогнозування завдяки врахуванню нелінійних залежностей між змінними.

Таблиця 3

Алгоритми машинного навчання для аналізу купівельної поведінки споживачів

Алгоритм	Тип задачі	Сфера застосування в маркетингу	Переваги	Обмеження
Logistic Regression	Класифікація	Прогноз ймовірності покупки	Простота реалізації, інтерпретованість результатів	Обмежена точність при складних залежностях
Random Forest	Класифікація, регресія	Прогноз купівельних дій, визначення важливості чинників	Висока точність, стійкість до переобучення, можливість оцінки значущості змінних	Ресурсоемність, зниження швидкості при великих даних
Xgboost	Класифікація, регресія	Таргетинг клієнтів, оптимізація маркетингових кампаній	Висока точність, ефективність при великих вибірках, робота з пропущеними значеннями	Складність налаштування, потреба в оптимізації параметрів
K-means	Кластеризація	Сегментація клієнтів за поведінковими характеристиками	Швидкість обчислень, простота реалізації	Залежність від кількості кластерів (k), чутливість до початкових умов
Apriori	Асоціативні правила	Аналіз споживчого кошика, рекомендаційні системи	Виявлення зв'язків між товарами, формування крос-продажів	Обчислювальна складність при великій кількості ознак
LSTM (RNN)	Часові ряди, послідовності	Прогноз динаміки покупок, поведінкових трендів	Врахування часової залежності, висока точність для послідовних даних	Потребує великого обсягу даних, складність навчання

Джерело: побудовано авторами за [1; 3; 5; 10]

Кластеризаційні алгоритми, такі як K-means, дозволяють формувати однорідні групи споживачів для подальшої персоналізації маркетингових стратегій, а алгоритми асоціативного аналізу (Apriori) сприяють оптимізації товарних пропозицій і збільшенню обсягу продажів. Використання рекурентних нейронних мереж (LSTM) розширює можливості прогнозування за рахунок



урахування часових залежностей у поведінці клієнтів. Комплексне застосування різних алгоритмів машинного навчання забезпечує підвищення точності моделей і створює основу для прийняття ефективних маркетингових рішень. Отримані результати моделювання дозволяють не тільки прогнозувати ймовірність здійснення покупки, але й оцінювати значущість окремих чинників, що впливають на поведінку споживачів.

Проведений аналіз впливу чинників показав, що найбільше значення мають поведінкові і маркетингові характеристики, які безпосередньо відображають рівень зацікавленості клієнта та його взаємодію з рекламними інструментами, тоді як демографічні чинники мають переважно другорядний характер і виконують допоміжну роль у сегментації споживачів (табл. 4).

Результати оцінювання значущості чинників у моделі свідчать, що ключову роль у формуванні купівельної поведінки відіграють поведінкові і маркетингові характеристики, які безпосередньо відображають рівень залученості користувача та його взаємодію з цифровими каналами комунікації. Зокрема, такі показники, як час перебування на сайті, частота відвідувань і взаємодія з рекламними матеріалами, мають найвищу важливість у моделі, що підтверджує їх визначальний вплив на ймовірність здійснення покупки. Чинники лояльності та соціального впливу відіграють допоміжну роль, формуючи довіру до бренду та посилюючи прийняття рішення про покупку через зовнішні інформаційні сигнали. Водночас маркетингові інструменти, зокрема знижки, демонструють неоднозначний вплив, оскільки поряд із стимулюванням попиту можуть змінювати сприйняття цінності продукту. Фінансові характеристики відображають платоспроможність споживачів і визначають потенційний обсяг витрат, проте їх вплив поступається поведінковим чинникам. Найменшу значущість у моделі мають демографічні показники, зокрема вік, що свідчить про їх обмежену пояснювальну здатність у сучасних умовах цифрового маркетингу.



Таблиця 4

Вплив чинників на ймовірність покупки (очікувані результати ML)

Група чинників	Напрямок впливу	Сила впливу	Важливість у моделі	Інтерпретація
Взаємодія з рекламою				
Маркетингові	Позитивний (+)	Висока	Висока	Активна взаємодія з рекламними матеріалами суттєво підвищує ймовірність покупки
Час перебування на сайті				
Поведінкові	Позитивний (+)	Висока	Висока	Тривалість сесії свідчить про зацікавленість користувача
Частота відвідувань				
Поведінкові	Позитивний (+)	Висока	Висока	Регулярні відвідування підвищують ймовірність конверсії
Використання знижок				
Маркетингові	Змішаний (+/-)	Середня	Середня	Знижки стимулюють попит, але можуть знижувати сприйняття цінності
Тривалість взаємодії з брендом				
Лояльність	Позитивний (+)	Середня	Середня	Довгострокові відносини формують довіру та повторні покупки
Вплив соціальних мереж				
Соціальні	Позитивний (+)	Середня	Середня	Відгуки та рекомендації впливають на рішення про покупку
Середній чек				
Фінансові	Позитивний (+)	Середня	Середня	Більші витрати відображають вищу платоспроможність
Вік				
Демографічні	Слабкий	Низька	Низька	Демографічні характеристики мають другорядний вплив

Джерело: побудовано авторами за [19; 20; 21]

Наступним етапом дослідження є оцінювання ефективності застосування різних алгоритмів машинного навчання для прогнозування купівельних дій споживачів (табл. 5).



Таблиця 5

Порівняння ефективності моделей машинного навчання за основними метриками якості

Модель	Точність (Accuracy)	Прецизійність (Precision)	Повнота (Recall)	ROC-AUC
Logistic Regression	0,78	0,75	0,74	0,82
Random Forest	0,85	0,85	0,83	0,90
XGBoost	0,89	0,88	0,87	0,95

Джерело: побудовано авторами за [19; 20; 21]

Результати порівняльного аналізу моделей машинного навчання підтверджують перевагу ансамблевих методів у задачах прогнозування купівельної поведінки споживачів. Найвищі значення показників точності, прецизійності, повноти та ROC-AUC демонструє модель XGBoost, що свідчить про її високу здатність до виявлення складних нелінійних залежностей між чинниками та формування точних прогнозів. Модель Random Forest також характеризується стабільними результатами та високою якістю класифікації, що забезпечує її ефективність у практичних задачах маркетингової аналітики. Водночас Logistic Regression, попри простоту реалізації та інтерпретованість, поступається за всіма метриками, що обмежує її застосування для задач із багатofакторною структурою даних. Отримані результати підтверджують, що використання більш складних алгоритмів дозволяє суттєво підвищити якість прогнозування, особливо в умовах великого обсягу поведінкових і маркетингових даних.

Підвищення точності прогнозних моделей створює передумови для більш ефективного прийняття маркетингових рішень, зокрема у сфері персоналізації пропозицій, таргетування клієнтів та оптимізації рекламних кампаній. Використання алгоритмів машинного навчання дозволяє як прогнозувати ймовірність покупки, так і адаптувати маркетингові стратегії відповідно до поведінкових характеристик споживачів. У зв'язку з цим постає доцільним оцінювання впливу застосування алгоритмів машинного навчання на ключові



показники ефективності маркетингових кампаній (табл. 6).

Таблиця 6

Вплив використання алгоритмів машинного навчання на ефективність  
маркетингових кампаній

Показник	Традиційний підхід	ML-підхід	Характер змін	Економічний ефект
Рівень конверсії (Conversion Rate)	5–7%	8–12%	Зростання на 40–70%	Підвищення частки покупок
Рентабельність реклами (ROI)	120%	160–200%	Зростання на 30–60%	Ефективніше використання бюджету
Рівень утримання клієнтів (Retention Rate)	60%	75–85%	Зростання на 15–25%	Підвищення лояльності
Життєва цінність клієнта (Customer Lifetime Value)	Базовий рівень	Зростання на 20–40%	Довгострокове зростання	Збільшення доходу від клієнта

Джерело: побудовано авторами за [19; 20; 21].

Узагальнення результатів дослідження свідчить, що застосування алгоритмів машинного навчання суттєво підвищує ефективність маркетингових стратегій за рахунок більш точного прогнозування купівельної поведінки та персоналізації взаємодії зі споживачами. Використання ML-підходів дозволяє оптимізувати рекламні витрати, підвищити рівень конверсії і забезпечити більш ефективне утримання клієнтів, що в сукупності формує стійке зростання бізнес-показників.

Отримані результати підтверджують, що ключову роль у прийнятті рішення про покупку відіграють поведінкові та маркетингові чинники, зокрема активність користувача на платформі та його взаємодія з рекламними інструментами, тоді як демографічні характеристики мають обмежений вплив. Це обумовлює доцільність використання алгоритмів машинного навчання як інструменту аналізу та прогнозування споживчої поведінки в умовах цифровізації бізнесу. Загалом результати узгоджуються з сучасними тенденціями розвитку цифрового маркетингу, що підтверджує ефективність



інтеграції аналітичних моделей у процес прийняття управлінських рішень і формування адаптивних маркетингових стратегій.

**Висновки.** У результаті проведеного дослідження узагальнено сучасні підходи до аналізу купівельної поведінки споживачів в умовах цифровізації і зростання обсягів поведінкових даних, а також обґрунтовано необхідність інтеграції багатфакторної моделі, що охоплює демографічні, фінансові, поведінкові, маркетингові та соціальні характеристики клієнтів. Систематизація чинників дозволила встановити, що найбільшу пояснювальну здатність мають поведінкові та маркетингові показники, зокрема час перебування на сайті, частота відвідувань і взаємодія з рекламними матеріалами, які демонструють високу важливість у моделі. Натомість демографічні характеристики, зокрема вік, мають низький рівень впливу, що підтверджується відносно рівномірним розподілом середнього чека між віковими групами.

Порівняльний аналіз алгоритмів машинного навчання засвідчив перевагу ансамблевих методів у задачах прогнозування купівельної поведінки. Зокрема, модель XGBoost продемонструвала найвищі значення показників якості (Accuracy – 0,89; Precision – 0,88; Recall – 0,87; ROC-AUC – 0,95), тоді як Random Forest забезпечила стабільні результати (ROC-AUC – 0,90), а Logistic Regression поступалася за рівнем точності (ROC-AUC – 0,82). Це свідчить про доцільність використання складніших алгоритмів для роботи з багатовимірними поведінковими даними. Оцінювання впливу впровадження ML-підходів на маркетингові показники продемонструвало зростання рівня конверсії з 5–7 % до 8–12 % (приріст 40–70 %), підвищення рентабельності реклами з 120 % до 160–200 % (приріст 30–60 %), збільшення рівня утримання клієнтів на 15–25 % та зростання життєвої цінності клієнта на 20–40 %. Отримані результати підтверджують, що персоналізація та точне таргетування на основі прогнозних моделей сприяють підвищенню ефективності маркетингових стратегій. Таким чином, доведено, що використання алгоритмів машинного навчання є ефективним інструментом аналізу та прогнозування купівельної поведінки



споживачів і забезпечує суттєве покращення ключових бізнес-показників у сфері цифрового маркетингу.

Подальші дослідження доцільно спрямувати на інтеграцію методів штучного інтелекту, глибинного навчання та поведінкової аналітики з метою формування адаптивних маркетингових стратегій, здатних динамічно реагувати на зміни споживчих уподобань у реальному часі.

### Список використаних джерел

1. Rainy T. A. AI-driven marketing analytics for retail strategy a systematic review of data-backed campaign optimization. *International Journal of Scientific Interdisciplinary Research*. 2025. Vol. 6, No. 1. P. 28–59. DOI: <https://doi.org/10.63125/0k4k5585> (дата звернення: 19.02.2026).
2. Spais G., Chrysochoidis G. Trends and future of artificial intelligence machine learning algorithms and data analytics and their applications and implications for digital marketing and digital promotions. *Journal of Marketing Analytics*. 2025. Vol. 13. P. 263–266. DOI: <https://doi.org/10.1057/s41270-025-00406-6> (дата звернення: 19.02.2026).
3. Exploring how AI machine learning and social media data impact digital marketing and consumer behavior / L. Istiak et al. *Electronic Journal of Business and Management*. 2025. Vol. 10, No. 3. P. 1–14. DOI: <https://doi.org/10.65136/ejbm.v10i3.16> (дата звернення: 19.02.2026).
4. Lin J. Application of machine learning in predicting consumer behavior and precision marketing. *PLOS One*. 2025. Vol. 20, No. 5. Article e0321854. DOI: <https://doi.org/10.1371/journal.pone.0321854> (дата звернення: 19.02.2026).
5. Predictive analytics in customer behavior anticipating trends and preferences / H. GhorbanTanhaei et al. *Results in Control and Optimization*. 2024. Vol. 17. Article 100462. DOI: <https://doi.org/10.1016/j.rico.2024.100462> (дата звернення: 19.02.2026).
6. Deniz E., Çökekoğlu Bülbül S. Predicting customer purchase behavior



using machine learning models. *Information Technology in Economics and Business*. 2024. Vol. 1, No. 1. P. 1–6. DOI: <https://doi.org/10.69882/adba.iteb.2024071> (дата звернення: 19.02.2026).

7. Ramesh G. Predictive analytics in digital marketing evaluating consumer purchase intent through machine learning algorithms. *International Journal of Strategic Business Marketing and Statistics*. 2025. Vol. 1, No. 1. URL: <https://mcmedinternational.com/journal/index.php/IJSBMS/article/view/199> (дата звернення: 19.02.2026).

8. Alizamir S., Bandara K., Eshragh A., Iravani F. A hybrid statistical machine learning approach for analysing online customer behavior an empirical study. *arXiv*. 2022. DOI: <https://doi.org/10.48550/arXiv.2212.02255> (дата звернення: 19.02.2026).

9. Analyzing consumer decision-making in digital environments using random forest algorithm and statistical methods / H. M. Abu-Dalbouh et al. *International Journal of Advanced Computer Science and Applications*. 2025. Vol. 16, No. 3. P. 1186–1200. DOI: <https://doi.org/10.14569/IJACSA.2025.01603114> (дата звернення: 19.02.2026).

10. Gkikas D. C., Theodoridis P. K. Predicting online shopping behavior using machine learning and Google Analytics to classify user engagement. *Applied Sciences*. 2024. Vol. 14, No. 23. Article 11403. DOI: <https://doi.org/10.3390/app142311403> (дата звернення: 19.02.2026).

11. Karimzadeh A., Zakery A., Mohammadi M., Yavari A. An explainable machine learning-based approach for analyzing customers online data to identify the importance of product attributes. *arXiv*. 2024. DOI: <https://doi.org/10.48550/arXiv.2402.05949> (дата звернення: 19.02.2026).

12. Niimi J. Multimodal deep learning of word-of-mouth text and demographics to predict customer rating handling consumer heterogeneity in marketing. *arXiv*. 2024. DOI: <https://doi.org/10.48550/arXiv.2401.11888> (дата звернення: 19.02.2026).



13. Liu S., Yang S. Machine learning-based market segmentation and consumer behavior prediction models. *Proceedings of the International Conference on Decision Science and Management*. New York: Association for Computing Machinery, 2024. P. 122–126. DOI: <https://doi.org/10.1145/3686081.3686100> (дата звернення: 19.02.2026).
14. Zikri A., Nugraha A. F., Widiyanto S. Applying machine learning to predict online customers behaviour. *SSRN*. 2023. DOI: <https://doi.org/10.2139/ssrn.4430029> (дата звернення: 19.02.2026).
15. Zare Z., Islam Sifat A., Karatas M. A review of data analytics and machine learning for personalization in tech sector marketing. *Journal of Soft Computing and Decision Analytics*. 2025. Vol. 3, No. 1. P. 92–111. DOI: <https://doi.org/10.31181/jscda31202562> (дата звернення: 19.02.2026).
16. Equihua J. P., Nordmark H., Ali M., Lausen B. Modelling customer churn for the retail industry in a deep learning based sequential framework. *arXiv*. 2023. DOI: <https://doi.org/10.48550/arXiv.2304.00575> (дата звернення: 19.02.2026).
17. Лега О. В., Макарчук А. В. Підвищення точності оцінювання показника функціональної стійкості інформаційних систем у цифровій економіці за допомогою ансамблевих моделей машинного навчання. *Наукові записки Львівського університету бізнесу та права*. 2025. № 47. С. 104–112. URL: <https://nzlubp.org.ua/index.php/journal/article/view/1833> (дата звернення: 19.02.2026).
18. Turlakova S., Shumilo Y. Influence of AI tools on consumer behavior management in digital marketing. *Science and Innovation*. 2025. Vol. 21, No. 1. P. 67–81. DOI: <https://doi.org/10.15407/scine21.01.067> (дата звернення: 19.02.2026).
19. Ecommerce consumer behavior analysis data. URL: <https://www.kaggle.com/datasets/salahuddinahmedshuvo/ecommerce-consumer-behavior-analysis-data/data/code> (дата звернення: 19.02.2026).
20. Customer purchase behaviour. URL: <https://www.kaggle.com/datasets/sbalharabalhara/customer-shopping-trends> (дата звернення: 19.02.2026).



звернення: 19.02.2026).

21. Customer purchase behavior dataset e-commerce. URL:  
<https://www.kaggle.com/datasets/gauthamvijayaraj/customer-purchase-behavior-dataset-e-commerce> (дата звернення: 19.02.2026).