

Електронний журнал «Ефективна економіка» включено до переліку наукових фахових видань України з питань економіки (Категорія «Б», Наказ Міністерства освіти і науки України № 975 від 11.07.2019). Спеціальності – 051, 071, 072, 073, 075, 076, 292.
Ефективна економіка. 2025. № 12.

DOI: <http://doi.org/10.32702/2307-2105.2025.12.91>

УДК 334:716.

О. А. Стригіна,

к. ф.-м. н., доцент, доцент кафедри інформаційних технологій, вищої математики та фізики, Білоцерківський національний аграрний університет

ORCID ID: <https://orcid.org/0000-0001-8071-0982>

У. С. Ревуцька,

к. ф.-м. н., доцент, доцент кафедри інформаційних технологій, вищої математики та фізики, Білоцерківський національний аграрний університет

ORCID ID: <https://orcid.org/0009-0005-3652-9031>

В. В. Новікова,

к. е. н., доцент, доцент кафедри інформаційних технологій, вищої математики та фізики, Білоцерківський національний аграрний університет

ORCID ID: <https://orcid.org/0000-0001-7985-1489>

О. В. Ткаченко,

к. пед. н., доцент, доцент кафедри інформаційних технологій, вищої математики та фізики, Білоцерківський національний аграрний університет

ORCID ID: <https://orcid.org/0000-0002-2770-832X>

М. І. Трофимчук,

к. е. н., доцент, доцент кафедри інформаційних технологій, вищої математики та фізики, Білоцерківський національний аграрний університет

ORCID ID: <https://orcid.org/0000-0002-3125-8392>

**ЕКОНОМІКО-МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ ПОВЕДІНКИ
СПОЖИВАЧІВ У ЦИФРОВОМУ МАРКЕТИНГУ**

O. Strygina,

*PhD in Physico-Mathematical Science, Associate Professor, Associate Professor
of the Department of Information Technologies, Higher Mathematics and Physics,
Bila Tserkva National Agrarian University*

U. Revytska,

*PhD in Physico-Mathematical Science, Associate Professor, Associate Professor
of the Department of Information Technologies, Higher Mathematics and Physics,
Bila Tserkva National Agrarian University*

V. Novikova,

*PhD in Economic Science, Associate Professor, Associate Professor of the
Department of Information Technologies, Higher Mathematics and Physics,
Bila Tserkva National Agrarian University*

O. Tkachenko,

*PhD in Pedagogical Sciences, Associate Professor, Associate Professor of the
Department of Information Technologies, Higher Mathematics and Physics,
Bila Tserkva National Agrarian University*

M. Trofymchuk,

*PhD in Economic Science, Associate Professor, Associate Professor of the
Department of Information Technologies, Higher Mathematics and Physics,
Bila Tserkva National Agrarian University*

ECONOMIC AND MATHEMATICAL MODELING OF CONSUMER BEHAVIOR IN DIGITAL MARKETING

У статті досліджено підходи до економіко-математичного моделювання поведінки споживачів у середовищі цифрового маркетингу. Розглянуто сучасні моделі прогнозування попиту, оцінки конверсії, сегментації та персоналізації, що ґрунтуються на апараті машинного навчання, статистичних методах та оптимізаційних алгоритмах. Особливу

увагу приділено аналізу побудованих економіко-математичних моделей поведінки споживачів у цифровому маркетингу. Розглянуто результати логістичної регресії, кластеризації методом k -means, марковської моделі воронки та прогнозування часових рядів (ARIMA). Кожна з моделей дає змогу оцінити різні аспекти поведінки споживачів — і всі разом вони формують цілісне аналітичне бачення механізмів прийняття рішень у цифровому середовищі. У статті подано огляд сучасних моделей, що використовуються для аналізу онлайн-поведінки, сегментації аудиторії та прогнозування попиту.

The article explores approaches to economic and mathematical modeling of consumer behavior in the digital marketing environment. Modern models of demand forecasting, conversion estimation, segmentation, and personalization based on machine learning, statistical methods, and optimization algorithms are considered. Particular attention is paid to the analysis of constructed economic and mathematical models of consumer behavior in digital marketing. The results of logistic regression, k -means clustering, Markov funnel model, and time series forecasting (ARIMA) are considered. Each of the models allows you to assess different aspects of consumer behavior - and together they form a holistic analytical vision of decision-making mechanisms in the digital environment. The article provides an overview of modern models used for online behavior analysis, audience segmentation, and demand forecasting. The purpose of the article is to develop and scientifically substantiate economic and mathematical models of consumer behavior in digital marketing based on the integration of econometric approaches, machine learning methods and big data analysis, in order to increase the accuracy of predicting user reactions and optimize marketing decisions in a dynamic online environment. Analysis of the applied models showed that the comprehensive use of economic and mathematical methods provides a deep understanding of consumer behavior in the digital environment. The combined application of these models creates a powerful toolkit for making scientifically

based management decisions in the field of digital marketing. Economic and mathematical models are an important tool for analyzing and predicting consumer behavior in digital marketing. They allow you to increase the effectiveness of advertising campaigns, optimize marketing budgets, and provide personalization in user interactions. The use of modern mathematical methods - machine learning, recommendation systems, Markov models - creates new opportunities for business in the context of the development of digital technologies and increasing competition. Economic and mathematical models are a key tool in modern digital marketing. They provide a deep understanding of consumer behavior, increase the accuracy of forecasts, and allow you to optimize marketing processes.

Ключові слова: *логістична регресія, кластеризація, марковська модель воронки, прогнозування часових рядів, цифрове середовище.*

Keywords: *logistic regression, clustering, Markov funnel model, time series forecasting, digital environment.*

Постановка завдання. Сучасний цифровий маркетинг характеризується високою динамічністю, персоналізацією та значною залежністю від великих масивів поведінкових даних. Це зумовлює потребу в економіко-математичних моделях, здатних не лише описувати, але й прогнозувати реакції споживачів у цифровому середовищі. У науковій літературі дедалі більше уваги приділяється комбінуванню класичних економетричних методів із методами машинного навчання, що дає змогу підвищити точність прогнозів і відобразити складні поведінкові патерни споживачів. Економіко-математичні моделі забезпечують можливість прогнозувати реакції споживачів, оптимізувати рекламні бюджети та підвищувати ефективність маркетингових стратегій.

Аналіз останніх досліджень і публікацій. Одним із провідних напрямів досліджень є адаптація класичних економетричних моделей (регресійні підходи, моделі часових рядів, структурні моделі попиту) до

нових типів даних, отриманих від онлайн-користувачів. Наприклад, Antohi, et al. пропонують методологію інтеграції поведінкових цифрових змінних у економетричні моделі, що дозволяє краще описувати мотивації та фактори онлайн-покупок [1]. Дослідники підкреслюють, що класичні моделі залишаються важливою теоретичною основою, проте потребують розширення за рахунок нелінійних методів, адаптованих до високої мінливості цифрових середовищ. В останні роки зростає кількість праць, присвячених використанню великих даних (Big Data) і машинного навчання в аналізі споживчих патернів (моделюванні поведінки споживачів). Систематичний огляд Theodorakopoulos узагальнює підходи застосування Big Data для сегментації, прогнозування попиту та рекомендаційних систем, підкреслюючи роль алгоритмів кластеризації, градієнтного бустингу та нейронних мереж [2]. Особливу увагу приділяють також впливу персоналізованих алгоритмів та автоматизованих маркетингових стратегій на поведінку користувачів. У роботі Ribeiro показано, що алгоритмічна персоналізація суттєво впливає на емоційне залучення, довіру та інтенції покупки, хоча виникають питання прозорості та етичних ризиків [5]. Цифрові платформи генерують дані у режимі реального часу, що стимулює розвиток динамічних моделей, таких як марковські процеси, моделі адаптивного попиту, reinforcement learning (RL). Ці підходи дозволяють оптимізувати рекламні бюджети, ставки в RTB-системах та розподіл маркетингових ресурсів. Аналіз AI-інструментів у маркетингу, проведений Acatrinei et al. , підтверджує, що динамічні моделі тісно пов'язані з підвищенням ефективності взаємодії зі споживачами [3]. Такий підхід особливо релевантний для великих e-commerce платформ, де реакція користувачів може змінюватися щогодини. Новий напрям досліджень — аналіз того, як цифрові маркетингові стратегії впливають на сталу та екологічно орієнтовану поведінку споживачів: моделювання сталих і соціально відповідальних патернів споживання. Shao et al. демонструють, що Big Data-персоналізація може сприяти переходу до сталих купівельних рішень, але ефект суттєво

варіюється між сегментами користувачів [4]. У більшості робіт домінує прогностичний підхід, тоді як причинно-наслідкові методи (A/B-експерименти, інструментальні змінні, causal ML) використовуються обмежено. Це ускладнює оцінку реального впливу маркетингових втручань. Цифрові сліди містять шум, нерівномірність та змішання поведінки різних сегментів, що потребує спеціальних методів фільтрації та нормалізації. Багато досліджень наголошують на ризиках алгоритмічної дискримінації, маніпуляції та проблемах приватності. Це особливо актуально у контексті європейських регуляцій (GDPR, DSA). Огляд сучасної літератури демонструє, що економіко-математичне моделювання поведінки споживачів у цифровому маркетингу еволюціонує у напрямі гібридних підходів, які поєднують класичні економетричні моделі та методи машинного навчання. Тренди свідчать про зростання ролі Big Data, динамічних моделей та персоналізованих систем рекомендацій, тоді як основними науковими викликами залишаються каузальна ідентифікація, інтерпретованість алгоритмів та етичні обмеження.

Формулювання цілей статті. Метою статті є розроблення та наукове обґрунтування економіко-математичних моделей поведінки споживачів у цифровому маркетингу на основі інтеграції економетричних підходів, методів машинного навчання та аналізу великих даних, з метою підвищення точності прогнозування реакцій користувачів і оптимізації маркетингових рішень у динамічному онлайн-середовищі.

Виклад основного матеріалу дослідження. Цифровий маркетинг переживає динамічний розвиток, що зумовлено збільшенням кількості цифрових каналів, обсягів даних про поведінку користувачів та можливостей аналітичних інструментів. У таких умовах бізнес стикається з потребою у науково обґрунтованих методах прогнозування поведінки споживачів і прийняття рішень щодо оптимізації маркетингових стратегій. Економіко-математичні моделі дозволяють кількісно оцінити реакції споживачів на

маркетингові стимули, виявити закономірності їхньої поведінки та забезпечити основу для ефективного планування рекламних кампаній.

1. Теоретичні основи моделювання поведінки споживачів

Поведінка користувачів в інтернеті характеризується високою динамічністю та багатоканальністю. Вона проявляється у: взаємодії зі сторінками сайтів (кліки, перегляди, час на сторінці), взаємодії з рекламними оголошеннями, реакціях на контент у соціальних мережах, історії покупок та переглядів у e-commerce, даних мобільної активності. Цифрова поведінка створює великі масиви даних (Big Data), що відкриває можливості для застосування математичних і машинних моделей. **Економіко-математичні моделі** дозволяють: прогнозувати попит та купівельні наміри; оцінювати ймовірність конверсії; визначати ключові фактори, які впливають на поведінку; сегментувати аудиторію; оптимізувати маркетингові бюджети; персоналізувати пропозиції. Розглянемо основні економіко-математичні моделі:

Регресійні моделі (лінійна, логістична) допомагають оцінити фактори впливу на поведінку та ймовірність конверсії. Для кількісного аналізу використовуються:

1. Лінійна регресія — оцінює взаємозв'язок між маркетинговими чинниками (ціна, реклама, SEO, активність соцмереж) та обсягом продажів.

2. Логістична регресія — визначає ймовірність виконання користувачем цільової дії (клік, перехід, покупка).

Як приклад розглянемо регресійну модель з метою прогнозувати ймовірність того, що користувач здійснить покупку в поточній сесії (бінарна ціль: $\text{purchase} \in \{0,1\}$), використовуючи поведінкові цифрові змінні (clickstream, session features, рекламні взаємодії, рекомендаційні скоринги).

Математична форма моделі.

$$\text{Логіт-предиктор: } \text{logit}(p_i) = \ln \frac{p_i}{1-p_i} = \beta_0 + \sum_{j=1}^J \beta_j X_{ij}, \quad (1.1)$$

де $p_i = \Pr(\text{purchase}=1|X_i)$. Оцінка параметрів β здійснюється методом максимальної правдоподібності з регуляризацією (за потреби). Якщо

потрібна інтерпретація ефекту у відсотках — для неперервної змінної X_k : $\exp(\beta_k)$ — відношення шансів (odds ratio) при прирості на 1 одиницю X_k .

Модель: логістична регресія (може бути регуляризована L1/L2). Переваги: інтерпретованість коефіцієнтів, простота імплементації, сумісність з економіко-математичними висновками.




Рис.1 Графік логістичної регресії – «Ймовірність покупки залежно від кількості переглядів»

На рис.1 графік показує, як зростає ймовірність покупки (вісь $P(\text{purchase})$) залежно від кількості переглядів товару (Views). Особливості графіка: має форму *сигмоїди* – плавної S-подібної кривої. При малій кількості переглядів ймовірність низька (≈ 0.2). При збільшенні переглядів крива стрімко зростає до ~ 1 . Червона точка позначає конкретний приклад споживача, для якого модель обчислила ймовірність покупки.

Графік залежності ймовірності покупки від кількості переглядів демонструє характерну S-подібну форму, притаманну логістичній моделі. На початковому етапі збільшення кількості переглядів незначно впливає на ймовірність конверсії, що вказує на низьку мотивацію користувачів до покупки після першого ознайомлення з товаром. При збільшенні кількості переглядів до середніх значень ймовірність покупки суттєво зростає, що свідчить про накопичення інтересу й прийняття рішення. Після досягнення певного порогу крива виходить на плато, що вказує на зменшення ефекту маржинального впливу переглядів. Отже, чим частіше користувач

переглядає товар, тим вища ймовірність, що він придбає його, але після певного порогу ефект насичується. Таким чином, модель логістичної регресії дозволяє виявити оптимальну кількість контактів користувача з товаром, після яких подальше нагадування або реклама дають мінімальний приріст до конверсії. Це може бути основою для оптимізації рекламних витрат і частоти показів.

2.Кластеризація та сегментація споживачів

Сегментація ґрунтується на алгоритмах:

- **k-means** — групування користувачів за схожими характеристиками;
- **DBSCAN** — виділення кластерів за траєкторіями поведінки;
- **Hierarchical Clustering** — побудова дерев класифікації споживачів.

Це дозволяє створювати персоналізовані пропозиції.

Розглянемо приклад: **K-Means на RFM (PCA 2D)** . RFM = Recency (дні від останньої покупки), Frequency (кількість покупок), Monetary (сума витрат).

Кластеризація допомагає виділити цінні сегменти.




Рис.2 Розподіл клієнтів на 4 кластери за RFM-показниками (Recency–Frequency–Monetary).

На графіку (рис.2) клієнти показані у просторі двох головних компонент (PCA), що спрощує візуалізацію. Кожна група клієнтів має свій колір (4

кластери). Кластери розташовані у різних зонах графіка – це означає, що між групами є значущі відмінності у поведінці. Dots – точки, кожна з яких представляє одного покупця.

Таким чином, алгоритм *k-means* відокремив сегменти, наприклад: клієнти з високою частотою й високими витратами, клієнти з рідкісними покупками, клієнти з низькою маржинальністю тощо. Результати кластеризації показують чітке групування користувачів за поведінковими ознаками. Використання PCA для візуалізації підтверджує наявність сегментів, які суттєво відрізняються за значеннями Recency, Frequency та Monetary. Отримані кластери можна інтерпретувати так:

- сегмент із високими витратами та високою частотою покупок — потенційні «VIP-клієнти»;
- сегмент із низькими витратами та високою давністю останньої покупки — «ризикові» або такі, що потребують повторної активації;
- сегмент зі стабільною середньою активністю — «ядро» клієнтської бази;
- сегмент із мінімальною історією покупок — «нові» або нерегулярні користувачі.

Таке сегментування дає змогу застосовувати диференційовані маркетингові стратегії, зокрема індивідуальні знижки, персоналізовані пропозиції та таргетовані рекламні кампанії.

2.1. Моделі прогнозування попиту

Використовуються:

- **ARIMA** — для часових рядів продажів;
- **Prophet (Meta)** — для прогнозів зі сезонністю;
- **LSTM-нейронні мережі** — для складних структур споживчої активності.

На графіку (рис.3) зображено часовий ряд продажів (синя лінія) + прогноз на майбутнє (помаранчева лінія) з довірчим інтервалом (блакитна зона). Синя лінія — історичні дані продажів, помаранчева — очікувані значення, які моделює ARIMA, блакитний коридор — межі невизначеності

(95% CI). Прогноз показує тренд росту. ARIMA-модель прогнозує поступове збільшення обсягів продажів із певною невизначеністю. Це корисно для планування запасів, бюджету та виробництва.




Рис.3 ARIMA-прогноз

Побудована ARIMA-модель демонструє стабільну динаміку продажів і дозволяє отримати прогноз із відповідними довірчими інтервалами. Згідно з прогнозом, в найближчі періоди очікується зростання обсягу продажів, хоча розширення довірчого інтервалу свідчить про збільшення невизначеності з віддаленням у часі. Результати моделювання ARIMA дають можливість: прогнозувати майбутній попит, планувати закупівлі, оптимізувати складські запаси, адаптувати маркетингові витрати відповідно до сезонних трендів.

2.2. Марковські моделі для аналізу воронки продажів

Маркетингову взаємодію користувачів із сайтом можна представити як систему станів:

1. Перегляд сторінки
2. Додавання до кошика
3. Оформлення замовлення
4. Оплата

Перехідні ймовірності дозволяють визначити слабкі місця воронки та оптимізувати UX/UI.

Марковська модель воронки – ймовірності переходів.

Як приклад на рис.4 зображено стовпчиковий графік, який показує ймовірності знаходження в кожному стані воронки після обчислення марковської моделі. Осі: X – етапи (View, Cart, Purchase, Bounce), Y – ймовірність знаходження в стані після поглинання.




Рис.4 Марковська модель воронки

Особливості: найвища ймовірність – *Bounce* (втрата користувача), далі – *Purchase*, *Cart*, *View*. Це відповідає моделі, де більшість користувачів усе ж залишають сайт, а не купують. Отже, ймовірність того, що користувач зрештою дійде до покупки $\approx 11\%$.

Цей графік показує слабкі місця воронки та дозволяє зрозуміти, де оптимізувати процес. Марковська модель дозволяє оцінити ймовірності довгострокових результатів взаємодії користувачів із сайтом. Здійснений розрахунок показує, що сумарна ймовірність поглинання в стані *Bounce* (втрата користувача) є домінуючою і становить понад 80%. Натомість ймовірність переходу до покупки становить близько 11%, що відповідає типовим показникам конверсії у більшості цифрових торговельних платформ. Окрім цього, модель дає змогу визначити етапи, де втрачається найбільше користувачів. У дослідженому прикладі найбільший відтік спостерігається після першого перегляду товару, що свідчить про потенційні проблеми зі сторінкою продукту або низьку релевантність рекламних

переходів. Результати моделі можуть бути використані для оптимізації UX/UI, покращення структури картки товару, а також удосконалення рекламних джерел трафіку.

2.3. Моделі атрибуції маркетингових каналів

Оцінюють, який канал приніс найбільший вклад у конверсію:

- **Лінійна атрибуція**
- **Markov-chain атрибуція**
- **Data-driven атрибуція**

Моделі атрибуції (лінійна, data-driven) дозволяють оцінити внесок окремих каналів у досягнення конверсії.

3. Використання машинного навчання у цифровому маркетингу

3.1. Нейронні мережі для прогнозування поведінки

- передбачення кліків (CTR prediction);
- прогнозування конверсій (CVR prediction);
- рекомендаційні системи — найпотужніший інструмент персоналізації.

3.2. Рекомендаційні системи

Застосовують:

- Collaborative Filtering;
- Content-based Filtering;
- Hybrid models.

Вони дозволяють формувати індивідуальні пропозиції для кожного користувача.

3.3. Оптимізація реклами за допомогою алгоритмів RL

Методи **reinforcement learning** використовуються для: автоматичної оптимізації ставок у контекстній рекламі; динамічної персоналізації банерів; адаптивного вибору каналів комунікації. Машинне навчання й рекомендаційні системи розширюють можливості таргетованої реклами та персоналізації контенту.

Висновки та перспективи подальших досліджень. Аналіз застосованих моделей показав, що комплексне використання економіко-математичних методів дає глибоке розуміння поведінки споживачів у

цифровому середовищі. Логістична регресія дозволяє оцінити ключові драйвери конверсії, кластеризація формує основу для сегментації клієнтів, марковська модель описує динаміку проходження воронки, а ARIMA забезпечує прогнозування продажів. Сукупне застосування цих моделей створює потужний інструментарій для прийняття науково обґрунтованих управлінських рішень у сфері цифрового маркетингу. Економіко-математичні моделі є важливим інструментом для аналізу та прогнозування поведінки споживачів у цифровому маркетингу. Вони дозволяють підвищити ефективність рекламних кампаній, оптимізувати маркетингові бюджети та забезпечити персоналізацію у взаємодії з користувачами. Використання сучасних математичних методів — машинного навчання, систем рекомендацій, марковських моделей створює нові можливості для бізнесу в умовах розвитку цифрових технологій та зростання конкуренції. Економіко-математичні моделі є ключовим інструментом сучасного цифрового маркетингу. Вони забезпечують глибоке розуміння поведінки споживачів, підвищують точність прогнозів та дозволяють оптимізувати маркетингові процеси. Поєднання класичних статистичних методів із сучасними алгоритмами машинного навчання створює потужну основу для ухвалення ефективних маркетингових рішень.

Література

1. Antohi V.M., et al. A new approach to econometric modeling in digitized consumer behavior. *Frontiers in Psychology*, 2022. URL: <https://doi.org/10.3389/fpsyg.2022.940518>. (date of access: 15.11.2025).
2. Theodorakopoulos L. Leveraging Big Data and Machine Learning for Personalized Consumer Insights. 2024. URL: <https://doi.org/10.1155/2024/3641502>. onlinelibrary.wiley.com (date of access: 15.11.2025).

3. Acatrinei C., et al. Artificial Intelligence in Digital Marketing... Sustainability, 2025. URL: <https://doi.org/10.3390/su17146638>. (date of access: 15.11.2025).
 4. Shao J., et al. The Impact of Big Data-Driven Strategies on Sustainable Consumer Behaviour. *Sustainability*, 2024. URL: <https://doi.org/10.3390/su162410960>. (date of access: 15.11.2025).
 5. Ribeiro A. The impact of artificial intelligence on consumer behavior: systematic review. *Electronic Commerce Research*, 2025. URL: <https://doi.org/10.1007/s10660-025-10063-7>. (date of access: 15.11.2025).
 6. Kotler, P., Keller, K. L. Marketing Management. *Pearson*, 2022. URL: <https://doi.org/10.12924/9781292405117>. (date of access: 15.11.2025).
 7. Wedel, M., Kannan, P. K. “Marketing Analytics for Data-Rich Environments.” *Journal of Marketing*, vol. 80, 2016, pp. 97-121. URL: <https://doi.org/10.1509/jm.15.0413>. (date of access: 15.11.2025).
 8. Shmueli, G., Bruce, P., Gedeck, P. Data Mining for Business Analytics. *Wiley*, 2023. ISBN: 978-1119549840 wiley.com+2books.google.com/jm+2 (date of access: 15.11.2025).
 9. Armstrong, J. S. “Forecasting Principles.” *International Journal of Forecasting*, 2019. URL: <https://doi.org/10.1007/978-0-306-47630-3>. (date of access: 15.11.2025).
 10. Breiman, L. “Random Forests.” *Machine Learning*, vol. 45, 2001, pp. 5-32. URL: <https://doi.org/10.1023/A:1010933404324> (date of access: 15.11.2025).
 11. Murphy, K. P. Machine Learning: A Probabilistic Perspective. MIT Press, 2023. ISBN: 978-0262018029. (date of access: 15.11.2025).
 12. Fader, P. S., Hardie, B. G. S. “Customer-Base Analysis.” *Marketing Science*, 2009. URL: <https://doi.org/10.1287/mksc.1100.0580>. (date of access: 15.11.2025).
- Backer, J. and Cramer, C. (1993), “Essential categories and factors of using labor resources potential of the population”, *Economic Theory*, vol. 1, pp. 41-45.

References

1. Antohi, V.M. (2022), “A new approach to econometric modeling in digitized consumer behavior”, *Frontiers in Psychology*. <https://doi.org/10.3389/fpsyg.2022.940518>
2. Theodorakopoulos, L. (2024), “Leveraging Big Data and Machine Learning for Personalized Consumer Insights”, *Journal of Computer Networks and Communications*. <https://doi.org/10.1155/2024/3641502>
3. Acatrinei, C. (2025), “Artificial Intelligence in Digital Marketing”, *Sustainability*, vol. 17(14), 6638. <https://doi.org/10.3390/su17146638>
4. Shao, J. (2024), “The Impact of Big Data-Driven Strategies on Sustainable Consumer Behaviour”, *Sustainability*, vol. 16(24), <https://doi.org/10.3390/su162410960>
5. Ribeiro, A. (2025), “The impact of artificial intelligence on consumer behavior: Systematic review”, *Electronic Commerce Research*. <https://doi.org/10.1007/s10660-025-10063-7>
6. Kotler, P. and Keller, K.L. (2022), “Marketing Management”, *Pearson*. <https://doi.org/10.12924/9781292405117>
7. Wedel, M. and Kannan, P.K. (2016), “Marketing analytics for data-rich environments”, *Journal of Marketing*, vol. 80(6), pp. 97-121. <https://doi.org/10.1509/jm.15.0413>
8. Shmueli, G. Bruce, P. and Gedeck, P. (2023), *Data Mining for Business Analytics*, Wiley, Hoboken, USA.
9. Armstrong, J.S. (2019), “Forecasting Principles”, *International Journal of Forecasting*. <https://doi.org/10.1007/978-0-306-47630-3>
10. Breiman, L. (2001), “Random forests”, *Machine Learning*, vol. 45, pp. 5-32. <https://doi.org/10.1023/A:1010933404324>
11. Murphy, K.P. (2023), *Machine Learning: A Probabilistic Perspective*, MIT Press, Cambridge, USA.
12. Fader, P.S. and Hardie, B.G.S. (2009), “Customer-base analysis”, *Marketing Science*. <https://doi.org/10.1287/mksc.1100.0580>

Стаття надійшла до редакції 13.12.2025 р.