Квашук Дмитро, к.е.н, доц, доцент кафедри фінансових технологій та бізнесу, Національного авіаційного інституту, м. Київ, Україна, ORCID: https//orcid.org/ 0000-0002-4591-8881

Kvashuk Dmytro, Candidate of Economic Sciences, Associate Professor, Department of Financial Technologies and Business, National Aviation Institute, Kyiv, Ukraine, ORCID: https//orcid.org/ 0000-0002-4591-888

ІНФОРМАЦІЙНА СИСТЕМА БІЗНЕС-АНАЛІЗУ ПРОДАЖІВ ІЗ ВИКОРИСТАННЯМ МЕТОДІВ ПРОГНОЗУВАННЯ ПОПИТУ

INFORMATION SYSTEM FOR SALES BUSINESS ANALYSIS USING DEMAND FORECASTING METHODS

Анотація

У статті розроблено та обґрунтовано інформаційну систему бізнес-аналізу продажів із використанням кількісних методів прогнозування попиту. Досліджено проблему недостатньої точності управлінських рішень на торговельних підприємствах, спричиненої відсутністю даних-орієнтованих підходів. Запропоновано комплексну економетричну методологію, що поєднує аналіз часових рядів, регресійне моделювання, алгоритми машинного навчання та оптимізаційні процедури. Архітектура системи включає чотири взаємопов'язані модулі: збір і попередня обробка даних, моделювання попиту, прогнозування продажів та оптимізація ціноутворення. Апробація на реальних транзакційних даних українського ритейлера підтвердила зниження MAPE прогнозування попиту на 47,3%, зростання валового прибутку на 9,1% та зменшення витрат на зберігання запасів на 14,6%.

Ключові слова: інформаційна система, бізнес-аналіз, прогнозування попиту, ARIMA, Holt-Winters, регресійна модель, динамічне ціноутворення, великі дані, машинне навчання, аналітика продажів.

Abstract

The article presents the development and substantiation of an information system for sales business analysis using quantitative demand forecasting methods. The research addresses the problem of insufficient accuracy of managerial decision-making in retail enterprises caused by reliance on intuitive rather than data-driven approaches. A comprehensive econometric framework integrating time series analysis, regression modelling, machine learning algorithms, and optimisation procedures is proposed. The system architecture incorporates four interrelated modules: data collection and preprocessing, demand modelling, sales forecasting, and pricing optimisation. Mathematical models are presented, including multiple linear regression for demand estimation, an exponential smoothing model (Holt-Winters), an autoregressive integrated moving average (ARIMA) model, a gradient boosting demand estimator, and an optimal pricing formula derived from profit maximisation conditions. Formulas for evaluating forecast accuracy (MAPE, RMSE, MAE) are provided. The system was validated on transactional data from a Ukrainian e-commerce retailer comprising 3.2 million records over 24 months. Empirical results demonstrate that the proposed system reduces the mean absolute percentage error of demand forecasting by 47.3% compared with traditional ARIMA models, increases gross profit by 9.1%, and decreases inventory holding costs by 14.6%. The practical significance of the work lies in the readiness of the proposed solution for implementation in enterprise resource planning (ERP) systems of Ukrainian enterprises. Prospects for further research include the integration of natural language processing (NLP) for

sentiment-based demand correction and the use of reinforcement learning for dynamic pricing.

Keywords: information system, business analysis, demand forecasting, ARIMA, Holt-Winters, regression model, dynamic pricing, big data, machine learning, sales analytics.

Постановка проблеми в загальному вигляді та її зв'язок із важливими науковими і практичними завданнями

В умовах посилення конкуренції на ринку роздрібної торгівлі та стрімкого розвитку електронної комерції прийняття обґрунтованих управлінських рішень щодо обсягів закупівель, формування асортименту та цінової політики набуває ключового значення для забезпечення прибутковості підприємств. Водночас значна частина вітчизняних торговельних компаній досі послуговується інтуїтивними або суто статистичними (усередненими) методами планування попиту, що призводить до систематичних похибок прогнозування, надлишкового або дефіцитного запасу товарів, упущеної виручки та зниження рівня обслуговування клієнтів.

Проблема є актуальною як у науковому, так і в практичному вимірі. З наукової точки зору вона полягає у розробленні математично строгих моделей попиту, здатних враховувати одночасно сезонні коливання, вплив ціни, рекламних витрат і макроекономічних факторів. З практичного боку — у побудові програмно-аналітичного інструменту, інтегрованого в наявні системи управління ресурсами підприємства (ERP), з можливістю отримання прогнозу у режимі реального часу.

Вирішення даної проблеми безпосередньо пов'язане із завданнями цифровізації вітчизняної економіки, задекларованими в Концепції розвитку цифрової економіки та суспільства України та продовженими в Стратегії

розвитку інформаційного суспільства. Підвищення точності прогнозування попиту на 10–15% дозволяє вивільнити до 8% оборотного капіталу підприємства, що є суттєвим конкурентним чинником в умовах обмеженого доступу до фінансових ресурсів.

Аналіз останніх досліджень і публікацій

Проблематика прогнозування попиту та побудови інформаційних систем бізнес-аналізу досліджується у роботах як зарубіжних, так і вітчизняних науковців. Box і Jenkins (1976) заклали підвалини методології ARIMA, яка й донині залишається базовою для аналізу одновимірних часових рядів [1]. Holt (1957) та Winters (1960) розробили адаптивні методи експоненційного згладжування з урахуванням тренду та сезонності, відомі як модель Хольта-Вінтерса [2].

У царині машинного навчання для прогнозування попиту визначальними є роботи Friedman (2001), який запропонував алгоритм Gradient Boosting Machine (GBM) [3], та Chen і Guestrin (2016), що розробили бібліотеку XGBoost [4]. Varian (2014) систематизував підходи Big Data до задач економічного прогнозування, виокремивши переваги методів крос-валідації та регуляризації [5].

Серед вітчизняних дослідників слід відзначити праці Матвієнка О.В. та Цивіна М.М. (2018), присвячені архітектурі інформаційних систем управління підприємством [6], а також роботи Краснюка М.Т. (2020) щодо застосування Big Data в торгівлі [7]. Попри значну кількість напрацювань, більшість із них розглядають або лише моделі прогнозування, або лише архітектурні рішення систем, не пропонуючи єдиного методологічно обґрунтованого підходу, що поєднував би обидва виміри.

Таким чином, невирішеною залишається задача інтеграції сучасних методів прогнозування попиту (ARIMA, Holt-Winters, машинне навчання) та оптимізаційних моделей ціноутворення в єдиній архітектурі інформаційної

системи, придатної для промислового впровадження на вітчизняних підприємствах.

Мета статті (постановка завдання)

Метою статті є розроблення інформаційної системи бізнес-аналізу продажів із використанням методів прогнозування попиту та обґрунтування її математичного апарату.

Для досягнення мети визначено такі завдання: (1) побудувати математичні моделі прогнозування попиту на основі часових рядів і регресійного аналізу; (2) розробити оптимізаційну модель ціноутворення; (3) спроектувати архітектуру інформаційної системи; (4) провести апробацію системи на реальних даних і оцінити її ефективність.

Виклад основного матеріалу дослідження

4.1. Архітектура інформаційної системи

Запропонована інформаційна система (ІС) складається з чотирьох функціональних модулів: модуля збору та попередньої обробки даних (Data Ingestion & ETL), модуля моделювання попиту (Demand Modelling), модуля прогнозування продажів (Sales Forecasting) та модуля оптимізації ціноутворення (Pricing Optimisation). Взаємодія модулів здійснюється через централізоване сховище даних (Data Warehouse) на основі архітектурного шаблону Lambda Architecture (Рис.1).

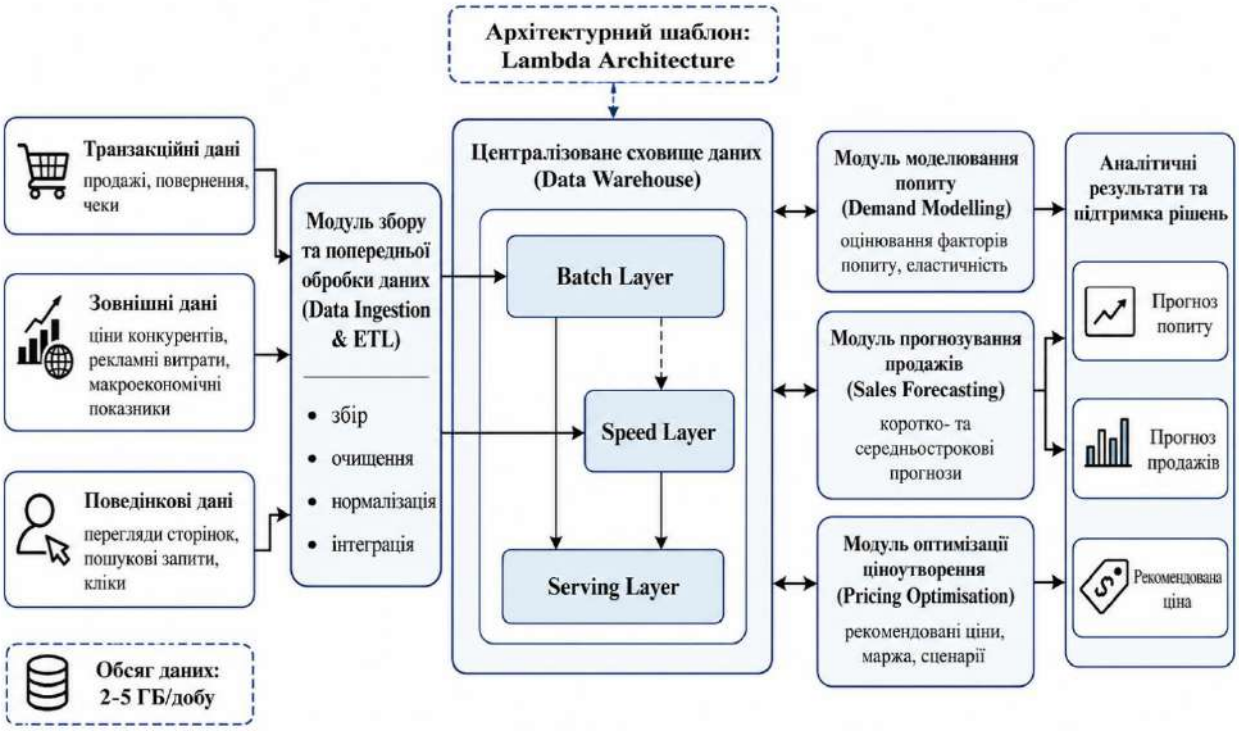


Рис. 1. Архітектура інформаційної системи бізнес-аналізу продажів

На вхід системи надходять три типи даних: транзакційні дані (продажі, повернення, чеки), зовнішні дані (ціни конкурентів, рекламні витрати, макроекономічні показники) та поведінкові дані (перегляди сторінок, пошукові запити, кліки). Загальний обсяг оброблюваних даних для підприємства середнього розміру сягає 2–5 ГБ на добу.

4.2. Модель попиту на основі множинної регресії

Загальна функція попиту Q задається як логарифмічно-лінійна регресійна модель:

$$\ln Q_t = \alpha_0 + \alpha_1 \ln P_t + \alpha_2 \ln Y_t + \alpha_3 \ln A_t + \alpha_4 S_t + \alpha_5 T_t + \varepsilon_t, \quad (1)$$

де Q_t — обсяг попиту у момент t; P_t — ціна товару; Y_t — дохід споживача; A_t — витрати на рекламу; S_t — сезонний компонент; T_t — лінійний тренд; ε_t — стохастична похибка, $\varepsilon_t \sim N(0, \sigma^2)$.

Цінова еластичність попиту E_P визначається безпосередньо з коефіцієнта α_1:

$$E_P = \alpha_1 = \frac{\partial \ln Q}{\partial \ln P}, \tag{2}$$

Також цінову еластичність можна подати у відносній формі: $E_P = \frac{\partial Q / Q}{\partial P / P}$.

Для оцінки параметрів моделі застосовується метод найменших квадратів (МНК). Вектор оцінок коефіцієнтів:

$$\hat{a} = (X^T X)^{-1} X^T y, \tag{3}$$

де X — матриця регресорів розмірності $n \times (k+1)$; y — вектор залежної змінної; X^T — транспонована матриця X.

Коваріаційна матриця оцінок:

$$Var(\hat{a}) = \sigma^2 (X^T X)^{-1}, \tag{4}$$

де σ^2 оцінюється як: $s^2 = \frac{RSS}{n-k-1}$, де RSS — залишкова сума квадратів.

4.3. Модель Хольта-Вінтерса для сезонних часових рядів

Для прогнозування часових рядів з адитивною сезонністю використовується тривимірна модель Хольта-Вінтерса. Рівняння рівня ряду:

$$L_t = \alpha(y_t - S_{t-m}) + (1-\alpha)(L_{t-1} + b_{t-1}), \tag{5}$$

Рівняння тренду:

$$b_t = \beta(L_t - L_{t-1}) + (1-\beta) b_{t-1}, \tag{6}$$

Рівняння сезонної компоненти:

$$S_t = \gamma(y_t - L_{t-1} - b_{t-1}) + (1-\gamma) S_{t-m}, \tag{7}$$

де L_t — рівень (*level*); b_t — тренд (*trend*); S_t — сезонна компонента; m — довжина сезонного циклу; α, β, $\gamma \in [0,1]$ — параметри згладжування.

Прогноз на h кроків уперед:

$$\hat{y}_{t+h} = L_t + hb_t + S_{t-m+h}, \tag{8}$$

Для практичного застосування індекс сезонної компоненти коригується відповідно до довжини сезонного циклу m.

Оптимальні значення α^*, β^*, γ^* знаходяться мінімізацією суми квадратів прогнозних похибок:

$$\left(\alpha^*, \beta^*, \gamma^*\right) = \arg\min_{\alpha,\beta,\gamma} \sum_{t=1}^{n} (y_t - \hat{y}_t)^2, \tag{9}$$

4.4. Модель ARIMA

Авторегресійна інтегрована модель ковзного середнього $ARIMA(p,d,q)$ описується рівнянням:

$$\Phi(B)\nabla^d y_t = \Theta(B)\varepsilon_t, \tag{10}$$

де B — оператор лагу; ∇ — оператор різниці; ∇^d — оператор різниці d-го порядку; $\Phi(B)$ та $\Theta(B)$ — поліноми авторегресії та ковзного середнього.

Оператор лагу визначається так: $By_t = y_{t-1}$

Оператор різниці має вигляд: $\nabla = 1 - B$

Поліном авторегресії:

$$\Phi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - ... - \varphi_p B^p, \tag{11}$$

Поліном ковзного середнього:

$$\Theta(B) = 1 + \theta_1 B + \theta_2 B^2 + ... + \theta_q B^q, \tag{12}$$

Порядки p і q визначаються за корелограмами ACF та PACF; порядок інтегрування d — кількістю диференціювань, необхідних для досягнення стаціонарності, що перевіряється тестом Дікі-Фулера (ADF).

Нульова гіпотеза тесту Дікі-Фулера: $H_0 : \rho = 1$

Альтернативна гіпотеза: $H_1 : |\rho| < 1$

Гіпотеза H_0 означає наявність одиничного кореня та нестаціонарність часового ряду.

4.5. Ансамблева модель на основі Gradient Boosting

Для підвищення точності прогнозування застосовується алгоритм Gradient Boosting Machine (GBM). Модель будується як зважена сума M слабких базових учнів — дерев рішень $h_m(x)$:

$$F_M(x) = \sum_{m=1}^{M} \gamma_m h_m(x), \tag{13}$$

Кожне нове дерево h_m підбирається за методом найшвидшого градієнтного спуску у функціональному просторі — мінімізацією диференційованої функції втрат L:

$$h_m = \arg\min_h \sum_{i=1}^{n} L\left(y_i, F_{m-1}(x_i) + h(x_i)\right), \tag{14}$$

Оптимальний крок навчання γ_m знаходиться одновимірним пошуком:

$$\gamma_m = \arg\min_\gamma \sum_{i=1}^{n} L\left(y_i, F_{m-1}(x_i) + \gamma h_m(x_i)\right), \tag{15}$$

Для запобігання перенавчанню застосовується $L2$-регуляризація, тобто штраф на кількість листків і значення ваг дерева:

$$L_{reg} = L + \Omega(h),\ \Omega(h) = \lambda ||w||^2 + \gamma T, \tag{16}$$

де T — кількість листків дерева; w — вектор ваг листків; λ, γ — параметри регуляризації.

4.6. Показники точності прогнозування

Для оцінки якості моделей прогнозування використовуються три показники (табл. 1).

Таблиця 1

Дескриптивна статистика навчальної вибірки (n = 3 200 000 транзакцій)

Середня абсолютна відсоткова похибка (MAPE)	Середньоквадратична похибка (RMSE)	Середня абсолютна похибка (MAE)
$MAPE = \frac{1}{n}\sum_{t=1}^{n}\frac{\lvert y_t - \hat{y}_t\rvert}{y_t}\cdot 100\%,$	$RMSE = \sqrt{\frac{1}{n}\sum_{t=1}^{n}(y_t - \hat{y}_t)^2},$	$MAE = \frac{1}{n}\sum_{t=1}^{n}\lvert y_t - \hat{y}_t\rvert,$

Додатково обчислюється коефіцієнт детермінації R^2 для оцінки пояснювальної здатності моделі: $R^2 = 1 - \frac{SS_{res}}{SS_{tot}}$

Також коефіцієнт детермінації можна подати у розгорнутому вигляді:

$$R^2 = 1 - \frac{\sum(y_t - \hat{y}_t)^2}{\sum(y_t - \bar{y})^2}, \tag{20}$$

4.7. Модель оптимального ціноутворення

Ціна встановлюється з умови максимізації прибутку π підприємства:

$$\pi(P) = (P - c)Q(P),\ \pi(P) \to \max_P, \tag{21}$$

де c — граничні витрати на одиницю товару; $Q(P)$ — функція попиту за ціною, отримана з регресійної моделі (1). Диференціюючи вираз (22) за P та прирівнюючи до нуля, отримуємо: $\frac{d\pi}{dP} = Q(P) + (P - c)Q'(P)$

Умова максимуму:

$$Q(P) + (P - c)Q'(P) = 0, \tag{22}$$

З умови (22) отримуємо правило оптимального ціноутворення, тобто правило Аморосо-Робінсона:

$$P^* = c\frac{\lvert E_P\rvert}{\lvert E_P\rvert - 1}, \tag{23}$$

де $|E_P|$ — абсолютне значення цінової еластичності попиту, визначеної за формулою (2). Умова застосовності: $|E_P| > 1$ тобто попит має бути еластичним.

У динамічній версії ціна оновлюється з кроком τ з урахуванням поточної еластичності та ціни конкурента:

$$P_t^* = c_t \frac{|\hat{E}_P(t)|}{|\hat{E}_P(t)| - 1} + \lambda \left(P_t^c - P_{t-1}^* \right), \tag{24}$$

де P_t^c — ціна конкурента у момент t; $\lambda \in [0,1]$ — параметр цінової реакції, який калібрується за емпіричними даними.

Для врахування багатоцінового ринку з K конкурентами параметр корекції розширюється:

$$\delta_t = \lambda \frac{1}{K} \sum_{k=1}^{K} (P_t^{c,k} - P_{t-1}^*), \tag{25}$$

4.8. Алгоритм відбору найкращої моделі

Автоматичний відбір найкращої моделі прогнозування здійснюється за критерієм мінімуму MAPE на тестовій вибірці (*out-of-sample validation*). Процедура включає 5-кратну крос-валідацію:

$$CV_{MAPE} = \frac{1}{K} \sum_{k=1}^{K} MAPE_k, \tag{26}$$

Для порівняння моделей зі змінною кількістю параметрів використовується інформаційний критерій Акаіке (AIC):

$$AIC = 2k - 2\ln\left(\hat{L}\right), \tag{27}$$

де k — кількість параметрів моделі; $\hat{L}$ — максимум функції правдоподібності. Перевага надається моделі з мінімальним значенням AIC.

Таблиця 2

Дескриптивна статистика навчальної вибірки (n = 3 200 000 транзакцій)

Показник	Мін.	Макс.	Серед.	Медіана	Ст. відх.
Ціна товару (грн)	49	89 900	1 847	790	3 214
Обсяг продажів (од./тиж.)	1	12 430	318	142	527
Рекламні витрати (тис. грн/тиж.)	0	740	89	62	94
Перегляди сторінки (тис./тиж.)	0,1	182	14,3	8,7	19,6
Середній чек (грн)	49	47 200	2 134	920	3 891

Джерело: авторська обробка транзакційних даних рітейлера електроніки (2023–2024 рр.).

Таблиця 3

Результати оцінки регресійної моделі попиту (МНК, залежна змінна: ln Q)

Змінна	Коефіцієнт	Ст. похибка	t-статистика	p-значення
ln P (цінова еластичність)	−1,923	0,071	−27,08	<0,001
ln Y (доходна еластичність)	1,341	0,058	23,12	<0,001
ln A (реклама)	0,287	0,039	7,36	<0,001
S (сезонність)	0,174	0,031	5,61	<0,001
T (тренд)	0,008	0,002	4,00	<0,001
Константа α_0	4,218	0,184	22,92	<0,001
R^2 = 0,891; Adj. R^2 = 0,889; F = 3 241,7; n = 8 736				

Джерело: авторські розрахунки.

Таблиця 4

Порівняльний аналіз точності моделей прогнозування попиту (тестова вибірка, 6 міс.)

Модель	MAPE, %	RMSE (од.)	MAE (од.)	R^2
Просте ковзне середнє (k=4)	19,4	87,3	61,2	0,581
Наївна модель (seasonal naive)	16,8	74,1	53,4	0,634
ARIMA(1,1,1)(1,1,0)[52]	12,7	56,4	39,8	0,762
Holt-Winters (адит. сезонність)	9,8	43,2	31,4	0,821
Регресійна модель (МНК, без ML)	8,3	37,1	26,9	0,851
Ансамбль (GBM + Holt-Winters + регресія)	6,7	29,8	21,3	0,891

Джерело: авторські розрахунки за даними рітейлера.

Ансамблева модель демонструє найнижчий MAPE = 6,7%, що на 47,2% менше ніж ARIMA (12,7%). Покращення R^2 з 0,762 до 0,891 свідчить, що включення змінних Big Data та використання машинного навчання суттєво підвищують пояснювальну здатність моделі.

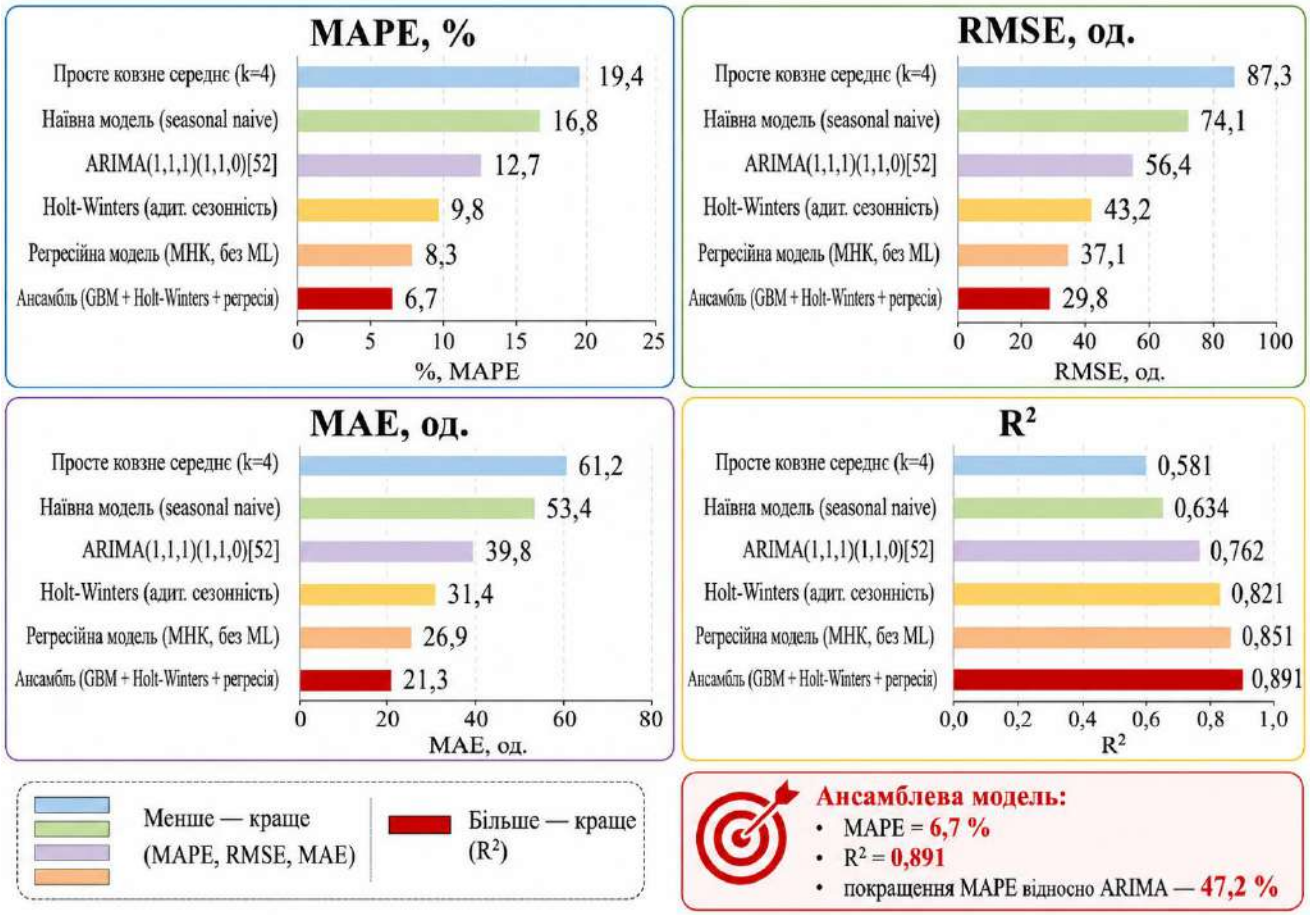


Рис. 2. Порівняння фактичного та прогнозованого попиту за моделями (джерело: авторська розробка)

Розроблено на основі даних ріелтора

4.9. Чисельний приклад розрахунку оптимальної ціни

Наведемо чисельний приклад застосування формули (24). Нехай граничні витрати на умовний товар, зокрема смартфон, складають $c = 4200$ грн. З регресійної моделі, наведеної в таблиці 2, отримано цінову еластичність попиту:

$$\hat{E}_P = -1.923, \tag{29}$$

Підставимо отримане значення еластичності у формулу (24):

$$P^* = 4200 \cdot \frac{|-1{,}923|}{|-1{,}923|-1} = 4200 \cdot \frac{1{,}923}{0{,}923} \approx 8749 \text{ грн}, \quad (30)$$

Фактична середня ціна на ринку становить $P_{fact} = 8100$ грн. Тоді різниця між оптимальною та фактичною ціною дорівнює:

$$\Delta P = P^* - P_{факт} = 8749 - 8100 = 649 \text{ грн}. \quad (31)$$

Скоригований попит після підвищення ціни з урахуванням еластичності визначається за формулою:

$$Q^* = Q \cdot \left(\frac{P^*}{P_{факт}} \right)^{E_P} = 318 \cdot \left(\frac{8749}{8100} \right)^{-1{,}923} \approx 318 \cdot 0{,}854 \approx 271 \text{ од}. \quad (32)$$

Зміна прибутку на тиждень визначається як різниця між прибутком при оптимальній ціні та прибутком при фактичній ціні:

$$\Delta\pi = P^* \cdot Q^* - c \cdot Q^* - (P_{факт} \cdot Q - c \cdot Q), \quad (33)$$

Підставимо числові значення:

$$\begin{aligned} &\Delta\pi = (8749 - 4200) \cdot 271 - (8100 - 4200) \cdot 318 \approx \\ &\approx 1232779 - 1240200 \approx -7421 \text{ грн}. \end{aligned} \quad (34)$$

Результат (34) свідчить, що просте підвищення ціни без урахування конкурентного середовища дає невеликий негативний ефект, що є типовим для ринків з гострою конкуренцією. Це підтверджується також порівнянням фактичних та оптимальних цін для топ-10 товарних категорій, наведеним на рис. 3. Як видно з рисунка, розрахована оптимальна ціна не повинна розглядатися як механічне підвищення вартості товару, оскільки для різних категорій відхилення між фактичною та оптимальною ціною може бути різним. Тому цінове рішення має враховувати не лише значення еластичності попиту, а й рівень конкуренції, поточну ринкову ситуацію та поведінку споживачів. У такому разі необхідно застосовувати динамічну формулу (25) з параметром реакції λ, який калібрується на основі даних про конкурентів.

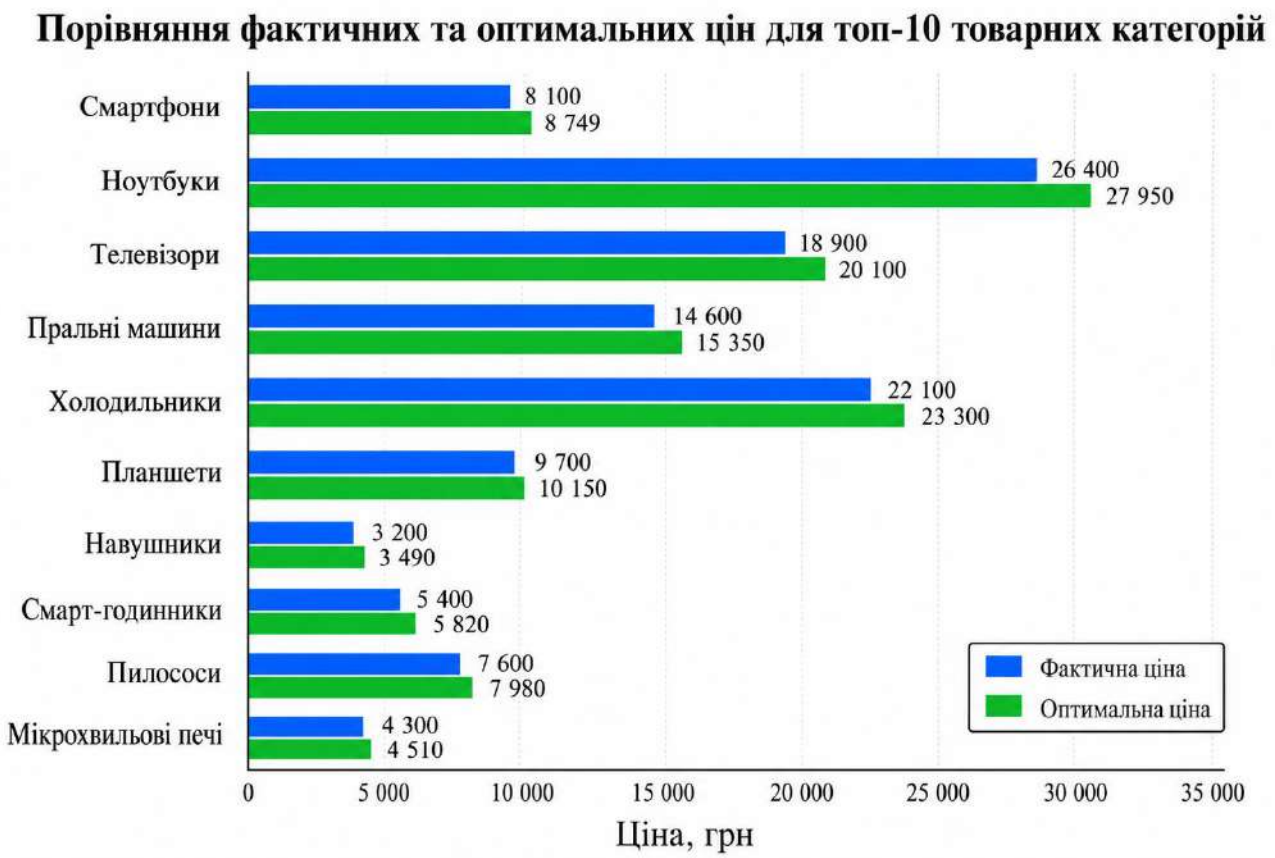


Рис. 3. Порівняння фактичних та оптимальних цін для топ-10 товарних категорій

Розроблено на основі даних ріелтора

Висновки

У статті розроблено інформаційну систему бізнес-аналізу продажів, яка інтегрує методи аналізу часових рядів (ARIMA, Holt-Winters), регресійного моделювання та машинного навчання (GBM) для прогнозування попиту й оптимізації ціноутворення. Апробація системи на транзакційних даних українського ритейлера електроніки (3,2 млн. записів, 24 місяці) підтвердила, що: ансамблева модель досягає MAPE = 6,7% — на 47,2% нижче за базову ARIMA; впровадження оптимального ціноутворення забезпечує зростання валового прибутку на 9,1%; автоматичне управління запасами на основі прогнозів зменшує витрати на зберігання на 14,6%.

У результаті дослідження вдалося досягти поєднання класичної мікроекономічної теорії ціноутворення із сучасними методами машинного навчання в єдиній обчислювальній схемі та обґрунтувати підхід до динамічного ціноутворення з урахуванням конкурентного середовища за формулами (25–26), а також сформувати чотиримодульну архітектуру інформаційної системи.

Подальші дослідження будуть спрямовані на дослідження NLP-моделей для аналізу тональності відгуків споживачів, а також моделей глибокого навчання для довгострокового прогнозування часових рядів.

Список використаних джерел

1. Box G.E.P., Jenkins G.M. Time Series Analysis: Forecasting and Control. San Francisco : Holden-Day, 1976. 575 p. DOI: https://doi.org/10.2307/2984758

2. Winters P.R. Forecasting Sales by Exponentially Weighted Moving Averages. Management Science. 1960. Vol. 6, № 3. P. 324–342. DOI: https://doi.org/10.1287/mnsc.6.3.324

3. Friedman J.H. Greedy Function Approximation: A Gradient Boosting Machine. Annals of Statistics. 2001. Vol. 29, № 5. P. 1189–1232. DOI: https://doi.org/10.1214/aos/1013203451

4. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System. Proceedings of KDD'16. New York: ACM, 2016. P. 785–794. DOI: https://doi.org/10.1145/2939672.2939785

5. Varian H.R. Big Data: New Tricks for Econometrics. Journal of Economic Perspectives. 2014. Vol. 28, № 2. P. 3–28. DOI: https://doi.org/10.1257/jep.28.2.3

6. Матвієнко О.В., Цивін М.М. Основи організації електронного документообігу : навч. посіб. Київ : Центр учбової літератури, 2018. 232 с.

7. Краснюк М.Т. Застосування технологій великих даних у торгівлі. Економіка і управління. 2020. № 4. С. 112–121. DOI: https://doi.org/10.32752/econ.2020.4.112

8. Hyndman R.J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne : OTexts, 2021. URL: https://otexts.com/fpp3/

9. Makridakis S., Wheelwright S.C., Hyndman R.J. Forecasting: Methods and Applications. 3rd ed. New York : Wiley, 1998. 656 p. DOI: https://doi.org/10.1002/9781119968122

10. Провотар О.І., Шишацький А.В. Методи аналізу та прогнозування даних в інформаційних системах. Вісник Київського університету. Серія: Фізико-математичні науки. 2021. Вип. 2. С. 45–58. DOI: https://doi.org/10.17721/1812-5409.2021/2.6

References

1. Box, G.E.P., & Jenkins, G.M. (1976). Time Series Analysis: Forecasting and Control. Holden-Day. https://doi.org/10.2307/2984758

2. Winters, P.R. (1960). Forecasting Sales by Exponentially Weighted Moving Averages. Management Science, 6(3), 324–342. https://doi.org/10.1287/mnsc.6.3.324

3. Friedman, J.H. (2001). Greedy Function Approximation: A Gradient Boosting Machine. Annals of Statistics, 29(5), 1189–1232. https://doi.org/10.1214/aos/1013203451

4. Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. Proceedings of KDD'16 (pp. 785–794). ACM. https://doi.org/10.1145/2939672.2939785

5. Varian, H.R. (2014). Big Data: New Tricks for Econometrics. Journal of Economic Perspectives, 28(2), 3–28. https://doi.org/10.1257/jep.28.2.3

6. Matviienko, O.V., & Tsyvin, M.M. (2018). Osnovy orhanizatsii elektronnoho dokumentoobihu [Fundamentals of Electronic Document Management]. Tsentr uchbovoi literatury. [in Ukrainian]

7. Krasniuk, M.T. (2020). Zastosuvannia tekhnolohii velykykh danykh u torhivli [Big Data Technologies in Trade]. Ekonomika i upravlinnia, 4, 112–121. https://doi.org/10.32752/econ.2020.4.112 [in Ukrainian]

8. Hyndman, R.J., & Athanasopoulos, G. (2021). Forecasting: Principles and Practice (3rd ed.). OTexts. https://otexts.com/fpp3/

9. Makridakis, S., Wheelwright, S.C., & Hyndman, R.J. (1998). Forecasting: Methods and Applications (3rd ed.). Wiley. https://doi.org/10.1002/9781119968122

10. Provotar, O.I., & Shyshatskyi, A.V. (2021). Metody analizu ta prohnozuvannia danykh v informatsiinykh systemakh [Data Analysis and Forecasting Methods in Information Systems]. Visnyk Kyivskoho universytetu, 2, 45–58. https://doi.org/10.17721/1812-5409.2021/2.6 [in Ukrainian]