

**П. В. Кучер**

Національний транспортний університет, Україна  
вул. Омеляновича–Павленка, 1, м. Київ, 01010  
kucherp97@gmail.com  
<https://orcid.org/0000-0002-1687-1092>

**ЗАСТОСУВАННЯ ГЛОБАЛЬНОЇ НЕЙРОМЕРЕЖЕВОЇ  
МОДЕЛІ N-BEATS ДЛЯ ПРОГНОЗУВАННЯ ПОПИТУ НА АВТОМОБІЛІ  
НА ОСНОВІ ПОШУКОВИХ ЗАПИТІВ**

**P. Kucher**

National Transport University, Ukraine  
1, Omelianovycha–Pavlenka str., Kyiv, 01010  
kucherp97@gmail.com  
<https://orcid.org/0000-0002-1687-1092>

**APPLICATION OF THE GLOBAL NEURAL NETWORK  
MODEL N-BEATS FOR FORECASTING AUTOMOBILE DEMAND BASED  
ON SEARCH QUERY DATA**

**Анотація.** У статті досліджено можливість застосування глобальної нейромережевої моделі N-BEATS для прогнозування попиту на 14 автомобільних брендів на основі даних пошукової активності за 2023-2025 роки, без використання екзогенних факторів. Модель навчена одночасно на всіх часових рядах і протестована на горизонті 12 місяців (2026 рік); точність прогнозу перевірено на фактичних даних за січень-травень 2026 року. Отримано загальну точність MAPE = 18,2 % (RMSE = 10 136,7), що перевищує точність базової моделі Seasonal Naive (MAPE = 21,5 %). Для 9 із 14 брендів глобальна модель виявилася точнішою за базову; найкращі результати отримано для Suzuki, Mercedes-Benz та Hyundai. Визначено очікувану динаміку попиту на 2026 рік порівняно з фактичним 2025 роком у розрізі кожного бренду. Результати підтверджують придатність пошукової активності як випереджального індикатора попиту та доцільність застосування глобальних нейромережевих моделей за обмеженої довжини часових рядів.

**Ключові слова:** N-BEATS; глобальні моделі прогнозування; пошукова активність; попит на автомобілі; часові ряди; нейронні мережі; Google Ads.

**Abstract.** This paper investigates the applicability of the global neural network model N-BEATS for forecasting demand for 14 automotive brands based on search activity data for 2023-2025, without exogenous factors. The model is trained simultaneously on all time series and evaluated over a 12-month horizon (2026); forecast accuracy is validated against actual data for January-May 2026. The model achieved an overall MAPE of 18.2% (RMSE = 10,136.7), outperforming the Seasonal Naive baseline (MAPE = 21.5%). For 9 of 14 brands, the global model proved more accurate than the baseline, with the strongest results for Suzuki, Mercedes-Benz, and Hyundai. Expected demand dynamics for 2026 relative to actual 2025 figures are estimated for each brand individually. The findings confirm that search activity serves as a viable leading indicator of demand and that global neural network models remain practical even with a limited length of individual time series.

**Keywords:** N-BEATS; global forecasting models; search activity; automobile demand; time series; neural networks; Google Ads.

**Вступ**

Український автомобільний ринок останні кілька років перебуває в умовах підвищеної нестабільності: коливання курсу гривні, перебудова логістичних маршрутів постачання, зміна купівельної спроможності населення та поступовий перехід частини попиту в бік електромобілів і азійських брендів – усе це робить традиційні джерела статистики

(дані реєстрацій МВС, звіти асоціацій імпортерів) недостатньо оперативними. Така статистика фіксує вже здійснені покупки, тоді як рішення про придбання автомобіля формується заздалегідь – і саме на цьому етапі покупець активно шукає інформацію про моделі, ціни та дилерів в інтернеті. Пошукова активність користувачів, таким чином, відображає намір купівлі ще до того, як він матеріалізується в

реальній транзакції, що робить її потенційно цінним випереджальним індикатором попиту.

### Огляд літератури

Архітектура N-BEATS була запропонована як глибока нейромережа на основі зворотних і прямих залишкових зв'язків, що показала результати на рівні або вище провідних статистичних та ансамблевих методів у конкурсі прогнозування M4 [1]. Згодом метод неодноразово застосовувався поза своєю первісною областю: зокрема, його ефективність підтверджено на задачі середньострокового прогнозування електроспоживання для 35 європейських країн, де модель перевершила десять базових підходів, включно з класичними статистичними та гібридними методами [2].

Подальшим розвитком стала архітектура NBEATSx, яка додає підтримку екзогенних змінних і застосовується для прогнозування цін на електроенергію [3] – це підкреслює гнучкість базової концепції N-BEATS і її придатність до адаптації під різні прикладні задачі. Ключовим теоретичним підґрунтям для застосування глобальних моделей (тобто моделей, які навчаються одночасно на кількох часових рядах, а не окремо на кожному) є робота Монтеро-Мансо та Гайндмана, де доведено, що складність локальних методів зростає пропорційно кількості рядів у наборі даних, тоді як для глобальних моделей вона залишається сталою – а отже за відсутності достатньої довжини окремого ряду саме глобальний підхід дає кращу узагальнювальну здатність [4].

Це безпосередньо стосується нашого випадку: при відносно короткій історії пошукової активності в розрізі кожного окремого бренду глобальна модель здатна переносити спільні закономірності сезонності й тренду між рядами.

Щодо застосування цифрових індикаторів попиту саме в автомобільній галузі, показовим є дослідження, в якому для прогнозування продажів інтелектуальних автомобілів використано не лише історію продажів, а й дані онлайн-

громадської думки та пошукового індексу, що дозволило підвищити точність прогнозу порівняно з чисто авторегресійною моделлю на історичних даних [5].

Це підтверджує загальну гіпотезу про випереджальну інформативність пошукової активності щодо майбутнього попиту, яка лежить в основі цього дослідження. В українському науковому просторі питання прогнозування часових рядів засобами глибокого навчання останніми роками активно розглядається: зокрема, порівнювалися архітектури на основі багатшарового перцептрона, LSTM та згорткових мереж для прогнозування нестационарних часових рядів [6; 7].

Водночас застосування саме глобальних архітектур типу N-BEATS до задач прогнозування попиту на українському ринку, а тим паче з використанням пошукової активності як вхідних даних, досі не отримало достатнього висвітлення.

### Мета дослідження

Мета дослідження – оцінити можливість застосування глобальної нейромережевої моделі N-BEATS для прогнозування динаміки попиту на автомобільні бренди на основі даних пошукової активності та перевірити точність такого прогнозу на фактичних даних.

### Змістова постановка задачі

Нехай маємо набір часових рядів  $Y = \{y_{i,1}, y_{i,2}, \dots, y_{i,T}\}$ ,  $i = 1, \dots, N$ , де  $N = 14$  – кількість автомобільних брендів,  $T = 36$  – кількість спостережень (місяців) у навчальній вибірці (січень 2023 – грудень 2025), а  $y_{i,t}$  – значення пошукової активності за брендом  $i$  у місяць  $t$ . Кожен ряд є одновимірною послідовністю без екзогенних факторів – модель не отримує на вхід жодних додаткових змінних (курс валют, ціна, рекламні витрати тощо), а спирається виключно на власну історію пошукового попиту.

Задача полягає у побудові функції прогнозування

$$\hat{y}_{i,t+1} \dots \hat{y}_{i,t+h} = F(Y, \theta) \quad (1)$$

де  $h = 12$  – горизонт прогнозу (повний 2026 рік);

$\Theta$  – параметри моделі, спільні для всіх 14 рядів одночасно;

$F(\dots)$  — функція прогнозування.

Саме ця умова – спільність параметрів  $\Theta$  для всього набору рядів, а не окремий набір параметрів  $\theta_i$  для кожного бренду – і визначає модель як глобальну, на відміну від традиційного локального підходу, де кожен ряд прогнозується незалежно. Глобальні моделі, що навчаються одночасно на групі споріднених часових рядів, демонструють стабільні переваги над локальними підходами на різних предметних областях [8].

Вибір глобального підходу для цієї задачі обумовлений двома обставинами:

1. Довжина кожного окремого ряду (36 спостережень) є відносно короткою для повноцінного навчання глибокої нейромережі в локальному режимі – глобальна модель натомість отримує фактично  $N \times T = 504$  спостереження для навчання спільних закономірностей сезонності й тренду.

2. Бренди одного ринку природно поділяють спільні макроекономічні та сезонні фактори (цикл прийняття рішення про купівлю авто, сезонність попиту, загальна динаміка ринку), що створює передумови для перенесення закономірностей між рядами.

Подібний підхід до групування споріднених, але не ідентичних товарних категорій уже застосовувався автором у попередніх дослідженнях прогнозування динаміки фармацевтичного й косметичного ринків: зокрема, при прогнозуванні попиту на вітамінні препарати за допомогою нейромережевих методів [9] та моделюванні динаміки ринків в умовах пандемії COVID-19 [10] було показано, що товарні позиції одного сегмента ринку демонструють подібну реакцію на сезонні коливання та зовнішні шоківі фактори, незважаючи на істотні відмінності в абсолютних обсягах попиту між окремими позиціями.

Цей емпіричний досвід додатково підтверджує доцільність перенесення закономірностей між спорідненими, але не тотожними часовими рядами – той самий принцип, що лежить в основі вибору

глобального підходу й у цьому дослідженні.

Окремо виокремлюється задача перевірки якості прогнозу: оскільки горизонт прогнозування ( $H = 12$ , 2026 рік) частково перекривається з періодом, за який на момент дослідження вже існують фактичні дані (січень-травень 2026), прогноз  $\hat{y}_{i,t}$  для  $t \in [T+1, T+5]$  порівнюється з реальними значеннями  $y_{i,t}$ , що дозволяє отримати об'єктивну, а не лише умовну оцінку точності моделі.

### Матеріали та методи дослідження

Вхідними даними дослідження є щомісячні показники пошукової активності щодо 14 автомобільних брендів, представлених на українському ринку: Audi, BMW, BYD, Daewoo, Ford, Hyundai, Mazda, Mercedes-Benz, Nissan, Renault, Skoda, Suzuki, Toyota, Volkswagen. Дані охоплюють період із січня 2023 по травень 2026 року (41 спостереження на кожен бренд), пропусків значень не виявлено.

Джерелом вхідних даних слугував інструмент планування ключових слів Google Ads (Google Keyword Planner) – безкоштовний сервіс платформи Google Ads, що надає агреговану статистику щомісячних обсягів пошукових запитів за обраними ключовими словами [11].

На відміну від Google Trends [12], який відображає відносну популярність запитів у нормованому вигляді (від 0 до 100), Google Keyword Planner повертає абсолютні оцінки середньомісячної кількості пошукових запитів у заданому географічному регіоні та мові інтерфейсу. Для кожного з 14 брендів було сформовано окремий ключовий запит у вигляді назви бренду (наприклад, «Toyota», «Volkswagen», «BYD»), з налаштуванням географії на Україну та мову.

Отримані щомісячні значення обсягу пошуків (average monthly searches) відображають приблизну кількість разів, яку користувачі вводили відповідний запит у пошуковій системі Google протягом кожного календарного місяця. Ці значення є агрегованими та анонімізованими – Google не розкриває індивідуальних запитів, а надає усереднені оцінки по

діапазонах або конкретні числові значення залежно від обсягу трафіку за запитом. Дані вивантажувалися вручну у форматі CSV через веб-інтерфейс Google Ads і охоплювали період із січня 2023 по травень 2026 року.

Під час підготовки дослідження використовувався інструмент штучного інтелекту Claude (Anthropic) як допоміжний засіб. Зокрема, ШІ застосовувався для генерації та розширення переліку пошукових ключових слів, які надалі використовувалися в Google Keyword Planner з метою максимального охоплення релевантних пошукових запитів щодо автомобільних брендів. Крім того, ШІ використовувався як асистент під час розроблення та налагодження програмного коду мовою Python для обробки даних, побудови прогнозової моделі та візуалізації результатів.

Усі отримані за допомогою ШІ пропозиції були перевірені, адаптовані та остаточно затверджені автором. ШІ не використовувався для аналізу результатів, формулювання наукових висновків або прийняття дослідницьких рішень.

Для навчання моделі використано підмножину за період: січень 2023 – грудень 2025 ( $T = 36$  місяців); фактичні дані за січень-травень 2026 року виокремлено та не використовувалися під час навчання – вони слугують для подальшої перевірки точності прогнозу (розділ «Результати дослідження»).

Попередня обробка обмежувалася стандартизацією кожного ряду окремо (z-нормалізація за середнім значенням і стандартним відхиленням), що виконується безпосередньо в межах архітектури моделі.

Така нормалізація необхідна через істотну різницю масштабів між брендами – від кількох тисяч пошукових запитів на місяць для Audi до понад ста тисяч для Volkswagen. Відповідно до постановки задачі, жодні зовнішні (екзогенні) фактори до моделі не додавалися – прогноз будується виключно на основі власної історії кожного ряду.

Як основний метод прогнозування застосовано глобальну нейромережеву модель N-BEATS [1], реалізовану засобами

бібліотеки `neuralforecast` (Nixtla). Модель навчається одночасно на всіх 14 часових рядах із єдиним, спільним для всіх брендів набором параметрів.

Ключові гіперпараметри моделі наведено в таблиці 1.

Таблиця 1. Гіперпараметри моделі N-BEATS

Гіперпараметр	Позначення	Значення
Горизонт прогнозу	h	12
Довжина вхідного вікна	input_size	12
Тип масштабування рядів	scaler_type	standard
Кількість кроків навчання	max_steps	800
Випадкове зерно	random_seed	42

Як базову модель для порівняння точності використано Seasonal Naive – метод, що приймає прогнозним значенням фактичне значення ряду за відповідний місяць попереднього сезонного циклу ( $season\_length = 12$ ), реалізований засобами бібліотеки `statsforecast`. Порівняння із простим, але змістовним еталоном дозволяє об'єктивно оцінити додану цінність нейромережевого підходу, а не лише засвідчити сам факт отримання прогнозу. Точність прогнозу оцінювалася за двома стандартними метриками – середньою абсолютною відсотковою похибкою (MAPE) та коренем із середньоквадратичної похибки (RMSE).

Перевірка точності здійснювалася за двома незалежними схемами. По-перше, прогноз моделі на січень–травень 2026 року порівнювався з фактичними даними за цей період, що дало об'єктивну (а не умовну) оцінку MAPE і RMSE для кожного бренду окремо. По-друге, для оцінки очікуваної динаміки попиту сумарний прогнозований обсяг пошукової активності за весь 2026 рік порівнювався із фактичним сумарним показником за 2025 рік у розрізі кожного бренду.

### Результати дослідження

Порівняння прогнозу N-BEATS із фактичними даними за січень–травень 2026 року показало загальну середню похибку

MAPE = 18,2 % (RMSE = 10 136,7), тоді як базова модель Seasonal Naïve дала MAPE = 21,5 % (RMSE = 13 801,6). Таким чином, глобальна нейромережева модель у середньому перевершила просту сезонну екстраполяцію на 3,3 відсоткових пункти за MAPE (таблиця 2).

Глобальна модель виявилася точнішою за базову для 9 із 14 брендів – найбільший виграш отримано для Mercedes-Benz (7,1 % проти 25,5 %) та

Hyundai (7,3 % проти 17,6 %). Водночас для Renault і Skoda точнішим виявився саме Seasonal Naïve, а для Audi й BYD обидва методи показали відносно високу похибку (понад 40 % та 35 % відповідно) – ймовірно, через нетипову динаміку цих брендів: BYD демонструє стрімке зростання, а Audi є невеликим за обсягом і волатильним рядом, що ускладнює прогнозування (рис. 1) на короткій історії.

Таблиця 2. Точність прогнозу за брендами (MAPE, %), січень–травень 2026

Бренд	N-BEATS	Seasonal Naïve
Suzuki	3,04	8,97
Mercedes-Benz	7,13	25,47
Hyundai	7,32	17,62
Mazda	8,61	16,79
Toyota	13,23	23,50
BMW	13,41	26,70
Volkswagen	14,73	18,40
Ford	15,61	15,99
Nissan	17,34	15,91
Daewoo	19,33	45,00
Renault	23,53	12,23
Skoda	24,00	11,08
Audi	43,12	27,50
BYD	44,33	36,15

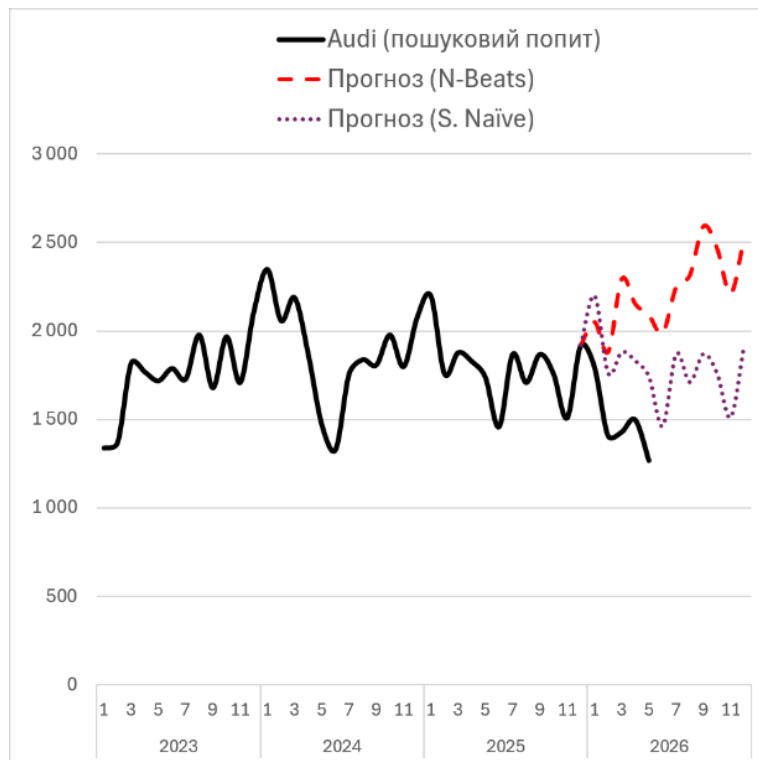


Рис. 1. Факт і прогноз пошукової активності для Audi (неточний прогноз), 2023-2026

Найточнішим виявився прогноз для бренду Suzuki (рис. 2)

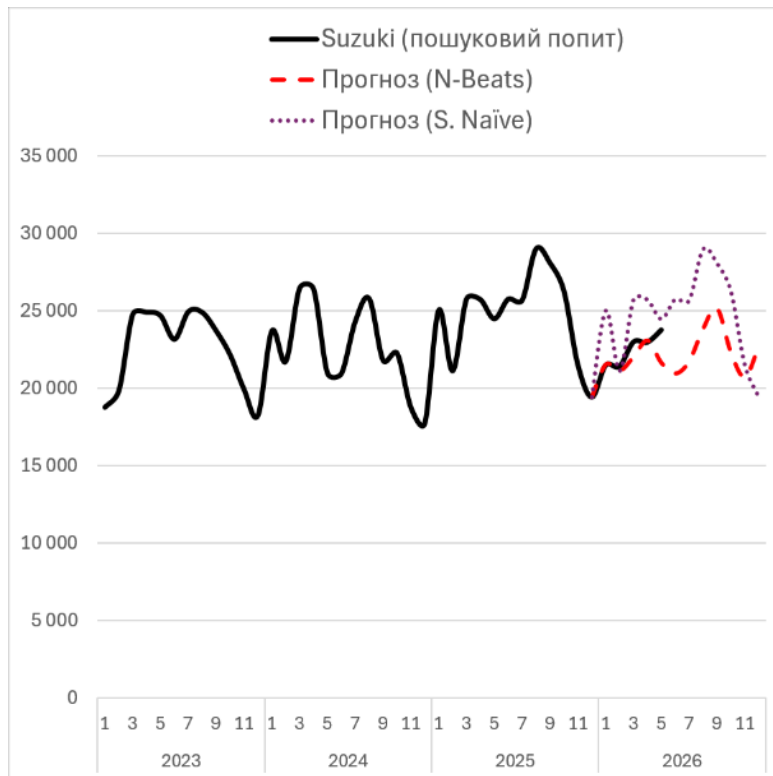


Рис. 2. Факт і прогноз пошукової активності для Suzuki (точний прогноз), 2023-2026

### Обговорення результатів

Ранжування точності за MAPE (горизонт січень-травень 2026) виявляє чітку закономірність: модель N-BEATS працює найкраще для брендів зі стабільною, помірно волатильною динамікою попиту (Suzuki, Mercedes-Benz, Hyundai, Mazda – MAPE 3-9%) і помітно гірше для брендів із нетиповою поведінкою ряду. Для Audi це пояснюється невеликим абсолютним обсягом (і відповідно нижчим попитом на бренд).

Порівняння з базовою моделлю Seasonal Naïve (загальний MAPE 18,2% проти 21,5%) показує, що нейромережвий підхід дає вииграш у середньому, але не для кожного окремого бренду – для Renault і Skoda проста сезонна екстраполяція виявилася точнішою. Це практично важливий висновок: глобальна модель доцільна як основний інструмент прогнозування на рівні всього портфеля брендів, але для окремих рядів з нетиповою динамікою варто звернути її прогноз із простішими еталонами, а не застосовувати наосліп.

Ключове обмеження дослідження – відсутність екзогенних факторів (курс валют, рекламні витрати, наявність техніки на складах дилерів, макроекономічні показники), що відповідало первісній постановці задачі («чистий» прогноз на основі лише історії пошукової активності), але, ймовірно, є основною причиною низької точності для волатильних брендів типу BYD і Audi. Також обмежує точність відносно коротка історія навчання (36 місяців) – для глибших архітектур це межа, на якій модель ще не повністю розкриває свій потенціал.

Практична цінність результату полягає в тому, що дилери та маркетингові підрозділи автомобільних брендів можуть використовувати пошукову активність як ранній, доступний і безкоштовний індикатор зміни попиту – на 1-2 місяці раніше за офіційну статистику реєстрацій. Отримані прогнозовані зміни попиту на 2026 рік (таблиця 3) можуть слугувати орієнтиром для коригування маркетингових бюджетів і закупівельних планів, особливо для брендів із

прогнозованим суттєвим зростанням (Daewoo, BYD, Renault).

Перспективним напрямом подальших досліджень є розширення моделі екзогенними факторами (NBEATSx [3]), що, ймовірно, підвищить точність саме для проблемних брендів, а також перевірка стійкості результату на довшому горизонті спостережень у міру накопичення нових даних.

### Висновки

1. У роботі застосовано глобальну нейромережеву модель N-BEATS для прогнозування динаміки попиту на 14 автомобільних брендів на основі даних пошукової активності за 2023-2025 роки, без використання екзогенних факторів. Прогноз на повний 2026 рік перевірено на фактичних даних за січень-травень 2026 року, що дало об'єктивну, а не умовну оцінку точності методу.

2. Глобальна модель показала загальну точність MAPE = 18,2% (RMSE = 10136,7), що в середньому перевершує базову модель Seasonal Naive (MAPE = 21,5%; RMSE = 13 801,6) на 3,3 відсоткових пункти. Для 9 із 14 брендів N-BEATS виявилася точнішою за базову модель; найкращі результати отримано для Suzuki, Mercedes-Benz, Hyundai та Mazda (MAPE 3–9%), найгірші – для Audi та BYD (MAPE понад 43%).

3. Практична цінність дослідження полягає у демонстрації того, що пошукова активність є придатним випереджальним індикатором попиту, а глобальний нейромережевий підхід дозволяє отримувати прийнятну точність прогнозу навіть за відносно короткої історії спостережень. Перспективи подальших досліджень пов'язані з включенням екзогенних факторів (NBEATSx) для підвищення точності прогнозу волатильних брендів.

### Література

1. Oreshkin B. N., Carпов D., Chapados N., Bengio Y. N-BEATS: Neural basis expansion analysis for interpretable time series forecasting // International Conference on Learning Representations (ICLR). 2020.

2. Oreshkin B. N., Dudek G., Peřka P., Turkina E. N-BEATS neural network for mid-term electricity load forecasting // Applied Energy. 2021. Vol. 293. 116918. DOI: 10.1016/j.apenergy.2021.116918

3. Olivares K. G., Challu C., Marcjasz G., Weron R., Dubrawski A. Neural basis expansion analysis with exogenous variables: Forecasting electricity prices with NBEATSx // International Journal of Forecasting. 2023. Vol. 39, No. 2. P. 884-900. DOI: 10.1016/j.ijforecast.2022.03.001

4. Montero-Manso P., Hyndman R. J. Principles and algorithms for forecasting groups of time series: Locality and globality // International Journal of Forecasting. 2021. Vol. 37, No. 4. P. 1632-1653. DOI: 10.1016/j.ijforecast.2021.03.004

5. Zhang M., Xu H., Ma N., Pan X. Intelligent Vehicle Sales Prediction Based on Online Public Opinion and Online Search Index // Sustainability. 2022. Vol. 14, No. 16. 10344. DOI: 10.3390/su141610344

6. Іващенко Г. С., Тимошенко Д. О., Близнюк О. В., Кононенко О. М. Моделі глибокого навчання для прогнозування часових рядів // Системи управління, навігації та зв'язку. Збірник наукових праць. 2024. Т. 1, № 75. С. 82-87. DOI: 10.26906/SUNZ.2024.1.082

7. Іващенко Г. С., Пономарьов В. В., Холієв В. В. Короткострокове прогнозування нестационарних часових рядів з використанням моделей MLP та LSTM // Системи управління, навігації та зв'язку. Збірник наукових праць. 2023. Т. 1, № 71. С. 91-95. DOI: 10.26906/SUNZ.2023.1.091

8. Abbasimehr, H., & Noshad, A. (2025). Localized global time series forecasting models using evolutionary neighbor-aided deep clustering method. Journal of Forecasting. <https://doi.org/10.1002/for.3263>

9. Кучер П., Юнькова О. Прогнозування динаміки ринку вітамінів за допомогою нейромереж // Наука і техніка сьогодні. 2023. № 3(17). С. 110-121. DOI: 10.52058/2786-6025-2023-3(17)-110-121

10. Кучер П. В., Юнькова О. О. Моделювання динаміки ринку препаратів для волосся в умовах пандемії COVID-19 // Проблеми сучасних трансформацій. Серія: економіка та управління. 2024. № 13. DOI: 10.54929/2786-5738-2024-13-11-01

11. Google LLC. Google Keyword Planner. Google Ads. URL: <https://ads.google.com/home/tools/keyword-planner/>

12. Fantazzini D., Toktamysova Z. Forecasting German car sales using Google data and multivariate models // International Journal of Production Economics. 2015. Vol. 170. P. 97-135. DOI: 10.1016/j.ijpe.2015.09.010

### References

1. Oreshkin, B. N., Carпов, D., Chapados, N., & Bengio, Y. (2020). N-BEATS: Neural basis expansion analysis for interpretable time series forecasting. International Conference on Learning Representations (ICLR).

2. Oreshkin, B. N., Dudek, G., Pelka, P., & Turkina, E. (2021). N-BEATS neural network for mid-term electricity load forecasting. *Applied Energy*, 293, 116918.

<https://doi.org/10.1016/j.apenergy.2021.116918>

3. Olivares, K. G., Challu, C., Marcjasz, G., Weron, R., & Dubrawski, A. (2023). Neural basis expansion analysis with exogenous variables: Forecasting electricity prices with NBEATSx. *International Journal of Forecasting*, 39(2), 884-900.

<https://doi.org/10.1016/j.ijforecast.2022.03.001>

4. Montero-Manso, P., & Hyndman, R. J. (2021). Principles and algorithms for forecasting groups of time series: Locality and globality. *International Journal of Forecasting*, 37(4), 1632-1653.

5. Zhang, M., Xu, H., Ma, N., & Pan, X. (2022). Intelligent vehicle sales prediction based on online public opinion and online search index. *Sustainability*, 14(16), 10344. <https://doi.org/10.3390/su141610344>

6. Ivashchenko, H. S., Tymoshenko, D. O., Blyzniuk, O. V., & Kononenko, O. M. (2024). Modeli hlybokoho navchannia dlia prohnozuvannia chasovykh riadiv [Deep learning models for time series forecasting]. *Systemy upravlinnia, navihatsii ta zviazku. Zbirnyk naukovykh prats*, 1(75), 82-87.

<https://doi.org/10.26906/SUNZ.2024.1.082>

7. Ivashchenko, H. S., Ponamarov, V. V., & Kholiev, V. V. (2023). Korotkostrokovoe prohnozuvannia nestatsionarnykh chasovykh riadiv z vykorystanniam modelei MLP ta LSTM [Short-term forecasting of non-stationary time series using MLP and LSTM models]. *Systemy upravlinnia, navihatsii ta zviazku. Zbirnyk naukovykh prats*, 1(71), 91-95.

<https://doi.org/10.26906/SUNZ.2023.1.091>

8. Abbasimehr, H., & Noshad, A. (2025). Localized global time series forecasting models using evolutionary neighbor-aided deep clustering method. *Journal of Forecasting*. <https://doi.org/10.1002/for.3263>

9. Kucher, P., & Yunkova, O. (2023). Prohnozuvannia dynamiky rynku vitaminiv za dopomohoiu neiromerezh [Forecasting vitamin market dynamics using neural networks]. *Nauka i tekhnika sohodni*, 3(17), 110-121.

[https://doi.org/10.52058/2786-6025-2023-3\(17\)-110-121](https://doi.org/10.52058/2786-6025-2023-3(17)-110-121)

10. Kucher, P. V., & Yunkova, O. O. (2024). Modeliuvannia dynamiky rynku preparativ dlia volossia v umovakh pandemii COVID-19 [Modelling hair product market dynamics during the COVID-19 pandemic]. *Problemy suchasnykh transformatsii. Seriya: ekonomika ta upravlinnia*, 13.

<https://doi.org/10.54929/2786-5738-2024-13-11-01>

11. Google LLC. (n.d.). Google Keyword Planner. Google Ads.

<https://ads.google.com/home/tools/keyword-planner/>

12. Fantazzini, D., & Toktamysova, Z. (2015). Forecasting German car sales using Google data and multivariate models. *International Journal of Production Economics*, 170, 97-135.

<https://doi.org/10.1016/j.ijpe.2015.09.010>

13. Abbasimehr, H., & Noshad, A. (2025). Localized global time series forecasting models using evolutionary neighbor-aided deep clustering method. *Journal of Forecasting*. <https://doi.org/10.1002/for.3263>

The article has been sent to the editors 19.06.26.

After processing 25.06.26.

Submitted for printing 30.06.26

Copyright under license CCBY-SA4.0.