

УДК 004.855.5:004.032.26:338.5

DOI <https://doi.org/10.32782/2663-5941/2026.2.1/04>

**Вакалюк Т.А.**

<https://orcid.org/0000-0001-6825-4697>

Державний університет "Житомирська політехніка"

**Фант М.О.**

<https://orcid.org/0000-0002-4994-8009>

Державний університет "Житомирська політехніка"

**Дунев С.С.**

<https://orcid.org/0009-0006-2041-0885>

Державний університет «Житомирська політехніка»

**Власенко О.В.**

<https://orcid.org/0000-0001-6697-2150>

Державний університет "Житомирська політехніка"

**Коломієць В.В.**

<https://orcid.org/0009-0002-8106-5502>

Державний університет "Житомирська політехніка"

## ОГЛЯД МЕТОДІВ ПРОГНОЗУВАННЯ ДИНАМІКИ ПОПИТУ ТОВАРІВ

У статті проведено комплексний огляд сучасних методів і підходів до прогнозування динаміки попиту товарів, що застосовуються в електронній комерції та роздрібній торгівлі. Розглянуто три основні категорії методів, зокрема статистичні моделі, методи машинного навчання та аналітика великих даних. У межах статистичних моделей проаналізовано методи лінійної та множинної регресії, експоненціального згладжування, а також моделі часових рядів ARIMA і SARIMA. Показано, що ці підходи ефективні для прогнозування в умовах стабільного попиту, але мають обмеження при роботі з нелінійними залежностями та великими масивами різнорідних даних.

Для подолання цих обмежень розглянуто методи машинного навчання, зокрема логістичну регресію, дерева рішень, ансамблеві методи (Random Forest і Gradient Boosting), а також рекурентні нейронні мережі типу LSTM (Long Short-Term Memory). Проведено порівняльний аналіз зазначених підходів за ключовими критеріями, серед яких точність прогнозування, масштабованість, здатність моделювати нелінійні залежності, вимоги до обсягу тренувальних даних та обчислювальна складність. Доведено, що нейронні мережі LSTM мають суттєві переваги для прогнозування часових рядів завдяки здатності фіксувати довгострокові залежності, моделювати нелінійні взаємозв'язки та адаптуватися до нових ринкових умов через перенавчання.

Окремо висвітлено роль аналітики великих даних у сучасних системах прогнозування. Розглянуто можливості платформ Hadoop і Apache Spark для розподіленої обробки структурованих і неструктурованих даних з різнорідних джерел у режимі реального часу. Обґрунтовано доцільність використання багатошарової архітектури LSTM з dropout-регуляризацією та оптимізатором ADAM для побудови аналітично-інформаційної системи прогнозування попиту. Запропонована система передбачає опрацювання вхідних даних про попередні обсяги попиту, сезонні фактори та додаткові параметри, їх обробку через приховані шари LSTM та формування прогнозованих значень на вихідному шарі.

**Ключові слова:** прогнозування попиту, машинне навчання, нейронні мережі, LSTM, часові ряди, ARIMA, SARIMA, аналітика великих даних, Random Forest, Gradient Boosting.

**Постановка проблеми.** У сучасному конкурентному середовищі точне прогнозування попиту на продукцію є вирішальним фактором для успіху бізнесу. В умовах зростаючих обсягів даних, доступних у реальному часі, компанії, що працюють в електронній комерції, як і в інших галузях, усе частіше застосовують прогресивні аналітичні підходи для побудови ефективних систем прогнозування попиту [1, 10]. Використання таких систем дозволяє бізнесам мінімізувати ризики, пов'язані з надлишком або нестачею товарів, оптимізувати ланцюги постачання, знижувати витрати та підвищувати рівень задоволеності клієнтів.

На сучасному етапі існує безліч методів і програмних рішень, які дозволяють прогнозувати попит на основі аналізу великих даних, обробки часових рядів і машинного навчання. Поширені інструменти прогнозування, які використовують компанії, варіюються від простих статистичних моделей до складних моделей на основі штучного інтелекту, здатних враховувати численні зовнішні фактори, такі як сезонні зміни, погодні умови, поведінка споживачів і навіть дані соціальних мереж тощо.

Інтернет-магазини, такі як Amazon, Walmart, Alibaba та інші, вже використовують передові методи прогнозування. Вони не лише оптимізують запаси, але й забезпечують більш персоналізований досвід для покупців. Алгоритми, що лежать в основі їхніх систем, часто поєднують різні підходи, зокрема, аналіз часових рядів, регресійні моделі, нейронні мережі, кластеризацію та асоціативний аналіз, що дозволяє враховувати як довгострокові тенденції, так і короткострокові зміни в попиті [5].

Прогнозування попиту є складним процесом, що потребує обробки великих обсягів даних, оскільки він враховує не лише історичні показники, але й безліч зовнішніх факторів, які можуть впливати на динаміку продажів. З цієї причини найбільш ефективні рішення у цій сфері зазвичай базуються на поєднанні кількох методів і алгоритмів [9]. Наприклад, аналітичні системи можуть використовувати методи регресії для визначення основних трендів, алгоритми машинного навчання для виявлення прихованих патернів, а також нейронні мережі для аналізу та передбачення сезонних коливань. Окрім цього, все більшого поширення набувають підходи, що базуються на аналітиці великих даних, яка обробляє і аналізує великий масив інформації, включаючи взаємодію клієнтів із сайтом та зовнішні економічні показники.

**Аналіз останніх досліджень і публікацій.** Проблема прогнозування попиту досліджується у численних наукових роботах, присвячених статистичним методам, машинному навчанню та великим даним. Класичні підходи до побудови моделей прогнозування розглянуто у монографії McKinney [1], де представлено практичні інструменти аналізу даних засобами Python. Фундаментальні засади статистичного навчання та регресійного аналізу ґрунтовно описано у роботі Hastie, Tibshirani і Friedman [2], яка залишається одним із найавторитетніших посібників у галузі статистичного моделювання. Класичний підхід до аналізу часових рядів, зокрема моделі ARIMA та SARIMA, детально викладено у монографії Box, Jenkins, Reinsel і Ljung [3], яка стала стандартом для дослідників у цій сфері. Питання побудови моделей часових рядів для задач прогнозування розглянуто також у роботі Brockwell і Davis [4], де наведено теоретичне обґрунтування та практичні приклади застосування відповідних методів.

Методи розпізнавання образів та машинного навчання, включаючи дерева рішень, нейронні мережі та методи ансамблю, систематизовано у фундаментальній праці Bishop [5]. Теоретичні основи глибинного навчання, у тому числі архітектура рекурентних нейронних мереж та LSTM, детально описано у монографії Goodfellow, Bengio і Courville [6]. Практичні аспекти застосування LSTM для задач прогнозування часових рядів викладено у роботі Brownlee [11], де наведено приклади реалізації відповідних архітектур та оцінку їх точності. Принципи прогнозування та їх практичне застосування в бізнесі розглянуто у роботі Hyndman і Athanasopoulos [8], яка охоплює як класичні статистичні методи, так і сучасні підходи на основі машинного навчання.

Питання бізнес-аналітики та управління ланцюгами постачання на основі великих даних досліджено у статті Chen, Chiang і Storey [7], де висвітлено трансформацію від традиційного аналізу до аналітики на основі великих масивів даних. Стратегічні аспекти управління ланцюгами постачання та методи прогнозування в контексті логістики розглянуто у роботі Chopra і Meindl [10]. Технологічна база для обробки великих даних описана у монографіях White [12] та Karau, Konwinski, Zaharia і Wendell [13], де висвітлено платформи Hadoop і Apache Spark відповідно. Таким чином, незважаючи на значну кількість публікацій у цій галузі, комплексний порівняльний аналіз методів прогнозування попиту з обґрунтуванням переваг архітектури LSTM для систем електронної комерції залишається актуальним завданням.

**Постановка завдання.** Метою статті є огляд сучасних систем прогнозування попиту, які використовуються на ринку, і методів, що лежать в основі цих систем.

**Виклад основного матеріалу.** Розглянемо найпоширеніші підходи до прогнозування, а також приклади їх застосування в інтернет-магазинах і великих роздрібних мережах.

*Статистичні моделі* є основою багатьох аналітичних систем, призначених для прогнозування попиту. Ці моделі ґрунтуються на припущенні, що історичні тенденції та закономірності можуть бути використані для передбачення майбутнього. Використовуючи різні математичні підходи, статистичні моделі дозволяють аналізувати взаємозв'язки між змінними, виявляти тренди, сезонність і циклічність у даних. Найчастіше застосовуються для довгострокового прогнозування в умовах стабільного попиту та коли потрібно отримати швидкі оцінки для планування [1].

Один з найпоширеніших методів у статистичних моделях – *лінійна регресія*, яка дозволяє визначити лінійну залежність між змінною попиту  $Y$  та іншими факторами (наприклад, ціна, маркетингові витрати). Модель описується рівнянням:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \epsilon$$

де:

- $Y$  – прогнозована величина попиту,
- $X_1, X_2, \dots, X_n$  – незалежні змінні (фактори, що впливають на попит),
- $\beta_0, \beta_1, \dots, \beta_n$  – коефіцієнти регресії, що показують вплив кожної змінної на попит,
- $\epsilon$  – випадкова похибка, яка враховує непередбачувані фактори.

Лінійна регресія є ефективною, коли між змінними існує чітка лінійна залежність. Це дозволяє легко інтерпретувати вплив кожного фактора на попит, але модель обмежена, якщо дані мають нелінійну природу [2].

*Множинна регресія* – це розширення лінійної регресії, яке дозволяє враховувати кілька змінних одночасно. Цей метод корисний для складніших прогнозів, де попит залежить від багатьох факторів. Наприклад, для прогнозування продажів комп'ютерної техніки можна використовувати множинну регресію, враховуючи сезонність, економічні умови, рівень конкуренції тощо.

Метод *експоненціального згладжування* є більш гнучким і застосовується для даних, які мають сильні тенденції або сезонні коливання. Він передбачає зниження ваги для старих значень у часі, що дозволяє краще враховувати останні

зміни у попиті. Основні формули експоненціального згладжування:

– *просте експоненціальне згладжування* для випадків без тренду і сезонності:

$$S_t = \alpha Y_t + (1 - \alpha) S_{t-1}$$

де:  $S_t$  – згладжене значення на момент  $t$ ,  $Y_t$  – фактичне значення попиту,  $\alpha$  – параметр згладжування (від 0 до 1).

– *експоненціальне згладжування з трендом (Holt's Method)* для випадків, коли дані мають тренд:

$$S_t = \alpha Y_t + (1 - \alpha)(S_{t-1} + T_{t-1})$$

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}$$

де:  $T_t$  – компонент тренду,  $\beta$  – параметр згладжування для тренду.

Методи експоненціального згладжування є ефективними, коли потрібно швидко реагувати на останні зміни у даних. Вони добре працюють із сезонними даними та дозволяють швидко адаптувати прогноз до нових умов [3].

Варто також розглянути моделі часових рядів, які включають моделі ARIMA та SARIMA.

Модель *ARIMA* (Auto-Regressive Integrated Moving Average) є однією з найпопулярніших моделей для аналізу часових рядів. ARIMA враховує автокореляцію між спостереженнями, що робить її ефективною для довгострокового прогнозування.

Модель складається з трьох компонентів: AR (Auto-Regressive), що враховує автокореляцію, коли поточне значення залежить від попередніх; I (Integrated), яка використовується для усунення тренду; та MA (Moving Average), що враховує випадкові зміни й згладжує дані.

ARIMA ефективно працює для даних із сезонними коливаннями та трендами, де є складні залежності між попередніми значеннями та поточним попитом [4].

Для даних із вираженою сезонністю застосовують модель SARIMA (Seasonal ARIMA), яка додає до ARIMA додаткові сезонні компоненти. SARIMA ефективна для складних часових рядів із сезонними коливаннями, що може бути корисним для прогнозування попиту, наприклад, на техніку у святкові сезони [5].

Статистичні моделі є основою для аналізу та прогнозування попиту завдяки своїй інтерпретованості та здатності обробляти сезонні та трендові компоненти. Методи, такі як лінійна та множинна регресія, експоненціальне згладжування, ARIMA та SARIMA, забезпечують широкий інструментарій для точного прогнозування залежно від особливостей даних.

Вони дозволяють відстежувати тенденції, сезонні коливання та вплив різних факторів на попит, що робить їх ідеальними для бізнесів, які прагнуть стабільності у постачанні та задоволенні попиту.

Для прогнозування попиту також застосовуються методи машинного навчання, які забезпечують точність і ефективність аналізу. Вони допомагають моделювати складні залежності та виявляти закономірності в даних.

*Машинне навчання* (ML) є сучасним підходом до прогнозування попиту, який здатен обробляти великі обсяги даних і виявляти приховані патерни у складних багатовимірних наборах даних. Алгоритми машинного навчання самостійно навчаються на історичних даних і можуть адаптуватися до нових трендів у міру надходження нових даних, що робить їх особливо ефективними для задач прогнозування в умовах швидкозмінного ринку. Методи ML широко використовуються в електронній комерції та роздрібній торгівлі, де вони дозволяють підвищити точність прогнозів і знизити витрати на управління запасами [1].

Для задач прогнозування динаміки попиту лінійні моделі, такі як *лінійна регресія та регресія Лассо*, можуть використовуватися для оцінки та аналізу змінних, що впливають на попит. Логістична регресія використовується для передбачення ймовірності настання певних подій, наприклад, високого чи низького попиту, тоді як регресія Лассо допомагає враховувати великий набір змінних та обирати лише найважливіші з них.

*Дерева рішень* є простими і потужними моделями для прогнозування, які ієрархічно розбивають дані на основі певних умов. Це дозволяє класифікувати або прогнозувати дані на основі багатьох факторів. Для задач прогнозування попиту дерева рішень є цінними через можливість враховувати взаємодії між різними змінними.

Формула для дерева рішень будується шляхом мінімізації похибки, де кожне розгалуження збільшує точність прогнозу. Проте, окремі дерева рішень можуть бути чутливими до викидів, тому популярними є *методи ансамблю*, такі як: *Random Forest та Gradient Boosting*.

Метод ансамблю *Random Forest* створює багато дерев рішень та об'єднує їх прогнози для підвищення точності. Метод ансамблю *Gradient Boosting* поетапно покращує прогнозування, додаючи нові дерева, які мінімізують похибку попередніх прогнозів. Методи ансамблю підходять для складних наборів даних і забезпечують точні прогнози, оскільки знижують ризик переобучення за рахунок усереднення [4].

*Нейронні мережі* є одним із найбільш гнучких і потужних методів для прогнозування попиту, особливо при роботі з великими наборами даних і складними залежностями між змінними. Модель нейронної мережі складається з багатьох шарів (вхідний, приховані, вихідний), де кожен шар містить нейрони, які з'єднані між собою. Мережа навчається на історичних даних, адаптуючи свої параметри для мінімізації похибки між прогнозованим і фактичним попитом.

Рекурентні нейронні мережі (RNN) і їхня вдосконалена версія – *LSTM (Long Short-Term Memory)* – спеціально розроблені для роботи з послідовними даними, як-от часові ряди. У прогнозуванні попиту LSTM є ефективними завдяки здатності запам'ятовувати важливу інформацію на довгі проміжки часу та ігнорувати менш важливі дані. Архітектура LSTM містить осередки пам'яті, які контролюються за допомогою "ворот" (forget, input і output). LSTM є ідеальним вибором для задач прогнозування попиту, оскільки вони здатні враховувати як короткострокові, так і довгострокові залежності.

*Кластеризація* допомагає сегментувати дані про попит на групи, що мають подібні характеристики, що дозволяє створювати прогнози для кожного кластера окремо. Наприклад, K-Means кластеризація розподіляє точки даних на k груп, зменшуючи внутрішню варіативність у кожному кластері. Це корисно для рітейлерів, які можуть використовувати прогнози попиту для різних клієнтських сегментів або товарних категорій.

Методи машинного навчання характеризуються високою точністю при роботі з великими обсягами даних, здатністю обробляти складні та нелінійні взаємозв'язки, а також адаптивністю до змінних ринкових умов. Водночас їх використання має певні обмеження, зокрема потребу у великих обсягах даних для тренування моделей, високі обчислювальні витрати та труднощі в інтерпретації складних моделей, таких як нейронні мережі.

Аналітика великих даних стала важливою складовою сучасних систем прогнозування, особливо у великих компаніях та інтернет-магазинах, таких як Amazon, Walmart, Alibaba та інші. Завдяки технологіям Big Data аналітики можуть обробляти та аналізувати надзвичайно великі обсяги інформації, отримуючи важливі інсайти про поведінку клієнтів, ринкові тенденції, сезонні коливання та інші фактори, які впливають на попит. На відміну від традиційних методів аналізу даних, аналітика великих даних дозволяє швидко обробляти і зберігати інформацію, включаючи неструктуровані

дані (соціальні медіа, відгуки клієнтів, погодні умови тощо) [1].

Великі дані характеризуються трьома основними аспектами. Обсяг (Volume) стосується величезних масивів даних, які перевищують можливості традиційних систем обробки. Швидкість (Velocity) відображає високі темпи генерації та оновлення даних, що вимагає майже миттєвої обробки. Різноманітність (Variety) включає різні джерела та формати даних, зокрема структуровані, неструктуровані та напівструктуровані.

Для прогнозування попиту застосовують алгоритми машинного навчання, що дозволяють виявляти закономірності у великих масивах даних, моделювати взаємозв'язки між змінними та сегментувати клієнтів за типами попиту. Аналіз часових рядів на основі технологій Big Data забезпечує виявлення трендів, сезонності та циклічності, а обробка даних у реальному часі дає змогу оперативно адаптувати прогнози до ринкових змін. Додатково враховується неструктурована інформація – відгуки клієнтів, дані соціальних мереж, погодні звіти, що розширює можливості моделювання поведінки споживачів.

Серед інструментів аналітики великих даних вирізняється Hadoop – відкрита платформа розподіленого зберігання та обробки інформації. Модель MapReduce забезпечує паралельні обчислення на кластерах серверів, а HDFS гарантує надійне зберігання даних через реплікацію. Горизонтальна масштабованість платформи дозволяє нарощувати обчислювальні потужності без істотних витрат на продуктивність [12].

Серед популярних інструментів варто відзначити Apache Spark – платформа для розподіленої обробки даних, яка значно прискорює операції завдяки виконанню обчислень в пам'яті. Spark підтримує широкий спектр завдань, таких як обробка потокових даних, аналітика великих обсягів інформації, а також машинне навчання через бібліотеку MLlib. Платформа інтегрується з різними джерелами даних, включаючи HDFS, Apache Cassandra та Amazon S3, що робить її універсальним інструментом для роботи з різними форматами та типами даних. Вона широко використовується в компаніях, які потребують обробки даних у реальному часі, наприклад, для аналізу логів або обробки фінансових транзакцій [13].

MongoDB і Cassandra є двома основними представниками NoSQL баз даних, що спеціалізуються на обробці неструктурованих та напівструктурованих даних. MongoDB відома своєю гнучкістю завдяки зберіганню даних у форматі

BSON (Binary JSON), що дозволяє зберігати складні структури і легко інтегрувати їх у сучасні веб-додатки. Cassandra, в свою чергу, відрізняється високою доступністю та масштабованістю, що робить її ідеальним вибором для розподілених систем, що потребують роботи з великими обсягами даних в різних локаціях. Її архітектура без єдиного вузла відмови забезпечує надійність і безперервну роботу [12].

Для обробки потокових даних популярною платформою є Kafka. Вона дозволяє здійснювати швидку передачу інформації між різними додатками та обробляти велику кількість подій у реальному часі. Kafka часто використовується для обробки даних з IoT-пристроїв або аналітики користувацької активності на вебсайтах. Крім того, Kafka інтегрується з іншими платформами, такими як Hadoop і Spark, утворюючи потужну екосистему для обробки та аналізу великих даних.

Аналітика великих даних відкриває нові можливості для прогнозування попиту, оскільки дозволяє враховувати як структуровані, так і неструктуровані дані. Вона забезпечує високу швидкість обробки інформації, що є надзвичайно важливим для ритейлерів, які повинні швидко реагувати на змінні умови ринку. Завдяки можливості обробляти різноманітні джерела даних, Big Data дозволяє створювати більш точні моделі прогнозування, що базуються на актуальних даних про ринок і споживчі уподобання.

Для прогнозування попиту, що враховує сезонність, тренди та раптові коливання, архітектура LSTM має низку ключових переваг. По-перше, модель ефективно обробляє довгострокові залежності в часових рядах, зберігаючи інформацію про попередні значення на тривалих інтервалах. По-друге, LSTM здатна моделювати нелінійні взаємозв'язки між змінними, що особливо актуально для електронної комерції, де попит залежить від маркетингових кампаній, зовнішніх подій і нових трендів. По-третє, модель легко інтегрує різнорідні джерела даних – від історії продажів до погодних умов і регіональних особливостей. Нарешті, можливість перенавчання на нових даних забезпечує адаптивність системи до змін ринкового середовища.

Нейронні мережі LSTM мають певні переваги в порівнянні з іншими методами прогнозування попиту. Статистичні моделі, такі як ARIMA і SARIMA, хоча і ефективні для прогнозування часових рядів, мають обмеження у роботі з довгостроковими нелінійними залежностями. Вони добре підходять для моделювання лінійних трен-

дів, але не здатні забезпечити точність прогнозів при складних або змінних взаємозв'язках. На відміну від них, LSTM краще справляється з складними і довгостроковими трендами, забезпечуючи більш точні прогнози для таких даних.

Методи експоненціального згладжування часто використовуються для короткострокових прогнозів, однак вони мають свої обмеження при роботі з великими обсягами даних. Вони можуть бути ефективними для спрощених задач, але не здатні враховувати складні фактори, які впливають на попит, такі як сезонність чи маркетингові кампанії. Крім того, ці методи не завжди дають змогу коректно прогнозувати зміни в попиті в динамічних умовах.

Інструменти аналітики великих даних, або Big Data, здатні збирати і обробляти великі обсяги інформації, але для точного прогнозування конкретних змін у попиті, особливо на короткий термін, необхідні спеціалізовані моделі, такі як LSTM. Ці моделі здатні враховувати складні взаємозв'язки між змінними і адаптуватися до нових даних, що робить їх більш ефективними для точного прогнозування.

Для AI системи пропонується використати архітектуру *багатошарової LSTM* із декількома прихованими шарами, що дозволить обробляти як сезонні, так і короткострокові коливання попиту. Додатково, структура включатиме параметри для регуляризації (dropout) і оптимізацію (наприклад, ADAM), що дозволить уникнути перенавчання та знизити похибку прогнозування.

Вхідний шар отримує дані про попередні періоди попиту, сезонні фактори та додаткові параметри, такі як місяць, пора року або маркетингові активності. Ці дані використовуються для подальшої обробки в моделі. Приховані шари LSTM відповідають за обробку інформації про довгострокові залежності, що дозволяє забезпечити високу точність прогнозування навіть у випадку сезонних змін попиту. Останній етап моделювання – вихідний шар, який на основі поточного стану передає прогнозовані значення попиту для подальшого аналізу.

Враховуючи складність і багатофакторність процесу прогнозування попиту, метод LSTM надає найточніші і стабільні результати. Його здатність працювати з часовими рядами, зберігати довгострокову пам'ять і адаптуватися до нових умов

робить його ідеальним вибором для нашої аналітично-інформаційної системи. Крім того, LSTM дозволяє враховувати складні залежності між змінними, що підвищує точність прогнозування, особливо в умовах мінливої ринкової ситуації.

Отже, для розробки аналітично-інформаційної системи прогнозування попиту методом вибору є модель нейронних мереж (LSTM). Вона не лише відповідає потребам прогнозування на основі часових рядів, але й забезпечує гнучкість і адаптивність, необхідні для роботи в умовах динамічного ринку.

**Висновки.** Статистичні моделі (регресійний аналіз, експоненціальне згладжування, ARIMA та SARIMA) ефективні в умовах стабільної ринкової кон'юнктури та вирізняються інтерпретованістю результатів, проте мають обмежені можливості при роботі з нелінійними залежностями та великими неструктурованими масивами даних. Методи машинного навчання, зокрема ансамблеві алгоритми Random Forest і Gradient Boosting, забезпечують вищу точність прогнозування завдяки здатності моделювати складні взаємозв'язки, хоча й потребують значних обчислювальних ресурсів і великих тренувальних вибірок. Платформи аналітики великих даних – Hadoop, Apache Spark, Kafka – розширюють можливості опрацювання різномірних джерел у реальному часі, однак їх впровадження вимагає суттєвих інфраструктурних витрат.

На основі порівняльного аналізу обґрунтовано вибір архітектури LSTM, яка перевершує статистичні моделі у роботі з довгостроковими залежностями та нелінійними патернами, а в умовах часових рядів демонструє кращу адаптивність порівняно з ансамблевими методами. Багатошарова LSTM із dropout-регуляризацією та оптимізатором ADAM слугує надійною основою для подальшого практичного впровадження системи прогнозування попиту.

Перспективами подальших досліджень є практична реалізація та тестування запропонованої системи на реальних наборах даних електронної комерції, а також дослідження можливостей гібридних підходів, що поєднують LSTM із статистичними методами або ансамблевими алгоритмами для підвищення точності прогнозування в умовах різних сценаріїв попиту.

#### Список літератури:

1. McKinney, W. Python for Data Analysis: Data Wrangling with pandas, NumPy, and Jupyter. 3rd ed. O'Reilly Media, 2022. 579 p.
2. Hastie, T., Tibshirani, R., & Friedman, J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd ed. Springer, 2009. 745 p. DOI: 10.1007/978-0-387-84858-7.

3. Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. Time Series Analysis: Forecasting and Control. 5th ed. Wiley, 2015. 712 p. DOI: 10.1111/jtsa.12194
4. Brockwell, P. J., & Davis, R. A. Introduction to Time Series and Forecasting. 3rd ed. Springer, 2016. 425 p. ISBN 978-3-319-29852-8. DOI: 10.1007/978-3-319-29854-2.
5. Bishop, C. M. Pattern Recognition and Machine Learning. Springer, 2006. 738 p. ISBN 978-0-387-31073-2.
6. Goodfellow, I., Bengio, Y., & Courville, A. Deep Learning. MIT Press, 2016. 775 p. ISBN 978-0-262-03561-3. URL: <https://www.deeplearningbook.org>.
7. Chen, H., Chiang, R. H. L., & Storey, V. C. Business Intelligence and Analytics: From Big Data to Big Impact. MIS Quarterly. 2012. Vol. 36, No. 4. P. 1165–1188. DOI: 10.2307/41703503.
8. Hyndman, R. J., & Athanasopoulos, G. Forecasting: Principles and Practice. 3rd ed. OTexts, 2021. 442 p. URL: <https://otexts.com/fpp3>.
9. Hochreiter, S., & Schmidhuber, J. Long Short-Term Memory. Neural Computation. 1997. Vol. 9, No. 8. P. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.
10. Chopra, S. Supply Chain Management: Strategy, Planning, and Operation. 7th ed. Pearson, 2018. 528 p.
11. Brownlee, J. Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python. Machine Learning Mastery, 2018. 596 p. URL: <https://machinelearningmastery.com>.
12. White, T. Hadoop: The Definitive Guide: Storage and Analysis at Internet Scale. 4th ed. O'Reilly Media, 2015. 756 p.
13. Karau, H., Konwinski, A., Zaharia, M., & Wendell, P. Learning Spark: Lightning-Fast Data Analysis. O'Reilly Media, 2015. 276 p.

**Vakaliuk T. A., Fant M. O., Duniev S. S., Vlasenko O.V., Kolomiets V. V. OVERVIEW OF METHODS FOR FORECASTING THE DYNAMICS OF DEMAND FOR GOODS**

*The article provides a comprehensive review of modern methods and approaches to forecasting the dynamics of demand for goods used in e-commerce and retail trade. Three main categories of methods are considered, namely statistical models, machine learning methods, and big data analytics. Within the framework of statistical models, the methods of linear and multiple regression, exponential smoothing, as well as ARIMA and SARIMA time series models are analysed. It is shown that these approaches are effective for forecasting in conditions of stable demand, but have limitations when working with non-linear dependencies and large arrays of heterogeneous data.*

*To overcome these limitations, machine learning methods are considered, in particular logistic regression, decision trees, ensemble methods (Random Forest and Gradient Boosting), as well as recurrent neural networks of the LSTM (Long Short-Term Memory) type. A comparative analysis of these approaches is carried out according to key criteria, including forecasting accuracy, scalability, ability to model nonlinear dependencies, training data volume requirements, and computational complexity. It has been proven that LSTM neural networks have significant advantages for time series forecasting due to their ability to capture long-term dependencies, model nonlinear relationships, and adapt to new market conditions through retraining.*

*The role of big data analytics in modern forecasting systems is highlighted separately. The capabilities of the Hadoop and Apache Spark platforms for distributed processing of structured and unstructured data from heterogeneous sources in real time are considered. The feasibility of using a multi-layer LSTM architecture with dropout regularisation and an ADAM optimiser to build an analytical and information system for demand forecasting is justified. The proposed system involves processing input data on previous demand volumes, seasonal factors and additional parameters, processing them through hidden LSTM layers and forming predicted values on the output layer.*

**Keywords:** demand forecasting, machine learning, neural networks, LSTM, time series, ARIMA, SARIMA, big data analytics, Random Forest, Gradient Boosting.

Дата першого надходження статті до видання: 05.02.2026

Дата прийняття статті до друку після рецензування: 06.03.2026

Дата публікації (оприлюднення) статті 11.05.2026