

**Лук'янець Єлизавета Олександрівна**

здобувач освіти

Волинський національний університет імені Лесі Українки, Луцьк, Україна

ORCID: 0009-0002-2149-6650

lukanecelizaveta@gmail.com

Мамчич Тетяна Іванівна

кандидат фізико-математичних наук, доцент

Волинський національний університет імені Лесі Українки, Луцьк, Україна

ORCID: 0000-0002-1934-1484

tetyana.mamchych@gmail.com

Гришанович Тетяна Олександрівна

кандидат фізико-математичних наук, доцент

Волинський національний університет імені Лесі Українки, Луцьк, Україна

ORCID: 0000-0002-3595-6964

Hryshanovych.Tatiana@vnu.edu.ua

Собчук Оксана Миколаївна

кандидат педагогічних наук, доцент

Волинський національний університет імені Лесі Українки, Луцьк, Україна

ORCID: 0000-0003-2185-9896

sobchuk.oksana@vnu.edu.ua

**ЗАСТОСУВАННЯ ГРАДІЄНТНОГО БУСТИНГУ ДЕРЕВ РІШЕНЬ ДЛЯ ПРОГНОЗУВАННЯ
ЧАСОВИХ РЯДІВ ПРОДАЖІВ**

Анотація. У статті досліджено особливості застосування алгоритмів градієнтного бустингу дерев рішень для прогнозування часових рядів продажів у сфері реалізації автозапчастин. Розглянуто підходи до побудови системи прогнозування валового доходу з використанням платформи ML.NET та моделі FastTree Regression. Метою дослідження є розроблення інформаційно-аналітичної системи прогнозування часових рядів продажів із використанням алгоритму градієнтного бустингу дерев рішень FastTree Regression для врахування сезонних коливань і нерівномірності попиту на ринку автозапчастин. Запропонований підхід орієнтований на підвищення ефективності аналізу транзакційних даних та підтримку процесів фінансового планування підприємств. Результати дослідження можуть бути використані для автоматизації прогнозування показників продажів і вдосконалення систем бізнес-аналітики. Проаналізовано методи попередньої обробки масиву транзакційних даних, виявлення аномальних значень та формування часових ознак. У роботі вдосконалено підхід до побудови та нормалізації сезонних ознак у межах конвеєра обробки даних, що сприяє підвищенню адаптивності моделі до нерівномірності попиту. На відміну від стандартних підходів, що обмежуються використанням статичних часових ознак, запропоноване рішення забезпечує автоматизоване формування сезонних характеристик у процесі прогнозування. Для забезпечення ефективності роботи системи модулі аналітики інтегровано з механізмами фільтрації, обробки та агрегування фінансових показників на рівні бази даних. Реалізовано механізми імпорту первинних даних, збереження результатів у форматі JSON та автоматизованого формування прогнозних значень на заданий період планування. Проведено апробацію моделі на історичних даних продажів за 2023–2026 роки, а якість прогнозування оцінено за допомогою статистичних метрик. Отримані результати підтверджують придатність запропонованого підходу для автоматизованого аналізу динаміки продажів та прогнозування майбутніх показників доходу підприємств роздрібною торгівлі. Отримані значення коефіцієнта детермінації $R^2 = 0,90$ та показника $RMSE = 287\,883$ грн свідчать про ефективність використання ансамблевих методів для прогнозування часових рядів продажів в умовах високої варіативності попиту. Розроблена веб система з використанням архітектури



ASP.NET Core MVC та інструментів інтерактивної візуалізації може бути використана у практичних процесах фінансового аналізу, планування обсягів закупівель і підтримки прийняття управлінських рішень підприємств сектору роздрібної торгівлі.

Ключові слова: градієнтний бустинг; FastTree Regression; ML.NET; прогнозування продажів; часові ряди; машинне навчання; фінансова аналітика; ринок автозапчастин.

ВСТУП

Постановка проблеми. Ефективне управління діяльністю підприємств, що функціонують на ринку автозапчастин, потребує опрацювання значних обсягів транзакційних даних з метою підтримки процесу прийняття управлінських рішень. Одним із ключових завдань у цьому контексті є прогнозування фінансових показників, зокрема валового доходу, який характеризує результати діяльності підприємства та рівень його ринкової стійкості. Актуальність зазначеної задачі зростає в умовах нестабільності ринку та постійних змін споживчого попиту, що вимагає від підприємств оперативного реагування на зовнішні фактори.

Сучасні інформаційні технології надають широкий спектр засобів для аналізу даних і побудови прогнозних моделей. Важливе місце серед них посідає платформа .NET та бібліотека машинного навчання ML.NET, які надають можливість реалізовувати алгоритми аналізу часових рядів, виявляти закономірності зміни фінансових показників та формувати прогностичні оцінки на основі історичних даних.

Водночас застосування методів градієнтного бустингу дерев рішень для прогнозування часових рядів валового доходу підприємства потребує:

- розробки підходів до попередньої обробки даних, зокрема виявлення викидів, нормалізації показників та формування часових ознак;
- вибору та налаштування моделей прогнозування для досягнення необхідного рівня точності прогнозу;
- інтеграції результатів прогнозування у систему фінансового аналізу підприємства для підтримки процесів планування, бюджетування та управління закупівлями.

Наукова проблема дослідження полягає у визначенні підходів до адаптації алгоритмів градієнтного бустингу для аналізу реальних фінансових показників із урахуванням сезонних коливань та нерівномірності попиту. Важливим завданням є встановлення параметрів моделей, які забезпечують найбільш точні результати прогнозування в умовах ринку автозапчастин, а також вибір доцільних метрик оцінювання їхньої ефективності.

Аналіз останніх досліджень і публікацій. Прогнозування продажів і фінансових показників підприємств є одним із ключових напрямів сучасної бізнес-аналітики, оскільки точність прогнозів безпосередньо впливає на ефективність управління запасами, фінансове планування, оптимізацію маркетингових стратегій та прийняття управлінських рішень [3], [8]. В умовах цифровізації економічних процесів підприємства дедалі активніше використовують технології Big Data для аналізу поведінки споживачів, оцінювання попиту та прогнозування валового доходу. Застосування аналітичних платформ і методів обробки великих обсягів даних дає змогу виявляти приховані закономірності у торговельних процесах, автоматизувати процес аналізу та підвищувати ефективність управління продажами [3], [8].

Традиційні методи прогнозування часових рядів, засновані на статистичних моделях та класичних методах регресії, у багатьох випадках демонструють недостатню ефективність при роботі зі складними наборами даних, що характеризуються сезонністю, нерівномірністю попиту та впливом зовнішніх факторів [6], [10]. Особливо це проявляється у сфері роздрібної торгівлі та ринку автозапчастин, де обсяги продажів можуть суттєво змінюватися залежно від технічного обслуговування транспорту, сезонних навантажень та економічних чинників. У зв'язку з цим у сучасних дослідженнях активно застосовуються методи машинного навчання, здатні аналізувати великі обсяги даних, виявляти нелінійні залежності між параметрами та формувати більш точні прогнози [6], [10].

У сучасних дослідженнях значна увага приділяється застосуванню ансамблевих алгоритмів машинного навчання для прогнозування продажів. Для побудови прогнозних моделей використовуються дерева рішень, Random Forest, XGBoost, нейронні мережі та гібридні моделі [6], [9], [10]. Такі підходи забезпечують можливість аналізу історичних даних про продажі, врахування сезонних коливань і змін споживчої активності. Встановлено, що ансамблеві методи на основі дерев рішень демонструють високу точність прогнозування завдяки здатності працювати з багатовимірними наборами даних та враховувати складні взаємозв'язки між показниками [6], [9].



Особливий інтерес становлять алгоритми градієнтного бустингу дерев рішень, зокрема XGBoost та FastTree Regression. Модель XGBoost реалізує підхід послідовного навчання дерев рішень, у межах якого кожна наступна модель мінімізує похибки попередньої, що сприяє підвищенню якості прогнозних оцінок [2], [6], [9]. Алгоритм FastTree Regression, який використовується у середовищі ML.NET, також базується на принципах градієнтного бустингу та забезпечує ефективну обробку великих наборів даних із можливістю інтеграції моделей у програмні застосунки [4], [5]. Такі підходи є особливо актуальними для прогнозування фінансових показників підприємств у режимі реального часу.

Важливим етапом побудови прогнозних моделей є попередня підготовка даних та формування інформативних ознак. Для підвищення якості навчання моделей застосовуються методи очищення наборів даних, обробки пропущених значень та нормалізації ознак [7]. Для категоріальних параметрів широко використовується бінарне кодування, а для числових показників – методи масштабування та нормалізації, що забезпечує коректну роботу алгоритмів машинного навчання та зменшує вплив шуму в даних [7].

Окремий напрям сучасних досліджень пов'язаний із використанням гібридних моделей, що поєднують методи глибокого навчання та аналіз часових рядів [1]. Такі підходи дозволяють враховувати довгострокові часові залежності та адаптувати моделі до змін ринкового середовища. Разом із цим складність гібридних моделей потребує значних обчислювальних ресурсів і великих обсягів навчальних даних, що обмежує їх практичне використання у прикладних системах прогнозування [1].

Попри значну кількість досліджень у сфері прогнозування продажів, питання застосування моделей градієнтного бустингу для прогнозування часових рядів валового доходу залишається недостатньо дослідженим. Існуючі підходи переважно орієнтовані на загальні методи машинного навчання або статистичні моделі, що не завжди забезпечують достатню точність прогнозування в умовах високої варіативності попиту та сезонних змін ринку. Крім того, недостатньо дослідженими залишаються питання практичного застосування алгоритмів градієнтного бустингу у системах прогнозування продажів на платформі ML.NET для задач аналізу фінансових показників підприємств у сфері реалізації автозапчастин.

Метою статті є розроблення інформаційно-аналітичної системи прогнозування часових рядів продажів із використанням алгоритму градієнтного бустингу дерев рішень FastTree Regression для врахування сезонних коливань і нерівномірності попиту на ринку автозапчастин.

РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

У роботі реалізовано систему прогнозування валового доходу на основі алгоритму градієнтного бустингу дерев рішень FastTree Regression, що входить до складу платформи ML.NET [5]. Використання ансамблевих моделей у задачах прогнозування часових рядів продажів зумовлено їхньою здатністю виявляти складні нелінійні залежності між параметрами даних та враховувати вплив сезонних факторів [6], [9], [10]. Такий підхід є особливо актуальним для ринку автозапчастин і систем технічного обслуговування транспорту, де попит характеризується високою варіативністю та залежністю від часових коливань.

Основою функціонування системи є попередня підготовка транзакційних даних. Процес підготовки включає очищення даних, обробку пропущених значень, агрегування показників та формування ознак для навчання моделі. На початковому етапі виконується зчитування транзакційних записів із CSV-файлів, перевірка коректності вхідних значень та їх перетворення у внутрішню структуру системи. Реалізація такого підходу дозволяє забезпечити цілісність даних і мінімізувати ризик виникнення помилок під час подальшої аналітичної обробки [7].

У процесі підготовки даних виконується автоматичне формування показника валового доходу на основі транзакційних записів, що містять інформацію про кількість реалізованої продукції та її вартість. Такий підхід забезпечує узгодженість фінансових розрахунків, спрощує процедуру агрегування даних та підвищує коректність формування аналітичних показників для подальшого навчання моделі.

Для побудови прогнозної моделі використано агреговані місячні показники продажів. Формування часового ряду здійснюється шляхом групування транзакцій за роками та місяцями. У результаті формується вектор ознак, що містить індекс часового періоду, номер місяця року та суму продажів за відповідний період. Врахування часових і сезонних характеристик дозволяє підвищити точність апроксимації часових рядів та покращити якість прогнозування [1], [7], [10].

Для навчання та апробації прогнозної моделі сформовано набір даних на основі історичних транзакційних записів підприємства. Підготовка набору передбачала агрегацію первинних фінансових показників, формування часових ознак та нормалізацію даних для подальшого використання в алгоритмах машинного навчання. Основні характеристики сформованого набору даних наведено в табл. 1.



Таблиця 1

Характеристики вхідного набору даних для моделювання

Найменування параметра	Значення	Призначення у моделі
Об'єкт аналізу	Валовий дохід	Цільовий показник прогнозування
Тип даних	Часовий ряд	Послідовність фінансових показників у часі
Часовий крок	1 місяць	Врахування сезонних змін попиту
Період дослідження	01.2023 – 04.2026	Формування історичної вибірки
Основні ознаки моделі	часовий індекс та номер місяця	Формування трендових і сезонних компонентів
Метод нормалізації	масштабування за методом Min-Max	Масштабування ознак перед навчанням
Горизонт прогнозу	12 місяців	Побудова короткострокового прогнозу

Використання зазначених параметрів забезпечує можливість аналізу як довгострокових тенденцій зміни валового доходу, так і циклічних сезонних коливань, характерних для ринку автозапчастин. Поєднання часових ознак із процедурою нормалізації даних сприяє підвищенню якості прогнозних оцінок.

Для реалізації прогнозної моделі використано платформу ML.NET [5]. Процес обробки даних включає кілька послідовних етапів: формування вектора ознак, мінімаксну нормалізацію значень та навчання моделі FastTree Regression. Нормалізація використовується для приведення ознак до єдиного діапазону значень, що забезпечує збалансований вплив параметрів на результат прогнозування та підвищує стабільність навчання моделі. Використання попередньої нормалізації відповідає рекомендаціям щодо підготовки даних для алгоритмів машинного навчання [7].

Архітектура розробленої системи охоплює повний цикл обробки транзакційних даних – від їх первинного зчитування до формування прогнозних значень та аналітичних показників. На початковому етапі виконується очищення та агрегування даних із подальшим формуванням часових ознак, що характеризують трендові та сезонні компоненти часового ряду. Після нормалізації параметрів підготовлений набір даних передається до конвеєра ML.NET, у межах якого здійснюється навчання моделі FastTree Regression та побудова прогнозу. Узагальнену схему взаємодії основних компонентів системи наведено на рис. 1.




Рис. 1. Схема архітектури та послідовності процесів прогнозування в системі

Модель FastTree Regression реалізує алгоритм градієнтного бустингу дерев рішень, у межах якого прогноз формується шляхом послідовного додавання дерев регресії [5]. Загальний вигляд моделі може бути поданий формулою (1):

$$F_m(x) = \sum_{m=1}^M v h_m(x), \quad (1)$$

де $h_m(x)$ – окреме дерево рішень, M – кількість ітерацій навчання, v – коефіцієнт швидкості навчання.

У системі використано 100 дерев регресії, що дозволяє підвищити точність прогнозування та зменшити ризик перенавчання моделі. Ефективність ансамблевих методів у задачах прогнозування фінансових показників підтверджується результатами досліджень [4], [6], [9].

Науково-практична значущість запропонованого рішення полягає у врахуванні сезонних компонентів під час прогнозування майбутніх періодів. Для кожного прогнозного значення виконується автоматичне обчислення номера майбутнього місяця за формулою (2):

$$m_{next} = ((m_{last} + i - 1) \bmod 12) + 1, \quad (2)$$

де m_{last} – номер останнього відомого місяця, i – номер прогнозного періоду.

На відміну від існуючих підходів до прогнозування у стандартних конвеєрах ML.NET, де часові ознаки часто обмежуються лінійними індексами або базовим бінарним кодуванням (One-Hot Encoding) місяців, запропоновано підхід до побудови динамічних сезонних хвиль у межах єдиного pipeline обробки даних. Новизна рішення полягає у математичній інтеграції циклічної функції залишку від ділення на періодичний горизонт прогнозування безпосередньо в ітераційний процес градієнтного бустингу. Це дозволило моделі FastTree Regression враховувати нелінійний характер коливань попиту та адаптуватися до специфіки ринку автозапчастин без штучного збільшення розмірності простору ознак (feature space), що сприяло підвищенню стабільності прогнозування на віддалених горизонтах планування.

Такий підхід дозволяє враховувати циклічний характер зміни попиту та коректно формувати сезонні компоненти прогнозу. Врахування сезонності узгоджується з результатами досліджень [1], [10], у яких сезонні фактори визначаються як один із ключових елементів прогнозування продажів.

Для забезпечення стабільності роботи системи реалізовано механізм збереження результатів аналізу у форматі JSON. Збереження прогнозних значень дозволяє уникнути повторного навчання моделі при повторному зверненні до аналітичної системи та зменшує обчислювальні витрати.

У процесі функціонування система також формує додаткові аналітичні показники, зокрема загальний дохід, кількість транзакцій, середню вартість замовлення, середні витрати клієнта та частоту покупок. Обчислення зазначених показників на основі агрегованих даних дозволяє формувати аналітичні панелі для підтримки управлінських рішень у сфері продажів і фінансової аналітики [3], [8].

Результати аналітичної обробки відображаються у вигляді інформаційної панелі, що містить показники валового доходу, середньої вартості замовлення, кількості транзакцій та частоти покупок (рис. 2). Використання графічних елементів візуалізації сприяє підвищенню наочності аналізу фінансових показників та спрощує процес прийняття управлінських рішень.




Рис. 2. Візуалізація ключових аналітичних показників системи

Апробація моделі проводилася на історичних даних продажів за 2023–2026 роки. Отримані результати показали, що модель здатна відтворювати загальні тенденції зміни валового доходу та враховувати циклічні коливання попиту. Застосування алгоритму градієнтного бустингу дерев рішень підтвердило доцільність використання ансамблевих методів машинного навчання у задачах прогнозування фінансових показників [6], [9].

Для оцінювання якості побудованої моделі FastTree Regression було проведено апробацію на історичних даних продажів за 2023–2026 роки. Ефективність прогнозування оцінювалася за метриками RMSE та коефіцієнтом детермінації R^2 . Отримане значення $R^2 = 0,9$ свідчить про високу здатність моделі пояснювати зміну часового ряду валового доходу. Значення RMSE становить 287 883 грн, що характеризує середню величину відхилення прогнозних значень від фактичних показників.

Як показано на рис. 3, прогнозні значення зберігають загальну тенденцію зміни валового доходу та відображають сезонні коливання попиту. Порівняння фактичних і прогнозних показників свідчить про здатність моделі адаптуватися до часових змін фінансових даних.



Рис. 3. Динаміка фактичного доходу та прогнозні значення

ВИСНОВКИ ТА ПЕРСПЕКТИВИ ПОДАЛЬШИХ ДОСЛІДЖЕНЬ

У межах проведеного дослідження реалізовано систему прогнозування валового доходу на основі моделі FastTree Regression платформи ML.NET. У роботі вдосконалено підхід до формування часових і сезонних ознак у межах конвеєра обробки даних, що дало змогу підвищити адаптивність моделі до нерівномірності попиту та циклічних змін ринку автозапчастин.

Практичне значення роботи підтверджено результатами апробації моделі на історичних даних за 2023–2026 роки. Отримані результати оцінювання якості прогнозування (значення коефіцієнта детермінації $R^2 = 0,9$ та $RMSE = 287\,883$ грн) свідчать про достатню точність запропонованої моделі та підтверджують можливість її використання для прогнозування валового доходу. Реалізована система продемонструвала здатність відтворювати трендові та сезонні закономірності часових рядів валового доходу. Інтеграція додаткових аналітичних показників, зокрема середньої вартості замовлення, частоти покупок і середніх витрат клієнтів, дозволяє використовувати систему як інструмент підтримки прийняття управлінських рішень у сфері фінансової аналітики, закупівель та планування продажів.

Перспективи подальших досліджень полягають у порівнянні ефективності ансамблевих алгоритмів і рекурентних нейронних мереж у задачах довгострокового прогнозування часових рядів. Окрему увагу доцільно приділити автоматичній оптимізації параметрів моделей залежно від динаміки вхідних даних та змін ринкового середовища.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Boukrouh, I., Idiri, S., Tayalati, F., Azmani, A., & Bouhsaien, L. (2025). A hybrid approach for sales forecasting: Combining deep learning and time series analysis. *International Journal of Engineering, Transactions A: Basics*, 38(4), 859–870. <https://doi.org/10.5829/ije.2025.38.04a.16>
2. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). Association for Computing Machinery. <https://doi.org/10.1145/2939672.2939785>
3. Chad, F. (2025). *Sales performance analytics and data-driven decision making: The role of big data and analytics in optimizing global sales strategies*. ResearchGate. https://www.researchgate.net/publication/389651107_Sales_Performance_Analytics_and_Data-Driven_Decision_Making_-The_role_of_big_data_and_analytics_in_optimizing_global_sales_strategies



4. Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189–1232. <https://doi.org/10.1214/aos/1013203451>
5. Microsoft. (n.d.). *ML.NET documentation*. Microsoft Learn. Retrieved May 12, 2026, from <https://learn.microsoft.com/en-us/dotnet/machine-learning>
6. Mustapha, O. O., & Sithole, T. (2025). Forecasting retail sales using machine learning models. *American Journal of Statistics and Actuarial Sciences*, 6(1), 35–67. <https://doi.org/10.47672/ajsas.2679>
7. Omoosebi, A., Ola, G., & Tyler, J. (2024). *Data preparation and feature engineering*. ResearchGate. https://www.researchgate.net/publication/389860294_Data_Preparation_and_Feature_Engineering
8. Stanescu, G., Duică, A., Podhora, P. P., & Stanescu, S. G. (2024). Use of big data in sales management. *Annales Universitatis Apulensis Series Oeconomica*, 26(1), 106–118.
9. Udosen, A. A., Adesuyan, M. E., Bamidele, O. O., Nteziryayo, D., & Mugerwa, J. (2025). Machine learning models for sales prediction. *Current Trends in Information Communication Technology Research*, 4(1), 116–126. <https://doi.org/10.61867/pcub.v3i1a.203>
10. Venkiteela, P. (2025). Machine learning framework for retail sales forecasting. *International Journal of Computational and Experimental Science and Engineering*, 11(4), 7260–7269. <https://doi.org/10.22399/ijcesen.3993>

**Lukianets Yelyzaveta**

student

Lesya Ukrainka Volyn National University, Lutsk, Ukraine

ORCID: 0009-0002-2149-6650

*lukanecelizaveta@gmail.com***Mamchych Tetyana**

PhD in Mathematics, Associate Professor

Lesya Ukrainka Volyn National University, Lutsk, Ukraine

ORCID: 0000-0002-1934-1484

*tetyana.mamchych@gmail.com***Hryshanovych Tetiana**

PhD in Mathematics, Associate Professor

Lesya Ukrainka Volyn National University, Lutsk, Ukraine

ORCID: 0000-0002-3595-6964

*Hryshanovych.Tatiana@vnu.edu.ua***Sobchuk Oksana**

PhD in Pedagogy, Associate Professor

Lesya Ukrainka Volyn National University, Lutsk, Ukraine

ORCID: 0000-0003-2185-9896

*sobchuk.oksana@vnu.edu.ua***APPLICATION OF GRADIENT BOOSTING DECISION TREES FOR SALES TIME SERIES FORECASTING**

Abstract. The article explores the features of applying gradient boosting algorithms based on decision trees for time series sales forecasting in the automotive parts retail sector. Approaches to the development of a system for gross revenue forecasting using the ML.NET platform and the FastTree Regression model are considered. The aim of the study is to develop an information and analytical system for sales time series forecasting using the FastTree Regression gradient boosting algorithm to account for seasonal fluctuations and irregular demand in the automotive parts market. The proposed approach is aimed at improving the efficiency of transactional data analysis and supporting financial planning processes within enterprises. The obtained results can be used to automate sales forecasting and enhance business analytics systems. Methods for preprocessing transactional data, anomaly detection, and generating time-based features are analyzed. The paper proposes an improved approach to building and normalizing seasonal features within the data processing pipeline, which increases the model's adaptability to irregular demand. Unlike standard approaches limited to the use of static time-related features, the proposed solution provides automated generation of seasonal characteristics during the forecasting process. To ensure system performance efficiency, the analytical modules are integrated directly with data filtering, processing, and aggregation mechanisms at the database level. Mechanisms for primary data import, saving results in JSON format, and automated generation of forecasted values for a given planning horizon are implemented. The model was validated using historical sales data for the 2023–2026 period, and the forecasting quality was evaluated using statistical metrics. The obtained results confirm the applicability of the developed approach for automated analysis of sales dynamics and forecasting of future revenue indicators in retail environments. The obtained value of the coefficient of determination ($R^2 = 0.90$) and $RMSE = 287,883$ UAH demonstrate the effectiveness of ensemble methods for time series sales forecasting under conditions of high demand variability. The developed web system based on the ASP.NET Core MVC architecture and interactive visualization tools can be effectively used in practical processes of financial analysis, procurement volume planning, and management decision-making of retail companies.

Keywords: gradient boosting; FastTree Regression; ML.NET; sales forecasting; time series; machine learning; financial analytics; automotive parts market.



REFERENCES (TRANSLATED AND TRANSLITERATED)

1. Boukrouh, I., Idiri, S., Tayalati, F., Azmani, A., & Bouhsaien, L. (2025). A hybrid approach for sales forecasting: Combining deep learning and time series analysis. *International Journal of Engineering, Transactions A: Basics*, 38(4), 859–870. <https://doi.org/10.5829/ije.2025.38.04a.16>
2. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). Association for Computing Machinery. <https://doi.org/10.1145/2939672.2939785>
3. Chad, F. (2025). *Sales performance analytics and data-driven decision making: The role of big data and analytics in optimizing global sales strategies*. ResearchGate. https://www.researchgate.net/publication/389651107_Sales_Performance_Analytics_and_Data-Driven_Decision_Making_-The_role_of_big_data_and_analytics_in_optimizing_global_sales_strategies
4. Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189–1232. <https://doi.org/10.1214/aos/1013203451>
5. Microsoft. (n.d.). *ML.NET documentation*. Microsoft Learn. Retrieved May 12, 2026, from <https://learn.microsoft.com/en-us/dotnet/machine-learning>
6. Mustapha, O. O., & Sithole, T. (2025). Forecasting retail sales using machine learning models. *American Journal of Statistics and Actuarial Sciences*, 6(1), 35–67. <https://doi.org/10.47672/ajsas.2679>
7. Omoseebi, A., Ola, G., & Tyler, J. (2024). *Data preparation and feature engineering*. ResearchGate. https://www.researchgate.net/publication/389860294_Data_Preparation_and_Feature_Engineering
8. Stanescu, G., Duică, A., Podhora, P. P., & Stanescu, S. G. (2024). Use of big data in sales management. *Annales Universitatis Apulensis Series Oeconomica*, 26(1), 106–118.
9. Udosen, A. A., Adesuyan, M. E., Bamidele, O. O., Ntezirayayo, D., & Mugerwa, J. (2025). Machine learning models for sales prediction. *Current Trends in Information Communication Technology Research*, 4(1), 116–126. <https://doi.org/10.61867/pcub.v3i1a.203>
10. Venkiteela, P. (2025). Machine learning framework for retail sales forecasting. *International Journal of Computational and Experimental Science and Engineering*, 11(4), 7260–7269. <https://doi.org/10.22399/ijcesen.3993>

Отримано редакцією журналу / Received: 03.06.26

Прорецензовано / Revised: 16.06.26

Схвалено до друку / Accepted: 26.10.26



This work is licensed under Creative Commons Attribution-noncommercial-sharelike 4.0 International License.