

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерних наук _____
(повна назва)

Кафедра _____ програмної інженерії _____
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти _____ другий (магістерський) _____

_____ Дослідження методів штучного інтелекту _____
_____ для автоматизації бізнес-процесів _____
(тема)

Виконав:
здобувач _____ 2 _____ року навчання
групи _____ ПЗМ-23-1 _____

_____ **Артем КУЩОВ** _____
(Власне ім'я, ПРІЗВИЩЕ)

Спеціальність _____ 121 – Інженерія програмного
забезпечення _____
(код і повна назва спеціальності)

Тип програми _____ освітньо-наукова _____

Керівник _____ доц. Наталя ВАЛЕНДА _____
(посада, Власне ім'я, ПРІЗВИЩЕ)

Допускається до захисту
Зав. кафедри

_____ **Кирило СМЕЛЯКОВ** _____
(підпис) (Власне ім'я, ПРІЗВИЩЕ)

2025 р.

Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерних наук _____
 Кафедра _____ програмної інженерії _____
 Рівень вищої освіти _____ другий (магістерський) _____
 Спеціальність _____ 121 – Інженерія програмного забезпечення _____
 Тип програми _____ освітньо-наукова програма _____
 Освітня програма _____ Інженерія програмного забезпечення _____
 (шифр і назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____

(підпис)

«____» _____ 2025 р.

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові _____ Купцову Артему Дмитровичу _____

(прізвище, ім'я, по батькові)

1. Тема роботи «Дослідження методів штучного інтелекту для автоматизації бізнес-процесів»

Затверджена наказом по університету від 15.04. 2025р. № 290 См2. Термін подання студентом роботи до екзаменаційної комісії 09.06.2025

3. Вихідні дані до роботи штучний інтелект, бізнес-процеси, автоматизовані процеси, машинне навчання, аналітика великих даних, когнітивні технології, рівні автоматизації, результати автоматизації, Python, Numpy, Pandas, Seaborn, Sklearn, Matplotlib, середовище розробки DataSpell.

4. Перелік питань, що потрібно опрацювати в роботі аналіз предметної галузі, огляд й аналіз літературних та наукових джерел, постановка задачі, теоретичне дослідження, практичне дослідження, висновки із роботи.

КАЛЕНДАРНИЙ ПЛАН

Но- мер	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Аналіз предметної галузі	15.04.2025	виконано
2	Огляд й аналіз літературних, наукових джерел	24.04.2025	виконано
3	Постановка задачі	30.04.2025	виконано
4	Теоретичне дослідження	06.05.2025	виконано
5	Методологія дослідження	09.05.2025	виконано
6	Імплементация моделей	12.05.2025	виконано
7	Проведення експерименту	15.05.2025	виконано
8	Підготовка пояснювальної записки	18.05.2025	виконано
9	Перевірка на наявність ознак академічного плагіату	20.05.2025	виконано
10	Захист роботи	9.06.2025	виконано

Дата видачі завдання 15 квітня 2025р.

Студент (ка/и) _____ Купцов А.Д.
(підпис)

Керівник роботи _____ доц. Валенда Н.А.
(підпис) (посада, прізвище, ініціали)

РЕФЕРАТ / ABSTRACT

Пояснювальна записка містить: 86 с., 19 рис., 14 джерел.

ШТУЧНИЙ ІНТЕЛЕКТ, АВТОМАТИЗАЦІЯ, МАШИННЕ НАВЧАННЯ,
АНАЛІЗ ВЕЛИКИХ ДАНИХ.

Об'єктом дослідження є автоматизація бізнес-процесів за допомогою штучного інтелекту та машинного навчання.

Метою роботи є проведення дослідження продуктивності автоматизації бізнес-процесів за допомогою штучного інтелекту та машинного навчання.

Методами розробки та проектування є використання різних методів машинного навчання для прогнозування попиту на послуги та товари, які надає бізнес.

У результаті кваліфікаційної роботи було проведено опис предметної галузі, визначено моделі штучного інтелекту для подальшого аналізу, виконано математичний опис вказаних моделей, виконано програмну реалізацію обраних моделей та алгоритмів попередньої обробки даних, проведено експеримент для дослідження ефективності прогнозування попиту на послуги та товари обраними моделями.

ARTIFICIAL INTELLIGENCE, AUTOMATION, MACHINE LEARNING, BIG DATA ANALYSIS.

The object of research is the automation of business processes using artificial intelligence and machine learning.

The purpose of the work is to conduct a study of the productivity of business process automation using artificial intelligence and machine learning.

The development and design methods are the use of various methods of machine learning for forecasting will be used for services and products that generate business.

As a result of the qualified work, a description of the subject matter was carried out, a model of piece intelligence was assigned for further analysis, a mathematical description of the indicated models was created, a program implementation of the resulting models and forward processing algorithms was determined According to these data, an experiment was conducted to investigate the effectiveness of predicting the consumption of goods and services using the selected models.

Заява щодо самостійного виконання кваліфікаційної роботи та можливості її публікації в електронному архіві відкритого доступу EIArKhNURE.

Завідувачу кафедри

ПІ

(скорочена назва кафедри)

проф. Кирилу СМЕЛЯКОВУ

(вчене звання, сласне ім'я, прізвище)

ЗАЯВА

щодо самостійності виконання кваліфікаційної роботи та можливості її публікації (та/або публікації анотації кваліфікаційної роботи) в електронному архіві відкритого доступу EIAr KhNURE

Я, Купцов Артем Дмитрович
(прізвище, ім'я, по батькові)

здобувач вищої освіти на другому (магістерському) рівні вищої освіти академічної групи ПІЗМ-23-1

кафедра програмної інженерії,
(повна назва кафедри)

заявляю: моя кваліфікаційна робота на тему

Дослідження методів штучного інтелекту для автоматизації бізнес-процесів,
(назва роботи)

що буде представлена в екзаменаційну комісію для публічного захисту, виконана самостійно, в ній не містяться елементи плагіату і вона може бути опублікована в репозиторії "EIArKhNURE". Погоджуюся з авторським договором, відповідно до Положення про репозиторій ХНУРЕ "EIArKhNURE". Всі запозичення з друкованих та електронних джерел мають відповідні посилання.

Я ознайомлений (а) з вимогами академічної доброчесності, згідно з якими виявлення плагіату є підставою для відмови в допуску кваліфікаційної роботи до захисту та застосування дисциплінарних заходів.

Дата 29.05.2025

Підпис



ЗМІСТ

Вступ.....	9
1 Опис предметної галузі.....	11
1.1 Вплив штучного інтелекту на трансформацію бізнес-середовища	11
1.2 Оптимізація бізнес-процесів за допомогою штучного інтелекту	13
1.3 Складності впровадження штучного інтелекту у бізнес-процеси	15
1.4 Аналіз наукових та літературних джерел.....	16
1.5 Аналіз літератури	17
1.6 Постановка задачі.....	21
2 Теоретичне дослідження	23
2.1 Роль штучного інтелекту в автоматизація бізнес процесів	23
2.2 Інтеграція штучного інтелекту у Big-tech компаніях.....	24
2.3 Ризики впровадження штучного інтелекту	29
2.4 Проблеми інтеграції штучного інтелекту до існуючих процесів	30
2.5 Трансформація бізнес-моделей під впливом штучного інтелекту	31
3 Методологія дослідження.....	33
3.1 Аналіз методів прогнозування.....	33
3.2 Математичне представлення.....	35
4 Імплементация моделей.....	40
4.1 Огляд даних	40
4.2 Попередня обробка даних	44
5 Проведення експерименту.....	52
5.1 Використання множинної лінійної регресії	52
5.2 Використання моделі хребтової регресії	54
5.3 Використання регресійної моделі ласо	56
5.4 Використання еластичної мережевої регресії	58
5.5 Використання моделі поліноміальної регресії.....	60
5.6 Порівняння методів оцінювання моделей	64
Висновки	68
Перелік джерел посилання	70

Перелік джерел посилання за науковими напрямками керівника та науковців кафедри програмної інженерії	72
---	----

ВСТУП

Зростання складності бізнес-процесів і конкуренція на глобальному ринку змушують компанії впроваджувати технологічні інновації для підвищення продуктивності. Штучний інтелект стає важливим інструментом для бізнесу, що прагне підвищити свою конкурентоспроможність, оптимізувати витрати та забезпечити гнучкість операцій. Впровадження штучного інтелекту дозволяє автоматизувати як рутинні, так і складні бізнес-процеси, зокрема аналіз великих обсягів даних, прогнозування ринкових тенденцій і персоналізацію обслуговування клієнтів. Це особливо важливо в умовах динамічного розвитку технологій та підвищення вимог споживачів. Попри очевидні переваги, компанії часто стикаються з труднощами у впровадженні штучного інтелекту через відсутність досвіду, високу вартість технологій та необхідність адаптації персоналу до нових умов роботи. Таким чином, дослідження впливу штучного інтелекту на автоматизацію бізнес-процесів є критично важливим для визначення шляхів ефективного використання цих технологій у сучасних умовах. Вивчення цього питання допоможе зрозуміти, як бізнес може інтегрувати інновації з найменшими ризиками і максимальними вигодами.

Метою цього дослідження є створення чітких рекомендацій щодо ефективного впровадження штучного інтелекту для автоматизації бізнес-процесів. Поставлену мету передбачається досягти через аналіз поточного стану автоматизації в різних галузях, виявлення ключових викликів та можливостей, а також розробку практичних підходів до інтеграції штучного інтелекту. Важливо не тільки визначити, як саме штучний інтелект впливає на ефективність процесів, але й знайти шляхи оптимізації цих впливів, враховуючи специфіку кожного окремого бізнесу.

Об'єктом дослідження є бізнес-процеси, які можна автоматизувати за допомогою технологій штучного інтелекту. Це включає як прості операції на кшталт обробки документів або управління базами даних, так і складні завдання, що потребують аналізу даних та прийняття рішень у реальному часі. Предмет

дослідження зосереджено на вивченні того, як впровадження штучного інтелекту впливає на продуктивність, швидкість виконання завдань, якість обслуговування клієнтів та фінансові показники компаній. Це дозволяє не тільки зрозуміти природу впливу штучного інтелекту на бізнес-процеси, але й сформулювати підходи до управління цим впливом.

Практичне значення результатів дослідження полягає в тому, що вони можуть бути використані для оптимізації роботи підприємств у різних галузях, зокрема у фінансах, логістиці, маркетингу, виробництві та сфері послуг. Вони дозволять компаніям ефективно використовувати можливості штучного інтелекту, знижуючи витрати і ризики та підвищуючи загальну продуктивність і якість роботи.

1 ОПИС ПРЕДМЕТНОЇ ГАЛУЗІ

1.1 Вплив штучного інтелекту на трансформацію бізнес-середовища

Штучний інтелект має глибокий і трансформаційний вплив на автоматизацію бізнес-процесів, що відкриває нові можливості для підвищення ефективності та створення конкурентних переваг. Автоматизація за допомогою штучного інтелекту дозволяє компаніям оптимізувати як прості, так і складні процеси, які раніше вимагали значного людського втручання. Завдяки штучному інтелекту стає можливим автоматизувати рутинні операції, які виконуються постійно, такі як введення даних, обробка платежів або сортування документів. Це звільняє працівників від повторюваних завдань і дозволяє їм зосередитися на творчій та стратегічній роботі.

Важливою перевагою використання штучного інтелекту є його здатність працювати з великими обсягами даних. Алгоритми машинного навчання можуть швидко аналізувати інформацію, виявляти закономірності та робити прогнози, що значно прискорює прийняття рішень. Наприклад, у фінансовій сфері штучний інтелект допомагає виявляти підозрілі транзакції або оцінювати кредитні ризики. В охороні здоров'я він використовується для діагностики захворювань на основі аналізу медичних зображень, що дозволяє лікарям ухвалювати більш точні рішення [1].

Ще одним важливим аспектом є персоналізація обслуговування клієнтів. Системи, що працюють на базі штучного інтелекту, можуть аналізувати уподобання користувачів і пропонувати індивідуальні рішення. Це помітно в електронній комерції, де алгоритми штучного інтелекту рекомендують товари або послуги на основі попередніх покупок і поведінки клієнта. Крім того, чат-боти та віртуальні асистенти забезпечують цілодобову підтримку користувачів, що підвищує рівень задоволеності клієнтів і знижує навантаження на відділи підтримки.

Впровадження штучного інтелекту також позитивно впливає на управління ризиками. Системи із використанням штучного інтелекту можуть прогнозувати

ризиками, аналізуючи великі масиви даних у реальному часі. Це дозволяє компаніям вчасно реагувати на потенційні загрози та ухвалювати обґрунтовані рішення. Наприклад, у виробничій сфері штучний інтелект допомагає прогнозувати несправності обладнання та планувати профілактичні ремонти, що запобігає простою та знижує витрати на ремонтні роботи.

Створення нових бізнес-моделей за допомогою штучного інтелекту дозволяє компаніям виходити за рамки традиційних підходів до ведення бізнесу, відкриваючи нові джерела доходу та вдосконалюючи взаємодію з клієнтами. Штучний інтелект трансформує способи створення цінності, надаючи можливість розробляти продукти та послуги, що адаптуються до індивідуальних потреб користувачів. Це сприяє переходу від масового виробництва до персоналізованих рішень, що відповідають конкретним запитам клієнтів.

Однією з ключових тенденцій є використання даних як основи для створення нових бізнес-моделей. Компанії, що володіють великими обсягами даних, можуть монетизувати їх через аналітичні сервіси або прогнозування тенденцій ринку.

Штучний інтелект також стимулює розвиток сервісних бізнес-моделей, орієнтованих на надання послуг "як продукту". Наприклад, замість продажу обладнання компанії можуть пропонувати його оренду з використанням моделей передплати, де плата стягується за фактичне використання. Завдяки прогнозному аналізу алгоритмів машинного навчання дозволить оптимізувати такі послуги, зменшуючи витрати та підвищуючи ефективність.

У галузі фінансів та страхування штучний інтелект дає змогу створювати гнучкі моделі ціноутворення, що враховують ризики в реальному часі, а також впроваджувати автоматизовані системи обробки заявок та управління активами. В охороні здоров'я нові моделі можуть включати дистанційний моніторинг пацієнтів та діагностику захворювань за допомогою мобільних додатків, що забезпечує доступ до медичних послуг навіть у віддалених регіонах[2].

Важливим аспектом є також поява платформового бізнесу, де штучний інтелект виступає як центральний елемент, що з'єднує постачальників і споживачів. Наприклад, платформи для спільного користування транспортом чи житлом

використовують машинне навчання для управління попитом і пропозицією, оптимізації маршрутів і ціноутворення.

1.2 Оптимізація бізнес-процесів за допомогою штучного інтелекту

Оптимізація складних процесів і управління за допомогою штучного інтелекту дозволяє бізнесу досягати нових рівнів ефективності та гнучкості. Штучний інтелект здатен аналізувати великі обсяги даних у реальному часі, виявляти приховані закономірності та прогнозувати результати, що значно покращує процеси прийняття рішень. Завдяки цьому компанії можуть оптимізувати логістичні ланцюги, управління виробництвом та ресурсами, зменшувати витрати та підвищувати швидкість виконання операцій.

У сфері логістики машинне навчання дозволяє оптимізувати маршрути доставки, враховуючи фактори, як-от трафік, погодні умови та терміновість замовлень. У виробництві алгоритми машинного навчання прогнозують можливі збої обладнання та допомагають планувати профілактичне обслуговування, що запобігає простою та знижує витрати на ремонт.

Штучний інтелект сприяє автоматизації управлінських процесів, таких як планування, контроль якості та управління ризиками. У фінансових установах він допомагає аналізувати ризики інвестицій і виявляти шахрайські транзакції. В управлінні персоналом, використовується для підбору кадрів, прогнозування потреб у персоналі та оцінки продуктивності [2].

Зниження витрат і підвищення ефективності є одними з ключових переваг впровадження штучного інтелекту у бізнес-процеси. Завдяки автоматизації рутинних завдань компанії можуть значно скоротити витрати на оплату праці та мінімізувати помилки, що виникають через людський фактор. Алгоритми штучного інтелекту здатні виконувати завдання швидше та безперервно, що підвищує продуктивність і дозволяє оптимізувати використання ресурсів.

Один із прикладів зниження витрат, який буде актуальним для більшості підприємств – автоматизація обробки даних та документообігу. Системи на основі штучного інтелекту можуть автоматично сортувати, аналізувати та обробляти

документи, що скорочує час на ручну обробку та зменшує потребу у великій кількості співробітників. У виробничих процесах використання штучного інтелекту для моніторингу та прогнозування несправностей обладнання дозволяє своєчасно проводити технічне обслуговування, запобігаючи дорогим поломкам та простою [2].

Штучний інтелект також підвищує ефективність шляхом оптимізації логістичних процесів. Алгоритми можуть визначати найефективніші маршрути доставки, оптимізувати управління запасами та прогнозувати попит на продукцію, що знижує витрати на зберігання та транспортування. У сфері обслуговування клієнтів автоматизовані чат-боти та віртуальні асистенти забезпечують швидке вирішення запитів без залучення великої кількості працівників.

Крім того, штучний інтелект допомагає оптимізувати управлінські рішення, аналізуючи великі обсяги даних і надаючи обґрунтовані рекомендації. Це дозволяє компаніям ефективніше планувати ресурси, уникати зайвих витрат та швидко адаптуватися до змін ринку.

Штучний інтелект суттєво підвищує якість та швидкість прийняття рішень завдяки здатності аналізувати великі обсяги даних, які неможливо ефективно обробити вручну. Використання алгоритмів машинного навчання дозволяє швидко і точно виявляти приховані закономірності, аналізувати тренди та робити прогнози. Це забезпечує більш інформовану основу для ухвалення рішень, мінімізуючи ризики помилок і суб'єктивності, притаманних людському фактору.

Однією з ключових переваг є здатність штучного інтелекту обробляти дані в реальному часі. Це особливо важливо у швидкоплинних сферах, таких як фінанси, де своєчасність і точність рішень можуть безпосередньо впливати на прибутковість. Наприклад, системи із використанням алгоритмів машинного навчання аналізують ринкові зміни і можуть миттєво надавати рекомендації щодо інвестицій або попереджати про потенційні ризики.

Штучний інтелект також підвищує якість рішень у складних ситуаціях з багатьма змінними. У сфері охорони здоров'я він допомагає лікарям діагностувати захворювання на ранніх стадіях, аналізуючи медичні дані, зображення або

симптоми пацієнтів. Це скорочує час на постановку діагнозу і підвищує його точність.

Крім того, системи на основі штучного інтелекту забезпечують постійне вдосконалення процесів прийняття рішень. Вони адаптуються до змінних умов, самонавчаючись на нових даних, що дозволяє бізнесу залишатися гнучким і ефективно реагувати на виклики. Завдяки цьому організації можуть швидко коригувати свої стратегії та ухвалювати рішення, які забезпечують стійкий розвиток і конкурентні переваги.

1.3 Складності впровадження штучного інтелекту у бізнес-процеси

Впровадження штучного інтелекту у бізнес-процеси є складним і багатогранним завданням, яке потребує врахування численних технічних, організаційних та етичних аспектів. Однією з головних складностей є інтеграція штучного інтелекту у вже існуючі бізнес-системи. Багато компаній використовують застаріле програмне забезпечення або мають складні ІТ-інфраструктури, що ускладнює поєднання нових технологій із традиційними підходами до управління даними та процесами. Цей процес вимагає серйозної модернізації та значних фінансових вкладень.

Ще однією важливою проблемою є доступ до якісних даних. Для навчання та ефективного функціонування алгоритмів машинного навчання потрібні великі обсяги достовірних і релевантних даних. Однак у багатьох організаціях дані зберігаються у фрагментованих або неповних базах, що ускладнює їх обробку та аналіз. Крім того, важливо забезпечити конфіденційність та безпеку даних, що особливо актуально у сферах, де обробляється чутлива інформація, наприклад, у фінансах чи охороні здоров'я.

Технічна складність розробки та налаштування систем з використанням штучного інтелекту також є суттєвим бар'єром. Розробка алгоритмів машинного навчання та їх адаптація до конкретних бізнес-завдань вимагає високого рівня експертизи. Для цього потрібні кваліфіковані фахівці, яких на ринку праці недостатньо. Компанії змушені інвестувати у навчання своїх співробітників або

залучати зовнішніх експертів, що підвищує витрати на проекти із впровадження штучного інтелекту.

Організаційні та культурні аспекти також відіграють важливу роль. Впровадження штучного інтелекту часто зустрічає опір з боку персоналу, який побоюється втрати робочих місць або не розуміє, як працювати з новими технологіями. Необхідно проводити навчання та роз'яснювальну роботу, щоб адаптувати працівників до нових умов. Крім того, керівництву компаній потрібно переглянути підходи до управління та прийняття рішень, оскільки впровадження штучного інтелекту змінює традиційні бізнес-процеси.

Окремим викликом є питання етики та відповідальності. Алгоритми машинного навчання часто працюють як "чорні скриньки", тобто їхні рішення складно пояснити або перевірити. Це створює ризики помилкових рішень або дискримінації, особливо якщо моделі навчаються на упереджених даних. Тому важливо розробляти прозорі алгоритми та впроваджувати механізми контролю, щоб забезпечити етичне використання штучного інтелекту.

1.4 Аналіз наукових та літературних джерел

Основні джерела згруповані за кількома ключовими темами: концептуальні основи штучного інтелекту, технологічні аспекти автоматизації, вплив штучного інтелекту на бізнес-процеси, економічні та соціальні ефекти впровадження штучного інтелекту, а також етичні та правові аспекти його використання.

Для формування джерел для роботи було використано кілька критеріїв відбору джерел. Авторитетність визначалась за науковим статусом видань, академічною репутацією авторів і належністю до провідних університетів чи дослідницьких центрів. Актуальність джерел забезпечувалась аналізом публікацій останніх років, оскільки швидкий розвиток технологій вимагає використання свіжих даних. Особливу увагу приділено об'єктивності та достовірності інформації, для чого враховувались джерела, які базуються на емпіричних дослідженнях або містять ретельно перевірені аналітичні висновки.

Серед основних джерел можна виділити наукові роботи, присвячені методам машинного навчання, зокрема праці про алгоритми глибокого навчання та їхню роль у бізнес-автоматизації. Важливими також є звіти консалтингових компаній, таких як «McKinsey» та «Deloitte» [3], які аналізують вплив штучний інтелект на продуктивність і ефективність бізнесу. Крім того, розглядалися нормативні документи та рекомендації міжнародних організацій, що регулюють впровадження штучного інтелекту, особливо у сферах, де важливі питання безпеки та етики.

1.5 Аналіз літератури

Дослідження впливу штучного інтелекту на автоматизацію бізнес-процесів базуються на ряді фундаментальних теорій, концепцій і моделей, що формують основу для ефективного впровадження технологій в корпоративному середовищі. Основні концептуальні підходи до автоматизації процесів за допомогою штучного інтелекту викладено в роботах провідних науковців і аналітиків, які охоплюють питання оптимізації, управління даними та прийняття рішень.

Теоретичні аспекти автоматизації бізнес-процесів на основі штучного інтелекту викладені у книзі «Artificial Intelligence: Foundations of Computational Agents» Рассела та Норвіга (Russell & Norvig, 2020) [4]. У цьому виданні розглядаються базові концепції інтелектуальних агентів і способи їх застосування для оптимізації бізнес-процесів. Автори акцентують увагу на важливості використання алгоритмів машинного навчання для покращення операційної ефективності.

Практичні кейси та економічний ефект від впровадження штучного інтелекту детально проаналізовано у звіті McKinsey & Company «The State of AI in 2023» [3]. У звіті наведено приклади успішної автоматизації у сферах логістики, фінансів та виробництва, де штучний інтелект забезпечив зниження витрат і підвищення продуктивності на 25-30%. Також підкреслено важливість створення стратегії інтеграції штучного інтелекту для досягнення сталого зростання.

Книга Ніка Бострома «Superintelligence: Paths, Dangers, Strategies» (Bostrom, 2016) [5] зосереджує увагу на довгострокових наслідках впровадження штучного

інтелекту у бізнес і суспільство. Бостром розглядає ризики та переваги використання штучного інтелекту, наголошуючи на необхідності стратегічного підходу до інтеграції нових технологій. Він робить висновок про те, що компанії, які рано адаптують штучний інтелект, зможуть отримати суттєві конкурентні переваги.

У статті «Deep Learning for Business Process Automation» з журналу «Journal of Artificial Intelligence Research» розглядається впровадження глибокого навчання у процесі автоматизації. Автори аналізують приклади використання нейронних мереж для обробки великих даних і прийняття рішень у реальному часі. Дослідження показало, що інтеграція глибокого навчання дозволяє значно скоротити витрати часу та підвищити точність прогнозів.

Регуляторні та етичні аспекти впровадження штучного інтелекту детально викладені в рекомендаціях Європейської комісії щодо етичного використання штучного інтелекту (*European Commission, 2021*). Документ наголошує на важливості дотримання принципів прозорості, відповідальності та захисту даних під час впровадження технологій. Ці аспекти є ключовими для забезпечення довіри до систем із використанням штучного інтелекту та їхнього ефективного використання у бізнесі.

Актуальність інформації, наданої в ключових джерелах про вплив штучного інтелекту на автоматизацію бізнес-процесів, зумовлена глобальними трендами цифрової трансформації та зростанням попиту на оптимізацію операційних витрат і підвищення продуктивності. Світові компанії все активніше впроваджують штучний інтелект для автоматизації рутинних завдань, управління ресурсами та покращення взаємодії з клієнтами. Це підвищує конкурентоспроможність бізнесу і створює нові можливості для зростання, що робить тему дослідження надзвичайно актуальною.

Звіт McKinsey & Company «The State of AI in 2023» [3] є одним із найактуальніших документів, оскільки він базується на найновіших даних, зібраних у глобальному масштабі. Звіт висвітлює останні досягнення у впровадженні штучного інтелекту, а також розглядає тенденції, що формуються.

McKinsey аналізує вплив технологій на продуктивність у різних галузях, таких як фінанси, виробництво та логістика, що дозволяє зробити висновки про актуальність штучного інтелекту для оптимізації процесів у сучасних умовах. Актуальність цього звіту підкріплюється конкретними кейсами, які підтверджують ефективність штучного інтелекту у зниженні витрат і підвищенні ефективності.

Книга Ніка Бострома «Superintelligence» [5] також є актуальною, хоча має більше стратегічний характер. Вона розглядає питання майбутнього розвитку штучного інтелекту та його потенційного впливу на бізнес і суспільство. Її актуальність полягає у висвітленні можливих ризиків та необхідності регулювання технологій, що сьогодні є предметом дискусій у бізнес-середовищі та на рівні урядів різних країн.

Рекомендації Європейської комісії щодо етичного використання штучного інтелекту актуальні з точки зору регулювання та відповідності нормативним вимогам. У зв'язку зі зростанням кількості впроваджень штучного інтелекту в різних галузях, питання прозорості, відповідальності та етики стають першочерговими для бізнесу, що робить це джерело надзвичайно важливим для розуміння контексту автоматизації.

Наукова новизна джерел полягає у розробці нових підходів до автоматизації, які раніше не були широко застосовані. У статті «Deep Learning for Business Process Automation» автори представляють інноваційні алгоритми глибокого навчання для автоматизації складних завдань, таких як аналіз даних та прогнозування. Важливою новизною є можливість адаптації цих алгоритмів до різних галузей і умов бізнесу, що дозволяє підвищити ефективність управління ресурсами та прийняття рішень.

Звіт Deloitte «AI-Fueled Organizations» акцентує увагу на трансформаційних змінах у бізнес-моделях завдяки штучному інтелекту. Новизна цього дослідження полягає в аналізі стратегій побудови організацій, орієнтованих на використання штучного інтелекту як основного драйвера зростання. Висновки Deloitte стосуються створення нових форм бізнесу, що базуються на використанні даних та інтелектуальних систем, що є інноваційним підходом у багатьох сферах.

Використані джерела мають суттєвий вплив на розвиток досліджень у сфері автоматизації. Вони надають практичні рекомендації щодо впровадження штучного інтелекту, а також аналізують ключові ризики та переваги. Це дозволяє сформулювати комплексний підхід до дослідження теми, враховуючи як технічні аспекти, так і етичні та регуляторні виклики.

Впровадження штучного інтелекту значно змінює підходи до автоматизації бізнес-процесів, відкриваючи нові можливості для підвищення продуктивності, оптимізації витрат і створення інноваційних бізнес-моделей. Основні висновки, зроблені на основі огляду літератури, підтверджують, що штучний інтелект має значний вплив на ефективність роботи компаній, особливо в галузях з високим рівнем складності процесів, таких як фінанси, логістика, виробництво та охорона здоров'я.

Аналіз сучасних досліджень дозволяє виділити кілька ключових аспектів:

- технології глибокого навчання та інтелектуальних агентів є провідними інструментами для автоматизації завдань, пов'язаних з аналізом великих обсягів даних, прогнозуванням і прийняттям рішень у реальному часі;
- штучний інтелект демонструє високу ефективність у виконанні рутинних завдань, що дозволяє звільнити людські ресурси для виконання більш креативних або стратегічних функцій;
- етичні та регуляторні аспекти залишаються важливою складовою впровадження штучного інтелекту, оскільки забезпечують прозорість, відповідальність і довіру до технологій.

Попри значний прогрес у дослідженнях, виявлено кілька прогалин, які вимагають подальшого вивчення. По-перше, бракує узгоджених підходів до інтеграції штучного інтелекту в бізнес-процеси з урахуванням різноманітності галузей і організаційних структур. Більшість досліджень зосереджені на вузьких прикладах і не пропонують універсальних моделей, адаптованих до ширших потреб. По-друге, обмежено вивчені довгострокові наслідки впровадження штучного інтелекту, зокрема вплив на зайнятість, корпоративну культуру та стійкість бізнесу до зовнішніх викликів. По-третє, існує недостатній акцент на ролі

штучного інтелекту у формуванні нових бізнес-екосистем, що включають партнерські відносини, орієнтовані на спільну розробку технологій.

Ці висновки обґрунтовують необхідність подальших досліджень, спрямованих на вирішення зазначених прогалин. Зокрема, важливо розробити комплексні моделі інтеграції штучного інтелекту, що враховують як технологічні, так і соціальні аспекти. Також доцільно досліджувати механізми підвищення адаптивності бізнесу до змін, зумовлених впровадженням штучного інтелекту. Це дозволить не лише посилити ефективність автоматизації, але й забезпечити її відповідність сучасним етичним і регуляторним стандартам.

1.6 Постановка задачі

У кваліфікаційній роботі досліджується вплив штучного інтелекту на автоматизацію бізнес-процесів, з акцентом на створення практичних рекомендацій для підвищення ефективності діяльності підприємств. Актуальність теми зумовлена швидким впровадженням інтелектуальних систем у різні сфери економіки, зокрема — у сферу прогнозування попиту та управління запасами, а також необхідністю адаптації бізнесу до цифрової трансформації.

Метою роботи є розробка та апробація моделей машинного навчання для прогнозування попиту в магазині роздрібною торгівлі для оптимізації витрат, підвищення точності планування й ефективного управління ресурсами. Для роботи були поставлені наступні дослідницькі завдання:

- а) аналіз предметної галузі:
 - 1) вивчити сучасний стан автоматизації бізнес-процесів із застосуванням штучного інтелекту, визначивши основні тенденції, переваги та проблеми;
 - 2) оцінити вплив штучного інтелекту на ключові аспекти бізнесу, такі як продуктивність, якість послуг, швидкість прийняття рішень.
- б) вибір методів дослідження та інструментів:
 - 1) обґрунтувати застосування методів машинного навчання для прогнозування попиту;

- 2) визначити критерії ефективності побудованої моделі.
- в) проведення експерименту:
- 1) підготувати датасет з історичними даними про продажі товарів;
 - 2) провести аналіз даних, очищення та нормалізацію для підготовки до навчання моделей;
 - 3) реалізувати кілька моделей машинного навчання для прогнозування попиту;
 - 4) порівняти результати моделей за метриками точності та обрати оптимальну.

Системний підхід дозволив розглядати процес управління попитом як взаємодію багатьох компонентів таких як аналітика, закупівлі, логістика. Машинне навчання застосовувалось як інструмент виявлення закономірностей у даних та побудови прогностичних моделей.

Емпіричні методи забезпечили отримання об'єктивних кількісних результатів. Реалізація моделей у середовищі Python дала змогу повністю автоматизувати процес аналізу та візуалізувати прогнози.

Дослідження обмежене обсягом доступних даних, технічними ресурсами та неможливістю повної інтеграції моделі у реальний бізнес-процес через відсутність співпраці з конкретним підприємством. Усі моделі апробовані на умовних даних, однак структурованих згідно з реальними кейсами.

Крім того, існують регуляторні та етичні обмеження. Дослідження пов'язані з впровадженням штучного інтелекту можуть торкатися питань конфіденційності даних, безпеки або дискримінації. Недостатня правова база в багатьох країнах обмежує можливості для проведення повноцінних експериментів або тестування нових моделей у реальних умовах.

2 ТЕОРЕТИЧНЕ ДОСЛІДЖЕННЯ

2.1 Роль штучного інтелекту в автоматизація бізнес процесів

Роль штучного інтелекту в автоматизації бізнес-процесів є однією з ключових змін у сучасному корпоративному середовищі. Штучний інтелект виступає каталізатором підвищення ефективності, зниження витрат і трансформації способу ведення бізнесу.

Штучний інтелект дозволяє автоматизувати завдання, які раніше вимагали значних людських ресурсів, таких як обробка великих обсягів даних, аналіз поведінки клієнтів, управління запасами та навіть прогнозування майбутніх бізнес-тенденцій. Наприклад, використання машинного навчання в аналітиці дає змогу бізнесам аналізувати великі масиви даних у режимі реального часу, забезпечуючи швидке прийняття рішень.

Важливою роллю штучного інтелекту є персоналізація обслуговування клієнтів. Інтелектуальні чат-боти здатні надавати підтримку 24/7, відповідаючи на запитання клієнтів і вирішуючи їхні проблеми без участі оператора. Це дозволяє скоротити час очікування клієнтів і знизити витрати на підтримку.

Штучний інтелект також активно впроваджується у виробничі процеси. Інтелектуальні системи моніторингу дозволяють зменшити час простоїв, прогнозуючи поломки обладнання та запобігаючи аваріям. Наприклад, у виробничих галузях штучний інтелект може аналізувати показники стану машин і автоматично створювати графіки технічного обслуговування.

У логістиці та управлінні ланцюжками постачання штучний інтелект відіграє вирішальну роль у прогнозуванні попиту, оптимізації маршрутів доставки та управлінні запасами. Наприклад, алгоритми на основі штучного інтелекту дозволяють розраховувати найбільш ефективні маршрути доставки, що зменшує витрати на паливо і час перевезень.

Крім того, штучний інтелект сприяє автоматизації фінансових процесів, таких як управління бюджетами, прогнозування прибутків і ризиків, а також виявлення шахрайських операцій. Завдяки системам штучного інтелекту, які

аналізують поведінку користувачів і транзакції, можна швидко виявляти аномалії, які вказують на можливе шахрайство.

В автоматизації маркетингових процесів штучний інтелект забезпечує можливість персоналізованих рекламних кампаній, автоматизації контент-маркетингу та оцінки ефективності кампаній. Наприклад, алгоритми можуть визначати, які продукти найбільше цікавлять клієнтів, і автоматично надсилати їм відповідні пропозиції [1].

2.2 Інтеграція штучного інтелекту у Big-tech компаніях

Розглянемо три популярні Big-tech компанії, які впроваджують штучний інтелект найактивніше, а саме «Amazon», «Tesla» та «IBM».

Amazon — одна з найбільших технологічних компаній світу, яка активно використовує штучний інтелект для підвищення ефективності та оптимізації своїх операцій. Бізнес процеси, у які компанія «Amazon» інтегрувала штучний інтелект:

- а) логістика та ланцюги постачань:
 - 1) оптимізація маршрутів доставки за допомогою алгоритмів машинного навчання;
 - 2) прогнозування попиту на товари для забезпечення складів необхідними ресурсами.
- б) клієнтський сервіс:
 - 1) використання чат-ботів для оперативної підтримки користувачів та розв'язання звичайних запитів;
 - 2) автоматизація оцінки скарг та запитів з метою швидшого їх вирішення.
- в) рекомендаційні системи:
 - 1) створення персоналізованих рекомендацій для користувачів, що збільшує ймовірність покупок;
 - 2) аналіз даних про споживчу поведінку для удосконалення системи рекомендацій.
- г) оптимізація складських операцій:

- 1) застосування роботизованих систем, що працюють під керівництвом штучного інтелекту, для зберігання, сканування та пакування товарів;
- 2) прогнозування термінів складу та розподілу товарів.

Завдяки інтеграції штучного інтелекту компанія «Amazon» досягла таких цілей:

- а) збільшення доходів:
 - 1) завдяки точнішим рекомендаціям та швидшим доставкам, «Amazon» підвищує рівень задоволення клієнтів та збільшує повторні покупки;
 - 2) за даними компанії, впровадження рекомендаційних систем збільшило обсяг продажів на 35%.
- б) зменшення операційних витрат:
 - 1) автоматизація складських операцій та логістики скорочує робочі витрати та зменшує помилки;
 - 2) застосування роботів «Kiva» скоротило витрати на складування до 20% та зменшило час виконання замовлень на 50%.
- в) підвищення конкурентоспроможності:
 - 1) використання передових технологій штучного інтелекту дозволяє «Amazon» залишатися на передовій ринку, адаптуючись до змінних умов та впроваджуючи інновації швидше за конкурентів;
 - 2) завдяки штучному інтелекту, компанія може обробляти до 1 млн замовлень щоденно.
- г) покращення клієнтського досвіду:
 - 1) чат-боти та персоналізовані рекомендації забезпечують зручність та ефективність для користувачів, що сприяє формуванню лояльності клієнтів;
 - 2) 70% клієнтів використовують персоналізовані рекомендації під час покупок.
- д) оптимізація ресурсів:
 - 1) прогнозування попиту та управління запасами зменшують перевитрати ресурсів, знижуючи екологічний вплив та витрати;

- 2) система прогнозування знизилася рівень надлишкових запасів на 25%.
- е) інновації в продуктах та послугах:
 - 1) використання штучного інтелекту сприяє розвитку нових продуктів і послуг, таких як голосовий асистент «Alexa», що розширює можливості користувачів та відкриває нові ринки для компанії;
 - 2) «Alexa» обслуговує понад 100 млн пристроїв по всьому світу.

Інтеграція штучного інтелекту у бізнес-процеси Amazon дозволила компанії досягти значного прогресу у підвищенні ефективності, зниженні витрат та покращенні взаємодії з клієнтами. Завдяки інноваційному підходу та використанню передових технологій, Amazon зміцнює свої позиції як лідера на глобальному ринку.

Компанія «Tesla», під керівництвом Ілона Маска, є однією з провідних технологічних компаній, яка використовує штучний інтелект для створення інноваційних продуктів та оптимізації своїх бізнес-процесів. Одним із ключових напрямків застосування штучного інтелекту у «Tesla» є розробка автопілоту для електромобілів. Автопілот «Tesla» використовує передові алгоритми комп'ютерного бачення, машинного навчання та нейронні мережі для аналізу даних з сенсорів, камер і радарів, що забезпечує високий рівень автономного керування транспортними засобами. Ця технологія не лише підвищує безпеку на дорогах, але й значно зменшує втому водіїв під час тривалих поїздок.

Штучний інтелект також широко використовується у виробничих процесах «Tesla». Завдяки впровадженню роботизованих систем, контроль якості та складання компонентів електромобілів стали набагато точнішими та швидшими. Штучний інтелект аналізує великий обсяг виробничих даних у реальному часі, що дозволяє ідентифікувати потенційні дефекти на ранніх етапах та мінімізувати відходи. У «Gigafactory», одному з найбільших виробничих об'єктів «Tesla», штучний інтелект допомагає оптимізувати витрати енергії, координувати логістику і забезпечувати ефективне управління запасами.

Одним із значних досягнень «Tesla» є створення суперкомп'ютера «Dojo», який розроблено для навчання нейронних мереж. «Dojo» забезпечує обробку

величезного обсягу даних, зібраних від автомобілів «Tesla», що постійно вдосконалює можливості автопілоту та інших функцій штучного інтелекту. Використання такої обчислювальної потужності дозволило «Tesla» знизити час навчання моделей і скоротити витрати на зовнішні обчислювальні ресурси.

Завдяки інтеграції штучного інтелекту «Tesla» також вдосконалила клієнтський досвід. Система «ОТА» (Over-The-Air) оновлень дозволяє постійно покращувати функціонал автомобілів без необхідності відвідування сервісних центрів. Штучний інтелект аналізує дані про використання автомобіля і надає індивідуальні рекомендації водіям, такі як оптимізація маршруту для економії заряду батареї чи сповіщення про необхідність технічного обслуговування.

Користь від інтеграції штучного інтелекту в бізнес-процеси «Tesla» очевидна. Автономне керування знижує кількість дорожньо-транспортних пригод на 40%, за офіційними звітами компанії. Виробничі процеси стали на 25% ефективнішими завдяки автоматизації та прогнозному аналізу. Рівень задоволення клієнтів також суттєво зріс, оскільки «Tesla» надає продукти та послуги, які адаптуються до потреб споживачів.

Інтеграція штучного інтелекту дала змогу «Tesla» зміцнити свої позиції на ринку, підвищити конкурентоспроможність і стимулювати інновації у транспортній та енергетичній галузях. Компанія продовжує інвестувати у розвиток штучного інтелекту, створюючи передумови для подальших проривів у технологіях майбутнього.

Компанія «ІВМ» вже кілька десятиліть є піонером у сфері штучного інтелекту, активно розвиваючи його застосування у своїх бізнес-процесах та пропонуючи відповідні рішення своїм клієнтам. Однією з найбільш відомих ініціатив компанії є розробка платформи «Watson», яка стала революційним інструментом для аналізу великих даних, автоматизації бізнесу та впровадження інтелектуальних рішень у різноманітні галузі. «Watson» використовує алгоритми машинного навчання, обробки природної мови та комп'ютерного бачення, що дозволяє компаніям вирішувати складні задачі, від прогнозування тенденцій до персоналізації клієнтських послуг.

«IBM» інтегрує штучний інтелект у свої виробничі та управлінські процеси для оптимізації операцій. Штучний інтелект активно використовується для автоматизації управління IT-інфраструктурою, зокрема у рішенні «IBM Cloud Pak». Завдяки аналізу даних у реальному часі, компанія мінімізує ризики простою систем і покращує продуктивність обчислювальних ресурсів. «IBM» також застосовує штучний інтелект для підвищення кібербезпеки через платформу «QRadar», яка ідентифікує потенційні загрози, аналізує поведінкові моделі та попереджає про можливі атаки на ранніх етапах.

Одним із ключових напрямків використання штучного інтелекту в «IBM» є трансформація клієнтського обслуговування. «Watson Assistant», інтегрований у контактні центри, дозволяє автоматизувати обробку запитів клієнтів, скорочуючи час очікування та підвищуючи точність відповідей. Це рішення використовується у різних секторах, включаючи охорону здоров'я, де штучний інтелект допомагає лікарям аналізувати медичні дані, прогнозувати ризики та розробляти персоналізовані плани лікування. У фінансовому секторі «Watson» допомагає виявляти шахрайські операції та забезпечувати відповідність регуляторним вимогам.

Крім того, «IBM» активно впроваджує штучний інтелект для оптимізації своєї внутрішньої діяльності. Наприклад, аналітичні інструменти «Watson» застосовуються для прогнозування потреб у людських ресурсах, що дозволяє ефективніше керувати персоналом та скорочувати витрати. Штучний інтелект також використовується у розробці нових продуктів і послуг, де він аналізує ринкові тенденції, допомагаючи швидше виводити інновації на ринок.

Економічний вплив інтеграції штучного інтелекту у бізнес-процеси «IBM» вражає. Завдяки автоматизації IT-інфраструктури компанія знизила витрати на її обслуговування на 30%. У сфері клієнтського обслуговування час обробки запитів скоротився на 50%, а рівень задоволеності клієнтів зріс на 20%. Впровадження «Watson» у медичні установи дозволило скоротити час на діагностику складних захворювань на 40%, що безпосередньо впливає на якість медичної допомоги.

Інтеграція штучного інтелекту в «ІВМ» є важливим елементом її стратегії інноваційного розвитку. Компанія не лише оптимізує свої процеси, але й надає інструменти, що дозволяють клієнтам по всьому світу підвищувати ефективність та конкурентоспроможність. Завдяки глибокому досвіду та інвестиціям у технології майбутнього, «ІВМ» залишається одним із ключових гравців у сфері штучного інтелекту, сприяючи глобальному прогресу в цій галузі [3].

2.3 Ризики впровадження штучного інтелекту

Одним із ключових ризиків є порушення етичних норм і правових стандартів. Використання штучного інтелекту часто пов'язане з обробкою великих обсягів персональних даних, що викликає занепокоєння щодо конфіденційності та безпеки інформації. Компанії повинні дотримуватися законодавства про захист даних, такого як GDPR в Європейському Союзі, щоб уникнути юридичних наслідків і втрати довіри клієнтів.

Початкові витрати на впровадження штучного інтелекту є однією з найбільших перешкод для багатьох компаній, особливо для малого та середнього бізнесу. Ці витрати охоплюють широкий спектр фінансових вкладень, починаючи з дослідження і розробки та закінчуючи підтримкою систем після їх впровадження.

Передусім, значну частину витрат становить необхідність створення або придбання відповідної інфраструктури. Для впровадження систем штучного інтелекту можуть знадобитися потужні сервери, хмарні обчислювальні ресурси, інструменти для роботи з великими даними та спеціалізоване програмне забезпечення. Наприклад, навчання складних моделей глибокого навчання вимагає використання графічних процесорів або навіть суперкомп'ютерів, що суттєво підвищує витрати на обладнання [2].

Іншим важливим компонентом є залучення кваліфікованих фахівців. Розробка та впровадження штучного інтелекту вимагає експертизи інженерів з даних, розробників алгоритмів, фахівців із машинного навчання та аналітиків. Найм таких спеціалістів може бути дорогим, особливо враховуючи високий попит на них у сучасному ринку праці. Крім того, компанії нерідко стикаються з

необхідністю проводити додаткове навчання свого персоналу для роботи з новими технологіями, що створює додаткові витрати.

Додаткові фінансові ресурси можуть знадобитися на етапі збору, обробки та очищення даних, які є основою для роботи систем штучного інтелекту. Підготовка якісних даних вимагає значного часу і зусиль, особливо якщо дані розрізнені, застарілі або містять помилки.

Не менш важливим є витрати на тестування і впровадження системи. Компанії повинні витратити час і ресурси на перевірку точності, надійності та безпеки рішень штучного інтелекту, щоб уникнути помилок у роботі, які можуть призвести до фінансових збитків або втрати репутації.

2.4 Проблеми інтеграції штучного інтелекту до існуючих процесів

Проблема інтеграції штучного інтелекту у бізнес-процеси є одним із ключових викликів для компаній, які прагнуть автоматизувати свої операції та підвищити ефективність. Вона охоплює низку технічних, організаційних та людських аспектів, які потребують ретельного аналізу та планування.

Однією з найбільших технічних складностей є забезпечення сумісності між існуючими системами та новими рішеннями штучного інтелекту. Багато компаній використовують застаріле програмне забезпечення або інфраструктуру, яка не підтримує інтеграцію сучасних технологій. Це вимагає додаткових витрат на оновлення систем, розробку інтерфейсів для обміну даними або навіть повну заміну існуючого обладнання. Особливо складним є завдання інтеграції в компаніях з великою кількістю підрозділів і різнорідних процесів, де кожен з них може мати свої унікальні потреби [1].

Організаційні аспекти інтеграції також можуть стати серйозною перешкодою. Впровадження штучного інтелекту зазвичай змінює звичні робочі процеси, що може викликати опір з боку співробітників. Люди часто побоюються втрати роботи через автоматизацію або не довіряють новим технологіям. Це потребує додаткових зусиль з боку керівництва, таких як навчання персоналу,

проведення інформаційних кампаній і залучення співробітників до процесу змін, щоб зменшити їхній опір.

Крім того, інтеграція штучного інтелекту вимагає значної кількості даних, на основі яких працюють алгоритми. Проблемою може стати доступність, якість та організація цих даних. У багатьох компаніях дані зберігаються у різних форматах, базах або відділах, що створює труднощі для їх об'єднання та аналізу. Необхідність очищення, стандартизації та впорядкування даних додає складності до процесу впровадження.

Ще одним важливим аспектом є забезпечення безпеки інтеграційних процесів. Використання штучного інтелекту підвищує ризики витоку конфіденційної інформації, кібератак або несанкціонованого доступу до даних. Це вимагає впровадження додаткових засобів захисту, таких як шифрування даних, багаторівнева аутентифікація та моніторинг активності в системах.

Процес інтеграції часто супроводжується невизначеністю щодо ефективності впроваджуваних технологій. Компанії можуть зіткнутися з необхідністю кількаразової модифікації систем, щоб досягти запланованих результатів. Це збільшує терміни реалізації проекту та створює ризик перевищення бюджету.

2.5 Трансформація бізнес-моделей під впливом штучного інтелекту

Штучний інтелект є потужним інструментом, який активно впливає на трансформацію бізнес-моделей, змінюючи традиційні підходи до створення цінності, управління ресурсами та взаємодії з клієнтами. Його вплив виходить за межі оптимізації окремих процесів, стимулюючи переосмислення основоположних принципів ведення бізнесу.

Штучний інтелект дозволяє компаніям інтегрувати дані як ключовий елемент їхніх бізнес-моделей. Завдяки аналізу великих обсягів інформації підприємства отримують нові знання про поведінку клієнтів, тенденції ринку та ефективність внутрішніх процесів. Це дає змогу приймати більш обґрунтовані стратегічні рішення, які враховують не лише поточні умови, але й прогнозують майбутні зміни.

Наприклад, у ритейлі компанії можуть створювати персоналізовані пропозиції для клієнтів на основі їхніх попередніх покупок і поведінкових даних, що підвищує лояльність та обсяг продажів [4].

У виробничому секторі штучний інтелект трансформує моделі управління ресурсами. Завдяки впровадженню розумних систем автоматизації підприємства можуть зменшувати витрати на матеріали, знижувати відходи та оптимізувати виробничі потоки. Інтелектуальні системи обслуговування обладнання, що прогнозують можливі несправності, мінімізують час простою та підвищують загальну ефективність. Це, своєю чергою, впливає на економічну модель бізнесу, роблячи його більш гнучким та конкурентоспроможним.

Штучний інтелект також сприяє розвитку нових бізнес-моделей, зокрема таких, що базуються на підписці, економіці обміну або платформних рішеннях. Компанії, як-от «Uber» чи «Airbnb», активно використовують алгоритми штучного інтелекту для оптимізації роботи своїх платформ, забезпечення безпеки угод та прогнозування попиту. Це дозволяє їм зменшувати витрати, підвищувати швидкість обслуговування і задовольняти потреби клієнтів із більшою точністю.

Окрім цього, трансформація бізнес-моделей за допомогою штучного інтелекту відкриває нові можливості для монетизації. Наприклад, дані, зібрані та оброблені за допомогою алгоритмів штучного інтелекту, можуть стати цінним активом, який компанії продають чи використовують для створення додаткових послуг. Технології розпізнавання облич або голосу дозволяють розвивати нові напрями в маркетингу, рекламі та фінансових послугах, що стає основою для інноваційних джерел доходу [5].

Втім, такі трансформації також супроводжуються викликами. Компанії повинні перебудувувати свої організаційні структури, інвестувати в навчання персоналу та створення відповідної інфраструктури. Зростання залежності від штучного інтелекту може підвищити ризики, пов'язані з кібератаками або помилками в роботі алгоритмів. Також важливими залишаються етичні питання, пов'язані з використанням даних клієнтів та автоматизацією рішень.

3 МЕТОДОЛОГІЯ ДОСЛІДЖЕННЯ

3.1 Аналіз методів прогнозування

Прогнозування попиту є ключовим елементом управління ланцюгами постачання та стратегічного планування підприємств у різних галузях економіки. Ефективне прогнозування дозволяє мінімізувати ризики, пов'язані з дефіцитом або надлишком продукції, оптимізувати витрати та підвищити задоволеність споживачів. Сучасні підходи до прогнозування попиту ґрунтуються як на класичних статистичних методах, так і на сучасних алгоритмах машинного навчання та штучного інтелекту. Методи прогнозування попиту можна розділити на три основні групи:

- класичні статистичні методи;
- методи машинного навчання;
- гібридні підходи.

До класичних методів прогнозування попиту належать математичні та статистичні моделі, що базуються на аналізі часових рядів та екстраполяції історичних даних:

- а) метод ковзного середнього (Moving Average, MA);

Метод ковзного середнього використовується для згладжування флуктуацій у часовому ряді шляхом усереднення попередніх значень. Він є ефективним для короткострокового прогнозування в умовах стабільного попиту, проте не враховує сезонність та тренди.

- б) експоненційне згладжування (Exponential Smoothing, ES);

На відміну від ковзного середнього, експоненційне згладжування присвоює більшій вазі останнім спостереженням, що дозволяє швидше реагувати на зміни в попиті. Популярною модифікацією цього методу є модель Холта-Вінтерса, яка дозволяє враховувати тренди та сезонність.

- в) моделі ARIMA та SARIMA.

Автоматично регресивна інтегрована модель ковзного середнього (ARIMA) є однією з найпоширеніших моделей часових рядів. Вона

поєднує авторегресію (AR), диференціювання (I) та ковзне середнє (MA). Розширенням ARIMA є сезонна модель SARIMA, яка додає сезонні компоненти, що дозволяє враховувати циклічні коливання попиту.

З появою великих масивів даних та розвитку обчислювальних потужностей класичні методи прогнозування почали поступатися місцем алгоритмам машинного навчання, які демонструють вищу точність прогнозів у складних динамічних умовах. До методів машинного навчання, які будуть якісно прогнозувати попит належать:

а) лінійна та поліноміальна регресія;

Лінійна регресія використовується для моделювання залежності між попитом та одним або кількома факторами (наприклад, ціною, маркетинговими витратами, макроекономічними показниками). Поліноміальна регресія дозволяє враховувати нелінійні взаємозв'язки, проте може бути схильна до перенавчання.

б) Decision Trees, Random Forest, XGBoost;

Дерева рішень та їх ансамблеві моделі (Random Forest, XGBoost) є потужними алгоритмами прогнозування, які дозволяють враховувати велику кількість факторів та їхні взаємозв'язки. Вони особливо ефективні для складних структурованих даних.

в) нейронні мережі та рекурентні нейронні мережі (LSTM, GRU).

Глибокі нейронні мережі, зокрема рекурентні нейронні мережі (LSTM, GRU), використовуються для прогнозування часових рядів, оскільки можуть враховувати довготривалі залежності між попередніми значеннями попиту.

Гібридні моделі поєднують у собі елементи статистичних та машинних методів для підвищення точності прогнозів. Наприклад, ARIMA може бути використана для моделювання трендової складової, а нейромережа – для врахування нелінійних взаємозв'язків. Комбінування різних моделей дозволяє зменшити похибки та підвищити адаптивність алгоритмів до змінних умов ринку.

Для оцінки ефективності прогнозування використовуються різні метрики, зокрема:

- Mean Absolute Error (MAE) – середня абсолютна помилка;
- Root Mean Squared Error (RMSE) – середньоквадратична помилка;
- Mean Absolute Percentage Error (MAPE) – середня абсолютна відносна помилка;
- R^2 (коефіцієнт детермінації) – показник, що характеризує якість моделі.

Методи прогнозування попиту відіграють важливу роль в управлінні бізнес-процесами та плануванні ресурсів. Класичні статистичні моделі забезпечують простоту у використанні та швидкість обчислень, проте мають обмежену точність у динамічних умовах. Методи машинного навчання, зокрема ансамблеві алгоритми та нейромережі, демонструють вищу ефективність у прогнозуванні попиту з урахуванням численних факторів. Гібридні підходи, які поєднують статистичні та штучні методи, є перспективним напрямом досліджень, що дозволяє досягти більшої адаптивності моделей та підвищити точність прогнозів. У подальших дослідженнях доцільно розглянути використання глибоких нейронних мереж у поєднанні з байєсівськими методами оптимізації для створення самонавчальних систем прогнозування.

3.2 Математичне представлення

Для ефективного прогнозування попиту необхідно побудувати математичну модель, яка дозволить враховувати часові тенденції, сезонні коливання, вплив зовнішніх факторів та стохастичні компоненти. Вибір моделі залежить від специфіки досліджуваних даних та особливостей процесів, що формують попит. У даній роботі розглянуто математичну основу прогнозування попиту на основі комбінованого підходу, що включає регресійний аналіз, авторегресійні моделі та методи машинного навчання.

Нехай D_t позначає рівень попиту в момент часу t . Мета прогнозування полягає в побудові функції за формулою 3.1:

$$\widehat{D}_{t+h} = f(D_t, D_{t-1}, \dots, X_t, X_{t-1}, \dots; \theta) \quad (3.1)$$

де \widehat{D}_{t+h} – прогнозоване значення попиту на момент $t + h$, де h - горизонт прогнозування,

$f(\cdot)$ – невідома функція залежності попиту від історичних значень та зовнішніх факторів;

X_t – набір зовнішніх змінних (наприклад, макроекономічні показники, ціни, рекламні витрати, сезонні ефекти);

θ – параметри моделі, які необхідно оцінити.

Залежно від характеру даних, функцію $f(\cdot)$ можна апроксимувати різними підходами, такими як класичні статистичні методи, нейронні мережі або ансамблеві методи машинного навчання.

Одним із найпростіших підходів є використання лінійної регресії за формулою 3.2:

$$\widehat{D}_t = \beta_0 + \beta_1 D_{t-1} + \beta_2 D_{t-2} + \dots + \beta_n D_{t-n} + \sum_{i=1}^m \gamma_i X_i + \varepsilon_t, \quad (3.2)$$

де β_0 – вільний член регресії;

β_i – коефіцієнти авторегресії;

γ_i – коефіцієнти впливу зовнішніх факторів;

ε_t – випадковий шум, що враховує непередбачувані зміни у попиті.

Однак цей метод має обмеження, оскільки не враховує нелінійні взаємозв'язки та складні патерни. Модель ARIMA є однією з найбільш поширених моделей часових рядів. Вона визначається за формулою 3.3:

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right) (1 - L)^d D_t = \left(1 + \sum_{j=1}^q \theta_j L^j\right) \varepsilon_t, \quad (3.3)$$

де L – оператор зсуву назад: $LD_t = D_{t-1}$;

p – порядок авторегресії (AR);

d – порядок диференціювання для стаціонаризації ряду;

q – порядок моделі ковзного середнього (MA);

ϕ_i та θ_j – коефіцієнти моделі.

Якщо у ряді є сезонність, застосовується модель SARIMA, яка доповнює ARIMA сезонними компонентами.

Окрім класичних моделей, прогнозування попиту можна реалізувати через алгоритми машинного навчання. Одним із популярних методів є ансамблеві алгоритми, такі як XGBoost, які використовують бустинг дерев рішень.

Нехай функція прогнозування моделюється як сума послідовно побудованих дерев за формулою 3.4:

$$\hat{D}_t = \sum_{k=1}^K T_k(X_t \theta_k), \quad (3.4)$$

Де $T_k()$ - дерево ухвалення рішень на k -му етапі бустингу. Параметри θ_k оптимізуються через мінімізацію функції втрат за формулою 3.5:

$$L = \sum_{t=1}^T (D_t - \hat{D}_t)^2 + \lambda \sum_{k=1}^K \|\theta_k\|, \quad (3.5)$$

Де перший член - середньоквадратична помилка (MSE), а другий член - штраф для запобігання перенавчанню.

Рекурентні нейронні мережі (RNN), зокрема Long Short-Term Memory (LSTM), використовуються для прогнозування попиту завдяки здатності враховувати довготривалі залежності. Нехай на вхід мережі подається вектор:

$$X_t = (D_{t-1}, D_{t-2}, \dots, X_{t-1}, X_{t-2}, \dots),$$

Вихідний прогноз визначається через параметризовану функцію за формулою 3.6:

$$h_t = \sigma(W_h h_{t-1} + W_x X_t + b_h), \quad (3.6)$$

$$\hat{D}_{t+1} = W_y X_t + b_y,$$

де h_t - прихований стан нейронної мережі;

W_h, W_x, W_y - вагові матриці;

b_h, b_y - зміщення;

$\sigma()$ - функція активації.

LSTM-мережі дозволяють враховувати довготривалу пам'ять, що особливо важливо для складних часових рядів.

Для вибору оптимальної моделі використовуються метрики якості прогнозування:

– середня абсолютна помилка (MAE) за формулою 3.7:

$$MAE = \frac{1}{N} \sum_{i=1}^N |D_i - \hat{D}_i|, \quad (3.7)$$

– середньоквадратична помилка (RMSE) за формулою 3.8:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (D_i - \hat{D}_i)^2}, \quad (3.8)$$

– середня абсолютна відносна помилка (MAPE) за формулою 3.9:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{D_i - \hat{D}_i}{D_i} \right| \times 100\%. \quad (3.9)$$

Математичне моделювання прогнозування попиту включає широкий спектр методів, від класичних статистичних моделей (ARIMA) до сучасних методів машинного навчання (XGBoost, LSTM). Вибір підходу залежить від характеру даних, наявності зовнішніх факторів та необхідного рівня точності. Гібридні моделі, що поєднують статистичні та нейромережеві методи, є перспективним напрямом для підвищення точності прогнозів. Методи машинного навчання, такі як регресійні моделі, дерева ухвалення рішень (XGBoost, Random Forest) та глибокі нейронні мережі (LSTM), демонструють значно кращу точність прогнозування у складних і динамічних умовах. Переваги машинного навчання включають:

- здатність обробляти великі обсяги даних та автоматично знаходити приховані закономірності;
- гнучкість у роботі з різними типами змінних, включаючи макроекономічні показники, ціни, рекламні витрати тощо;
- висока адаптивність до змінних умов ринку завдяки можливості постійного донавчання моделей;
- обробка нелінійних взаємозв'язків, що є важливим для точного прогнозування.

Разом з тим, ці методи мають і недоліки:

- високі обчислювальні витрати: нейромережі та ансамблеві методи вимагають значних ресурсів для навчання;
- необхідність ретельного налаштування гіперпараметрів, що може ускладнити їхню практичну реалізацію;
- часто складна інтерпретація прогнозів, особливо у випадку глибокого навчання (LSTM).

Попри ці обмеження, методи машинного навчання є перспективними для прогнозування попиту, особливо у випадках, коли є велика кількість історичних даних та додаткових факторів, що впливають на динаміку продажів.

4 ІМПЛЕМЕНТАЦІЯ МОДЕЛЕЙ

4.1 Огляд даних

Розробка програми для прогнозування попиту необхідно розпочати з попередньої обробки даних. Необхідно візуалізувати дані для розуміння характеру та природи існуючих показників та представити дані у формі зрозумілої методам машинного навчання.

Наведемо графік розподілення цільового параметру – тижневих продаж (див. рис. 4.1).




Рисунок 4.1 – Розподілення тижневих продаж (рисунок виконано самостійно)

З графіку можна побачити, що більшість значень зосереджено ближче до нуля, але є довгий хвіст праворуч, що свідчить про наявність кількох високих значень. Є кілька локальних піків, що може свідчити про наявність кількох груп у даних або сезонні ефекти. Дані мають асиметричний, багатомодальний розподіл із довгим правим хвостом, що вказує на наявність екстремальних значень або нерівномірний розподіл продажів між різними об'єктами.

Розглянемо розподілення характеристики безробіття та вартості пального (див. рис. 4.2, 4.3).



Рисунок 4.2 – Розподілення безробіття (рисунок виконано самостійно)

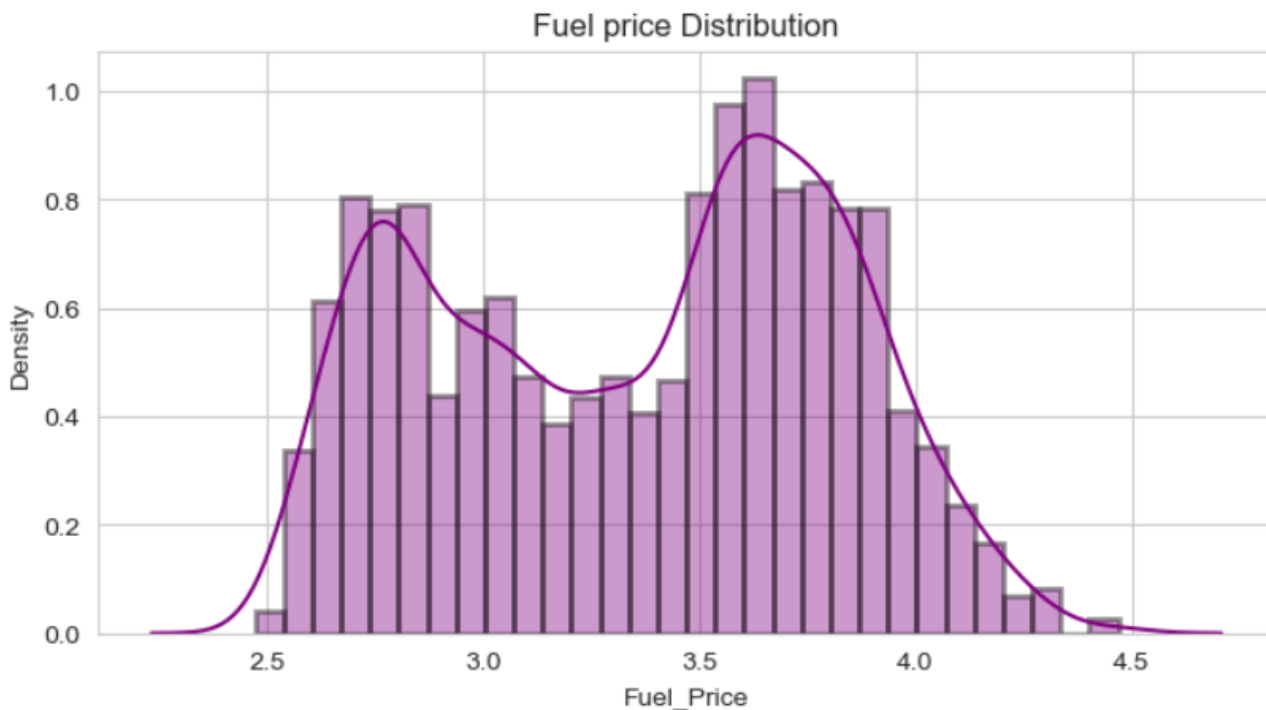


Рисунок 4.3 – Розподілення вартості пального (рисунок виконано самостійно)

З графіку 4.2 можна побачити, що основний пік знаходиться приблизно на рівні 8, що, ймовірно, є середнім або найпоширенішим рівнем безробіття в даних. Є також невеликий локальний пік у діапазоні 13–14, що може свідчити про окрему групу регіонів або часові періоди з вищим безробіттям. Більшість значень зосереджено в діапазоні 6–9, але є довгий "хвіст" праворуч, що вказує на наявність вищих значень безробіття. Розподіл демонструє скупчення значень навколо 8, але також вказує на наявність значної кількості випадків з високими рівнями безробіття.

На графіку 4.3 можна побачити, що дані мають бімодальний розподіл, що може свідчити про різні стани ринку пального. Високий розкид і довгий правий хвіст натякають на те, що ціни могли різко зростати в окремі періоди або регіони. у даних є два основних піки: один приблизно на рівні 2.8, інший – близько 3.6. Це може вказувати на дві окремі групи цін. Більшість значень зосереджено в діапазоні 2.5–4.0, є деякі високі значення, що досягають понад 4.5. Це свідчить про наявність деяких випадків із вищими цінами. Ціни варіюються від приблизно 2.4 до 4.5, що вказує на значні коливання у вартості пального. Між двома основними кластерами (близько 3.0) спостерігається невелике зниження густини, що може свідчити про зміну тенденцій або вплив зовнішніх факторів.

Розглянемо графік розподілення характеристики температура (див. рис. 4.4).

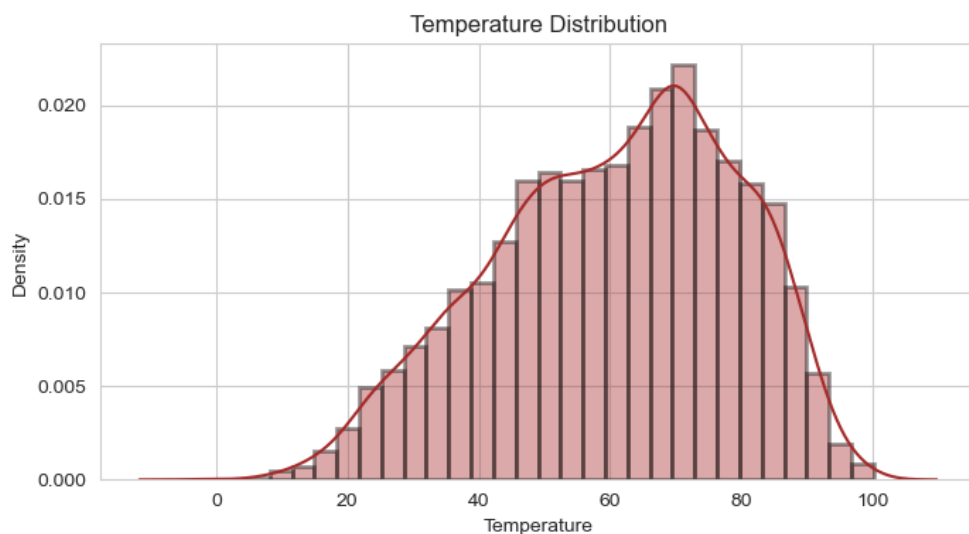


Рисунок 4.4 – Розподілення температури (рисунок виконано самостійно)

Розподіл температури наближений до нормального, що є типовим для природних явищ. Дані мають симетричний вигляд із чітко вираженим центром. Більшість значень зосереджено навколо 60–70, а крайні значення менш поширені. Це свідчить про стабільний температурний діапазон із рідкісними екстремальними випадками. Хоча розподіл здебільшого симетричний, правий хвіст трохи довший, що означає наявність деяких вищих значень температури.

Розглянемо графік розподілення характеристики індекс споживчих цін (див. рис. 4.5).




Рисунок 4.5 – Розподілення індексу споживчих цін (рисунок виконано самостійно)

Дані про індекс споживчих цін мають двогорбий розподіл, що може свідчити про різні періоди інфляції, зміну економічних умов або поділ між різними групами товарів. Прогалина між піками вказує на те, що значення в цьому діапазоні є менш поширеними. Графік має два основні піки: перший пік знаходиться в діапазоні 120–140; другий пік у діапазоні 200–220. Це свідчить про наявність двох окремих груп даних, що може відповідати різним часовим періодам або категоріям товарів/послуг. У проміжку 150–190 спостерігається значний спад щільності, що може означати рідкісні значення CPI у цьому діапазоні.

Розглянемо графік варіативності категоріальних ознак (див. рис. 4.6).

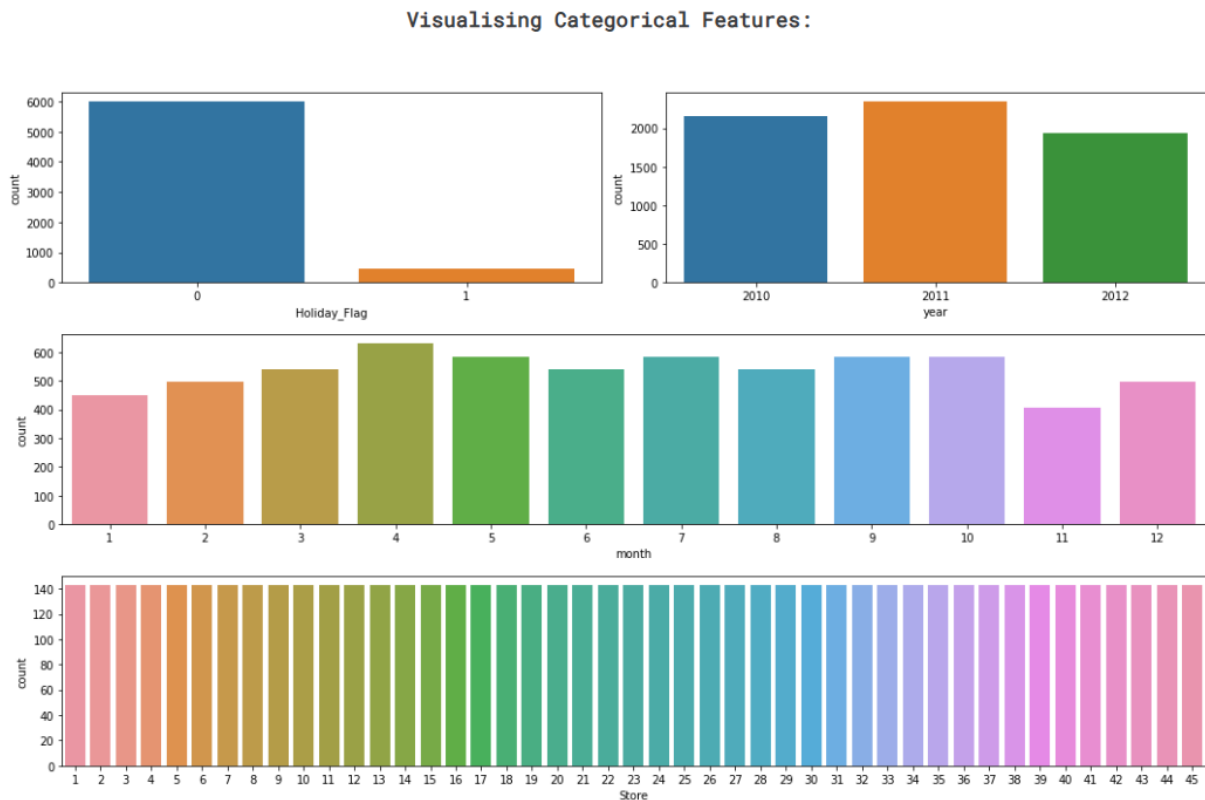


Рисунок 4.6 – Варіативність категоріальних ознак (рисунок виконано самостійно)

З графіку можна побачити, що святкових днів значно менше, ніж звичайних. Найбільше даних зібрано у 2011 році. Записи рівномірно розподілені за магазинами, що свідчить про однакову кількість спостережень для кожного магазину та є певні сезонні коливання.

4.2 Попередня обробка даних

На початку необхідно видалити повторювані рядки, якщо такі існують. Наведемо програмну реалізацію видалення повторюваних рядків:

```
counter = 0
rs,cs = original_df.shape
df.drop_duplicates(inplace=True)
if df.shape==(rs,cs):
    print('\n\033[1mInference:\033[0m The dataset doesn\'t have any
duplicates')
else:
```

```
print(f'\n\033[1mInference:\033[0m Number of duplicates
dropped/fixed ---> {rs-df.shape[0]}')
```

Результатом виконання коду є розуміння, що датасет немає повторювані рядки (див. рис. 4.7).

Inference: The dataset doesn't have any duplicates

Рисунок 4.7 – Результат видалення повторюваних рядків (рисунок виконано самостійно)

Наступним кроком є перевірка рядків на пусті значення, що можуть зашкодити правильному навчанню моделей машинного навчання. Наведемо програмну реалізацію перевірки на пусті значення рядків:

```
nvc = pd.DataFrame(df.isnull().sum().sort_values(), columns=['Total
Null Values'])
nvc['Percentage'] = round(nvc['Total Null Values']/df.shape[0],3)*100
print(nvc)
```

Результатом виконання коду є кількість пустих значень за кожною із змінних. Із результату можна побачити що дані не мають пустих значень (див. рис. 4.8).

	Total Null Values	Percentage
Store	0	0.0
Weekly_Sales	0	0.0
Holiday_Flag	0	0.0
Temperature	0	0.0
Fuel_Price	0	0.0
CPI	0	0.0
Unemployment	0	0.0
weekday	0	0.0
month	0	0.0
year	0	0.0

Рисунок 4.8 – Результат аналізу пустих значень (рисунок виконано самостійно)

Наступним кроком буде перетворення категоріальних стовпців у числові. Наведемо програмну реалізацію перетворення категоріальних стовпців у числові:

```
df3 = df.copy()
ecc = nvc[nvc['Percentage']!=0].index.values
fcc = [i for i in cf if i not in ecc]
#One-Hot Binay Encoding
oh=True
dm=True
for i in fcc:
    if df3[i].nunique()==2:
        if oh==True: print("\033[1mOne-Hot Encoding on
features:\033[0m")
            print(i);oh=False
            df3[i]=pd.get_dummies(df3[i], drop_first=True, prefix=str(i))
        if (df3[i].nunique())>2):
            if dm==True: print("\n\033[1mDummy Encoding on
features:\033[0m")
                print(i);dm=False
                df3 = pd.concat([df3.drop([i], axis=1),
pd.DataFrame(pd.get_dummies(df3[i], drop_first=True,
prefix=str(i)))],axis=1)
df3.shape
```

Наступним кроком буде видалення екстремальних викидів даних. Наведемо програмну реалізацію видалення екстремальних викидів даних:

```
df1 = df3.copy()
features1 = nf
for i in features1:
    Q1 = df1[i].quantile(0.25)
    Q3 = df1[i].quantile(0.75)
    IQR = Q3 - Q1
    df1 = df1[df1[i] <= (Q3+(1.5*IQR))]
    df1 = df1[df1[i] >= (Q1-(1.5*IQR))]
    df1 = df1.reset_index(drop=True)
display(df1.head())
print('\n\033[1mInference:\033[0m\nBefore removal of outliers, The
dataset had {} samples.'.format(df3.shape[0]))
print('After removal of outliers, The dataset now has {}
samples.'.format(df1.shape[0]))
```

Після виконання коду можна побачити кількість видалених екстремальних викидів (див. рис. 4.9).

Inference:

Before removal of outliers, The dataset had 6435 samples.

After removal of outliers, The dataset now has 5953 samples.

Рисунок 4.9 – Результат видалення екстремальних викидів даних (рисунок виконано самостійно)

Після всіх перетворень даних необхідно перевірити скільки даних було видалено від основного об'єму даних. Наведемо програмний код, який візуалізує фінальний набір даних:

```
df = df1.copy()
df.columns=[i.replace('-', '_') for i in df.columns]

plt.title('Final Dataset')
plt.pie([df.shape[0], original_df.shape[0]-df.shape[0]], radius = 1,
labels=['Retained', 'Dropped'], counterclock=False,
autopct='%1.1f%%', pctdistance=0.9, explode=[0,0],
shadow=True)
plt.pie([df.shape[0]], labels=['100%'], labeldistance=-0,
radius=0.78)
plt.show()

print(f'\n\033[1mInference:\033[0m After the cleanup process,
{original_df.shape[0]-df.shape[0]} samples were dropped, \
while retaining {round(100 -
(df.shape[0]*100/(original_df.shape[0])),2)}% of the data.')
```

Результатом виконання програмного коду є графік, який візуалізує фінальний набір даних (див. рис. 4.10).

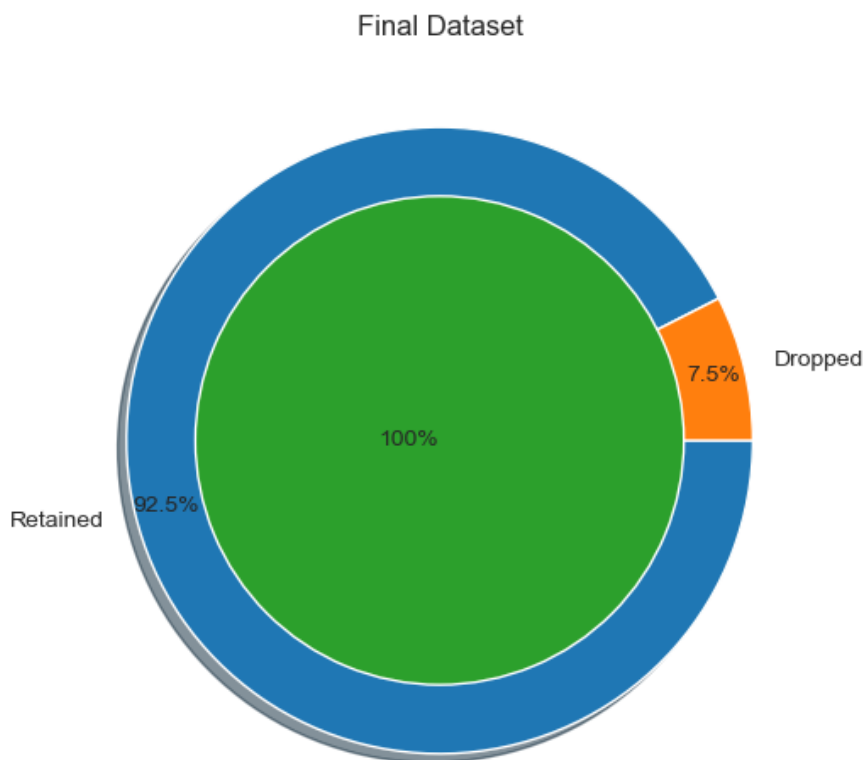


Рисунок 4.10 – Візуалізація фінального набору даних (рисунок виконано самостійно)

З графіку можна побачити, що Основна частина даних (92.5%) була збережена. Лише 7.5% даних були видалені, що може свідчити про невелику частку викидів або некоректних значень у початковому наборі даних.

Наступним кроком буде розбиття даних на навчальні та тестові набори для подальшого навчання моделей машинного навчання та перевірки навчання. Наведемо програмний код для розділення даних:

```
m=[]  
for i in df.columns.values:  
    m.append(i.replace(' ','_'))  
df.columns = m  
X = df.drop([target],axis=1)  
Y = df[target]  
Train_X, Test_X, Train_Y, Test_Y = train_test_split(X, Y,  
train_size=0.8, test_size=0.2, random_state=100)
```

```

Train_X.reset_index(drop=True,inplace=True)
print('Original set ---> ',X.shape,Y.shape,'\nTraining set --->
',Train_X.shape,Train_Y.shape,'\nTesting set ---> ',
Test_X.shape,' ', Test_Y.shape)

```

Після виконання коду отримаємо два набори даних. Тренувальний набір включає 80 відсотків від оригінального набору даних, тестувальний – 20 відсотків.

Наступним кроком буде нормалізація обох наборів даних. Наведемо програмний код, який виконує нормалізацію даних:

```

std = StandardScaler()

print('\033[1mStandardization on Training set'.center(120))
Train_X_std = std.fit_transform(Train_X)
Train_X_std = pd.DataFrame(Train_X_std, columns=X.columns)
display(Train_X_std.describe())

print('\n','\033[1mStandardization on Testing set'.center(120))
Test_X_std = std.transform(Test_X)
Test_X_std = pd.DataFrame(Test_X_std, columns=X.columns)
display(Test_X_std.describe())

```

Наведений код стандартизує дані, щоб вони мали нульове середнє та одиничне стандартне відхилення. `fit_transform()` використовується для навчального набору, а `transform()` – для тестового, щоб уникнути витоків даних.

Створимо функцію для оцінки подальших експериментів із моделями машинного навчання. Функції необхідно порівнювати результати збігання навчального та тестового наборів даних а також надавати інформацію щодо параметрів помилок RSS, MSE та RMSE. Наведемо програмний код, який реалізує оцінку методів машинного навчання:

```

Model_Evaluation_Comparison_Matrix = pd.DataFrame(np.zeros([5,8]),
columns=['Train-R2', 'Test-R2', 'Train-RSS', 'Test-RSS',
'Train-MSE', 'Test-MSE', 'Train-RMSE', 'Test-RMSE'])

```

```

rc=np.random.choice(Train_X_std.loc[:,Train_X_std.nunique()>=50].columns.values,2,replace=False)
def Evaluate(n, pred1,pred2):
    plt.figure(figsize=[15,6])
    for e,i in enumerate(rc):
        plt.subplot(2,3,e+1)
        plt.scatter(y=Train_Y, x=Train_X_std[i], label='Actual')
        plt.scatter(y=pred1, x=Train_X_std[i], label='Prediction')
        plt.legend()
    plt.show()
    print('\n\n{}Training Set Metrics{}'.format('-'*20, '-'*20))
    print('\nR2-Score on Training set --->',round(r2_score(Train_Y,
pred1),20))
    print('Residual Sum of Squares (RSS) on Training set ---
>',round(np.sum(np.square(Train_Y-pred1)),20))
    print('Mean Squared Error (MSE) on Training set ---
>',round(mean_squared_error(Train_Y, pred1),20))
    print('Root Mean Squared Error (RMSE) on Training set ---
>',round(np.sqrt(mean_squared_error(Train_Y, pred1)),20))
    print('\n\n{}Testing Set Metrics{}'.format('-'*20, '-'*20))
    print('\nR2-Score on Testing set --->',round(r2_score(Test_Y,
pred2),20))
    print('Residual Sum of Squares (RSS) on Training set ---
>',round(np.sum(np.square(Test_Y-pred2)),20))
    print('Mean Squared Error (MSE) on Training set ---
>',round(mean_squared_error(Test_Y, pred2),20))
    print('Root Mean Squared Error (RMSE) on Training set ---
>',round(np.sqrt(mean_squared_error(Test_Y, pred2)),20))
    print('\n\n{}Residual Plots{}'.format('-'*20, '-'*20))
    Model_Evaluation_Comparison_Matrix.loc[n,'Train-R2'] =
round(r2_score(Train_Y, pred1),20)
    Model_Evaluation_Comparison_Matrix.loc[n,'Test-R2'] =
round(r2_score(Test_Y, pred2),20)
    Model_Evaluation_Comparison_Matrix.loc[n,'Train-RSS'] =
round(np.sum(np.square(Train_Y-pred1)),20)
    Model_Evaluation_Comparison_Matrix.loc[n,'Test-RSS'] =
round(np.sum(np.square(Test_Y-pred2)),20)
    Model_Evaluation_Comparison_Matrix.loc[n,'Train-MSE'] =
round(mean_squared_error(Train_Y, pred1),20)

```

```
Model_Evaluation_Comparison_Matrix.loc[n,'Test-MSE'] =
round(mean_squared_error(Test_Y, pred2),20)
plt.figure(figsize=[15,4])
plt.subplot(1,2,1)
sns.distplot((Train_Y - pred1))
plt.title('Error Terms')
plt.xlabel('Errors')
plt.subplot(1,2,2)
plt.scatter(Train_Y,pred1)
plt.plot([Train_Y.min(),Train_Y.max()], [Train_Y.min(),Train_Y.max()],
'r--')
plt.title('Test vs Prediction')
plt.xlabel('y_test')
plt.ylabel('y_pred')
plt.show()
```

5 ПРОВЕДЕННЯ ЕКСПЕРИМЕНТУ

5.1 Використання множинної лінійної регресії

Для реалізації множинної лінійної регресії використаємо бібліотеку sklearn. Наведемо програмний код реалізації лінійної регресії:

```
MLR = LinearRegression().fit(Train_X_std,Train_Y)
pred1 = MLR.predict(Train_X_std)
pred2 = MLR.predict(Test_X_std)

print('{}{}\033[1m Evaluating Multiple Linear Regression Model
\033[0m{}\n'.format('<'*3,'-'*35 , '-'*35, '>'*3))
print('The Intercept of the Regression Model was found to be
',MLR.intercept_)


Evaluate(0, pred1, pred2)
```

Даний код реалізує побудову та оцінку моделі множинної лінійної регресії. Спочатку створюється об'єкт моделі LinearRegression із бібліотеки sklearn.linear_model, який одразу навчається на тренувальному наборі даних Train_X_std і відповідних значеннях цільової змінної Train_Y за допомогою методу .fit(). Після навчання модель здійснює передбачення: спочатку на тренувальному наборі (зберігається у змінній pred1), а потім на тестовому (pred2). Далі виводиться оформлений заголовок процесу оцінювання моделі та значення перехоплення (intercept) моделі, що відповідає значенню цільової змінної, коли всі ознаки дорівнюють нулю. Функція Evaluate проводить детальний аналіз роботи моделі, зокрема обчислити метрики якості прогнозу (наприклад, R², MSE, RMSE) та побудувати графіки для візуального аналізу точності передбачень.

Після виконання коду отримаємо результат множинної лінійної регресії у вигляді порівняння виконання на тренувальному та тестовому наборі даних (див. рис. 5.1).

<<<----- Evaluating Multiple Linear Regression Model ----->>>
 ----->>>

The Intercept of the Regression Model was found to be 1047603.298112138



-----Training Set Metrics-----

R2-Score on Training set ---> 0.9276826744775732
 Residual Sum of Squares (RSS) on Training set ---> 111450847994430.22
 Mean Squared Error (MSE) on Training set ---> 23404209994.630455
 Root Mean Squared Error (RMSE) on Training set ---> 152984.3455868294

-----Testing Set Metrics-----

R2-Score on Testing set ---> 0.927676279121959
 Residual Sum of Squares (RSS) on Training set ---> 29463185193746.86
 Mean Squared Error (MSE) on Training set ---> 24738190758.813484
 Root Mean Squared Error (RMSE) on Training set ---> 157283.79051514965

-----Residual Plots-----




Рисунок 5.1 – Результат множинної лінійної регресії (рисунок виконано самостійно)

З рисунку можна побачити, що модель добре узгоджується з даними, оскільки R^2 92.76% і для навчального, і для тестового набору. Значення MSE та

RMSE помірні, що означає відносно невеликі помилки прогнозування. Відсутні значні ознаки перенавчання, оскільки метрики навчального та тестового набору близькі. Аналіз помилок свідчить про адекватний розподіл залишків, що підтверджує правильність використання моделі.

5.2 Використання моделі хребтової регресії

Використаємо модель хребтової регресії для порівняння результату із методом множинної лінійної регресії. Наведемо програмну реалізацію хребтової регресії:

```
RLR = Ridge().fit(Train_X_std,Train_Y)
pred1 = RLR.predict(Train_X_std)
pred2 = RLR.predict(Test_X_std)

print('{}{}\033[1m Evaluating Ridge Regression Model
\033[0m{}\n'.format('< '*3, '- '*35, '- '*35, '> '*3))
print('The Intercept of the Regression Model was found to be
',MLR.intercept_)


Evaluate(1, pred1, pred2)
```

Цей код виконує побудову та оцінку моделі хребтової регресії (Ridge Regression), яка є варіацією лінійної регресії з L2-регуляризацією. Спочатку створюється об'єкт моделі Ridge() з бібліотеки sklearn.linear_model, який одразу навчається на стандартизованих тренувальних ознаках Train_X_std та відповідних цільових значеннях Train_Y за допомогою методу .fit(). Після цього модель здійснює прогнозування для тренувального набору, результат зберігається у змінній pred1, і для тестового набору — у змінній pred2. Далі виводиться стилізований заголовок, який повідомляє, що зараз відбувається оцінка моделі хребтової регресії.

Після виконання коду отримаємо результат хребтової регресії у зазначеному форматі (див. рис. 5.2).

<<----- Evaluating Ridge Regression Model ----->>>

The Intercept of the Regression Model was found to be 1047603.298112138



-----Training Set Metrics-----

R2-Score on Training set ---> 0.9276821973327432
 Residual Sum of Squares (RSS) on Training set ---> 111451583339598.72
 Mean Squared Error (MSE) on Training set ---> 23404364414.027447
 Root Mean Squared Error (RMSE) on Training set ---> 152984.8502761873

-----Testing Set Metrics-----

R2-Score on Testing set ---> 0.927696636618113
 Residual Sum of Squares (RSS) on Training set ---> 29454891971661.734
 Mean Squared Error (MSE) on Training set ---> 24731227516.08878
 Root Mean Squared Error (RMSE) on Training set ---> 157261.65303750554

-----Residual Plots-----




Рисунок 5.2 – Результат хребтової регресії (рисунок виконано самостійно)

З рисунку можна побачити, що хребтова регресія показує аналогічні результати до множинної лінійної регресії, але може бути більш стабільною при високій колінеарності даних. Відсутні ознаки перенавчання: значення R^2 , RMSE та

MSE на тестовому та навчальному наборах майже однакові. Розподіл залишків є нормальним, що підтверджує адекватність використання цієї регресійної моделі.

5.3 Використання регресійної моделі ласо

Використаємо модель регресійної моделі ласо для порівняння з іншими моделями машинного навчання. Наведемо програмну реалізацію регресійної моделі ласо:

```
LLR = Lasso().fit(Train_X_std,Train_Y)
pred1 = LLR.predict(Train_X_std)
pred2 = LLR.predict(Test_X_std)

print('{}{}\033[1m Evaluating Lasso Regression Model
\033[0m{}\n'.format('<'*3,'-'*35 , '-'*35, '>'*3))
print('The Intercept of the Regression Model was found to be
',MLR.intercept_)


Evaluate(2, pred1, pred2)
```

Цей код виконує побудову та початкову оцінку моделі ласо-регресії (Lasso Regression), яка є різновидом лінійної регресії з L1-регуляризацією. Створюється модель Lasso() з бібліотеки sklearn.linear_model, яка одразу навчається на стандартизованих ознаках тренувального набору Train_X_std і цільових значеннях Train_Y за допомогою методу .fit(). Після навчання модель використовується для прогнозування значень на тих самих тренувальних даних, результат зберігається у змінній pred1, а також здійснюється прогноз на тестовому наборі — результат у змінній pred2. Далі виводиться красиво оформлений заголовок, який повідомляє, що відбувається оцінювання моделі ласо-регресії.

Після виконання коду отримаємо результат регресійної моделі ласо (див. рис. 5.3).

```
<<<----- Evaluating Lasso Regression Model ----->>>
```

```
The Intercept of the Regression Model was found to be 1047603.298112138
```



```
-----Training Set Metrics-----
```

```
R2-Score on Training set ---> 0.9276826740433101
Residual Sum of Squares (RSS) on Training set ---> 111450848663688.89
Mean Squared Error (MSE) on Training set ---> 23404210135.171963
Root Mean Squared Error (RMSE) on Training set ---> 152984.3460461624
```

```
-----Testing Set Metrics-----
```

```
R2-Score on Testing set ---> 0.9276767498337136
Residual Sum of Squares (RSS) on Training set ---> 29462993435532.15
Mean Squared Error (MSE) on Training set ---> 24738029752.75579
Root Mean Squared Error (RMSE) on Training set ---> 157283.27868135186
```

```
-----Residual Plots-----
```




Рисунок 5.3 – Результат виконання регресійної моделі ласо (рисунок виконано самостійно)

З рисунку можна побачити, що модель регресійної моделі ласо показує результати, які дуже схожі на модель хребтової регресії. Ласо-регресія може робити нульові значення для деяких коефіцієнтів, що може бути корисним для зменшення складності моделі, особливо якщо деякі предиктори є неінформативними. Значення R^2 на тренувальному та тестовому наборах майже однакові. Розподіл залишків відповідає нормальному, а прогнозовані значення добре узгоджуються з реальними, що підтверджує ефективність моделі.

5.4 Використання еластичної мережевої регресії

Використаємо модель еластичної мережевої регресії для порівняння з іншими моделями машинного навчання. Наведемо програмну реалізацію еластичної мережевої регресії:

```
ENR = ElasticNet().fit(Train_X_std,Train_Y)
pred1 = ENR.predict(Train_X_std)
pred2 = ENR.predict(Test_X_std)

print('{}{}\033[1m Evaluating Elastic-Net Regression Model
\033[0m{}\n'.format('<'*3, '-'*35, '-'*35, '>'*3))
print('The Intercept of the Regression Model was found to be
',MLR.intercept_)

Evaluate(3, pred1, pred2)
```

Цей код виконує побудову та первинну оцінку моделі еластичної мережевої регресії (Elastic-Net Regression), яка поєднує властивості L1- та L2-регуляризацій, тобто поєднує підходи ласо і хребтової регресії. Спочатку створюється модель ElasticNet() з бібліотеки sklearn.linear_model, яка навчається на стандартизованому тренувальному наборі ознак Train_X_std та відповідних значеннях цільової змінної Train_Y за допомогою методу .fit(). Далі за допомогою методу .predict() виконуються передбачення на тренувальному наборі (pred1) і на тестовому (pred2).

Після цього виводиться стилізований заголовок, який повідомляє, що відбувається оцінювання моделі Elastic-Net.

Після виконання коду отримаємо результат еластичної мережевої регресії (див. рис. 5.4).

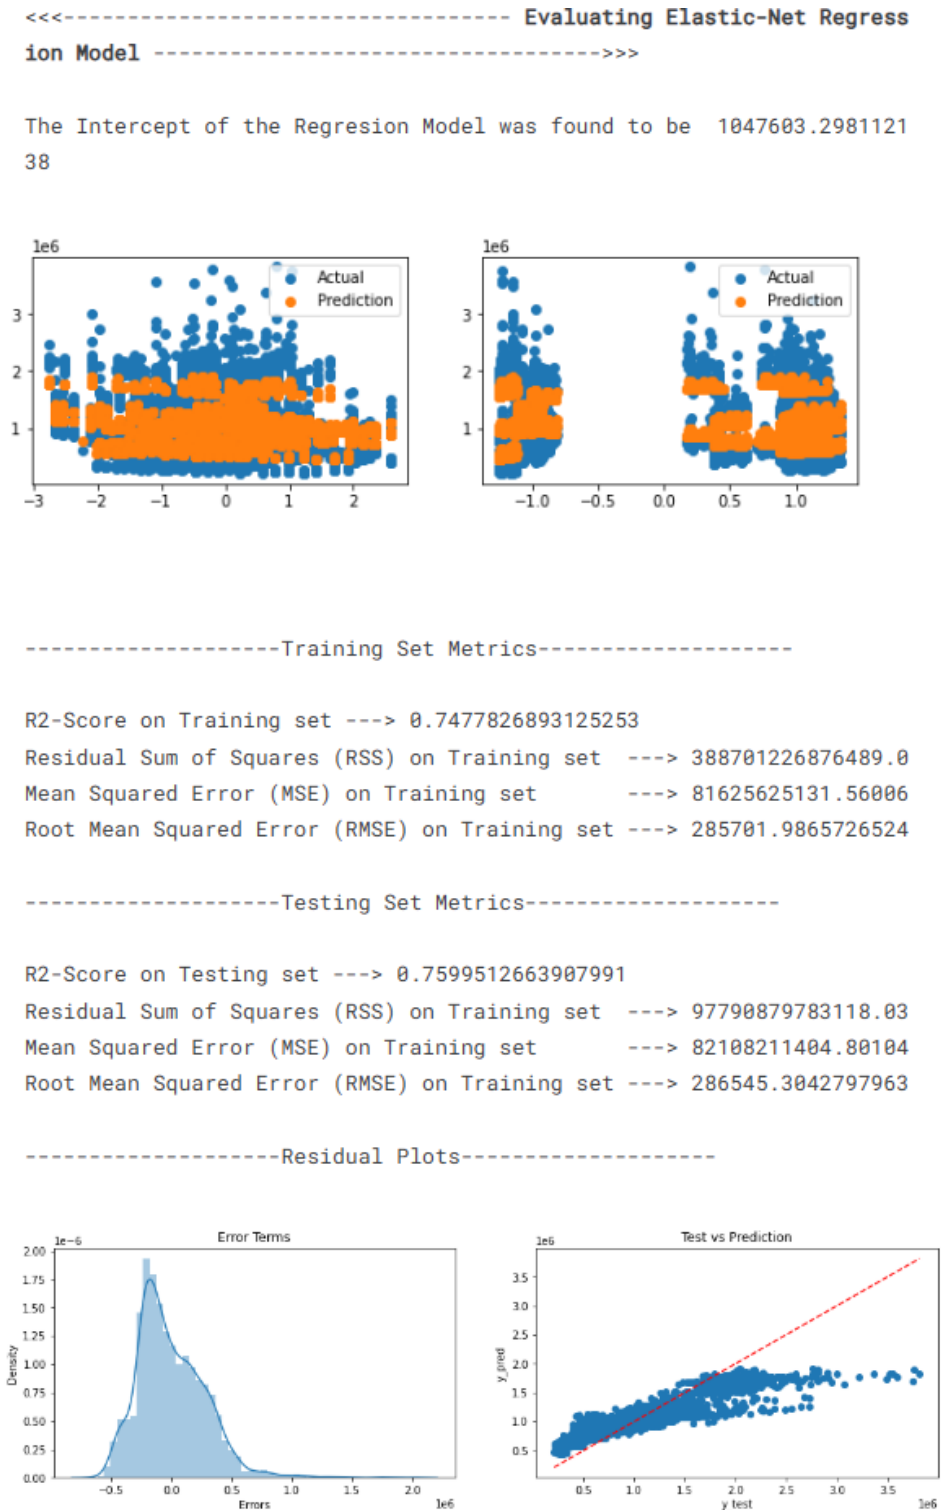


Рисунок 5.4 – Результат еластичної мережевої регресії (рисунок виконано самостійно)

З рисунку можна побачити, що модель працює добре, пояснюючи понад 75% варіації даних. RMSE вказує на доволі точний прогноз (~286 тисяч). Графіки залишків показують адекватний розподіл помилок, хоч є можливі викиди. Модель може мати труднощі з передбаченням дуже високих значень.

5.5 Використання моделі поліноміальної регресії

Використаєм модель поліноміальної регресії для порівняння з іншими моделями машинного навчання. Для початку необхідно перевірити ефективність поліноміальної регресії на різних ступенях. Наведемо програмну реалізацію перевірки ефективності поліноміальної регресії:

```
Trr=[]; Tss=[]
n_degree=4

for i in range(2,n_degree):
    poly_reg = PolynomialFeatures(degree=i)
    X_poly = poly_reg.fit_transform(Train_X_std)
    X_poly1 = poly_reg.fit_transform(Test_X_std)
    LR = LinearRegression()
    LR.fit(X_poly, Train_Y)

    pred1 = LR.predict(X_poly)
    Trr.append(np.sqrt(mean_squared_error(Train_Y, pred1)))

    pred2 = LR.predict(X_poly1)
    Tss.append(np.sqrt(mean_squared_error(Test_Y, pred2)))

plt.figure(figsize=[15,6])
plt.subplot(1,2,1)
plt.plot(range(2,n_degree),Trr, label='Training')
plt.plot(range(2,n_degree),Tss, label='Testing')
#plt.plot([1,4],[1,4], 'b--')
plt.title('Polynomial Regression Fit')
plt.xlabel('Degree')
plt.ylabel('RMSE')
```

```

plt.grid()
plt.legend()

plt.subplot(1,2,2)
plt.plot(range(2,n_degree),Trr, label='Training')
plt.plot(range(2,n_degree),Tss, label='Testing')
plt.title('Polynomial Regression Fit')
plt.ylim([0,2e16])
plt.xlabel('Degree')
plt.ylabel('RMSE')
plt.grid()
plt.legend()
plt.show()

```

Після виконання коду отримуємо результат перевірки ефективності поліноміальної регресії на різних ступенях (див. рис. 5.5).

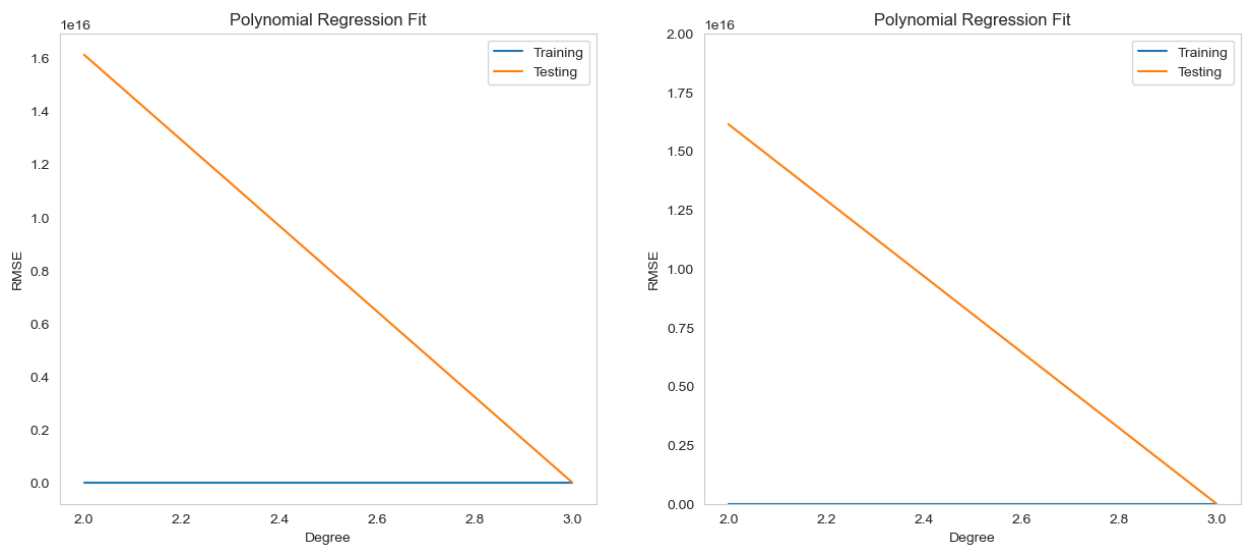


Рисунок 5.5 – Результат перевірки поліноміальної регресії (рисунок виконано самостійно)

З рисунку можна зробити висновок, що поліноміальна регресія 2-го порядку дає більш оптимальні результати навчання та тестування. Тому подальший експеримент буде проводитись на поліноміальну регресію 2-го порядку. Наведемо програмну реалізацію поліноміальної регресії 2-го порядку:

```

poly_reg = PolynomialFeatures(degree=2)
X_poly = poly_reg.fit_transform(Train_X_std)
X_poly1 = poly_reg.fit_transform(Test_X_std)
PR = LinearRegression()
PR.fit(X_poly, Train_Y)

pred1 = PR.predict(X_poly)
pred2 = PR.predict(X_poly1)

print('{}{}\033[1m Evaluating Polynomial Regression Model
\033[0m{}\n'.format('<'*3, '-'*35, '-'*35, '>'*3))
print('The Coefficient of the Regression Model was found to be
',MLR.coef_)
print('The Intercept of the Regression Model was found to be
',MLR.intercept_)

Evaluate(4, pred1, pred2)

```

Цей код реалізує побудову поліноміальної регресії другого ступеня на основі стандартизованих ознак. Спочатку створюється об'єкт `PolynomialFeatures` з параметром `degree=2`, який дозволяє розширити вхідні ознаки до поліноміального простору, включаючи квадратичні та взаємодіючі терміни. Методом `fit_transform()` перетворюються ознаки тренувального набору `Train_X_std` у нову матрицю `X_poly`, а аналогічне перетворення тестових даних зберігається у `X_poly1`. Потім створюється модель звичайної лінійної регресії `LinearRegression()`, яка навчається на поліноміально розширених тренувальних ознаках і відповідних значеннях цільової змінної `Train_Y`. Після навчання модель здійснює прогнозування як на тренувальному наборі (`pred1`), так і на тестовому (`pred2`). Далі виводиться стилізований заголовок про оцінювання поліноміальної регресії.

Після виконання коду отримаємо результат поліноміальної регресії 2-го порядку (див. рис. 5.6).

<<<----- Evaluating Polynomial Regression Model ----->>>
 ----->>>


The Coefficient of the Regression Model was found to be [382416.72707697 -87749.08819447 -3
 3466.21811552 -70608.43596712

```

23371.88280837  44272.12738693  67885.30758384 -171730.97447116
194110.33061399 -182942.03065485 -95260.47050719 -110787.17299967
-154257.07523525  200572.26744363 -27802.83358985  36027.35653929
202356.39957846  137960.5727378 -126652.1156391  29819.45548371
75864.89398192  119328.98106792  104372.22301835 -108321.57336704
54083.53671998  65645.06638736  110781.93941655 -114111.68634244
52174.80531825  169276.22877422  47325.81863416 -164944.63849199
-45218.40228284  78308.2717848  42369.70043942 -163871.15661923
-143446.53544316 -94113.42272716 -57253.08807135 -49965.33157002 ]

```

The Intercept of the Regression Model was found to be 1047603.298112138



-----Training Set Metrics-----

R2-Score on Training set ---> 0.940476691273314
 Residual Sum of Squares (RSS) on Training set ---> 91733525612284.02
 Mean Squared Error (MSE) on Training set ---> 19263655105.477535
 Root Mean Squared Error (RMSE) on Training set ---> 138793.57011575694

-----Testing Set Metrics-----

R2-Score on Testing set ---> -3.880366289092445e+20
 Residual Sum of Squares (RSS) on Training set ---> 1.5807808172355157e+35
 Mean Squared Error (MSE) on Training set ---> 1.3272718868476202e+32
 Root Mean Squared Error (RMSE) on Training set ---> 1.1520728652509876e+16

-----Residual Plots-----




Рисунок 5.6 – Результат поліноміальної регресії 2-го порядку (рисунок виконано самостійно)

З рисунку можна побачити, що на навчальному наборі модель показує високу точність, але на тестовому наборі даних можна побачити перенавчання.

5.6 Порівняння методів оцінювання моделей

Для оцінки проведеного експерименту необхідно порівняти метрики виконання моделей машинного навчання. Ці метрики дозволять обрати оптимальну модель, що буде підходити для прогнозування попиту. Наведемо програмну реалізацію для порівняння моделей машинного навчання:

```
EMC = Model_Evaluation_Comparison_Matrix.copy()
EMC.index = ['Multiple Linear Regression (MLR)', 'Ridge Linear
Regression (RLR)', 'Lasso Linear Regression (LLR)', 'Elastic-Net
Regression (ENR)', 'Polynomial Regression (PNR)']
EMC
```

Після виконання програмного коду, отримаємо таблицю порівняння різних метрик при використанні описаних моделей машинного навчання (див. рис. 5.7).

	Train-R2	Test-R2	Train-RSS	Test-RSS	Train-MSE	Test-MSE
Multiple Linear Regression (MLR)	0.927683	9.276763e-01	1.114508e+14	2.946319e+13	2.340421e+10	2.473819e+10
Ridge Linear Regression (RLR)	0.927682	9.276966e-01	1.114516e+14	2.945489e+13	2.340436e+10	2.473123e+10
Lasso Linear Regression (LLR)	0.927683	9.276767e-01	1.114508e+14	2.946299e+13	2.340421e+10	2.473803e+10
Elastic-Net Regression (ENR)	0.747783	7.599513e-01	3.887012e+14	9.779088e+13	8.162563e+10	8.210821e+10
Polynomial Regression (PNR)	0.940477	-3.880366e+20	9.173353e+13	1.580781e+35	1.926366e+10	1.327272e+32

Рисунок 5.7 – Результат порівняння метрик моделей (рисунок виконано самостійно)

З рисунку можна побачити, що множинна лінійна регресія є базовою моделлю із доброю узгодженістю та точністю. Хребтова лінійна регресія – Ідентична до множинної регресії, але стійкіша до мультиколінеарності (завдяки L2-

регуляризації). Лінійна регресія ласо також подібна до множинної регресії, додатково виконуючи вибір ознак (L1-регуляризація). Модель еластичної мережевої регресії має середній результат, ця модель може бути корисна при великій кількості ознак. Поліноміальна регресія 2-го порядку дуже сильне перенавчання та не може використовуватись в поточному вигляді. Наступною перевіркою буде порівняння оцінки R2 для різних регресійних моделей. Наведемо програмну реалізацію порівняння:

```
R2 = round(EMC['Train-R2'].sort_values(ascending=True), 4)
plt.hlines(y=R2.index, xmin=0, xmax=R2.values)
plt.plot(R2.values, R2.index, 'o')
plt.title('R2-Scores Comparison for various Regression Models')
plt.xlabel('R2-Score')
for i, v in enumerate(R2):
    plt.text(v+0.02, i-0.05, str(v*100), color='blue')
plt.xlim([0, 1.1])
plt.show()
```

Після виконання програмного коду отримаємо графік порівняння помилки R2 для використаних моделей (див. рис. 5.8).

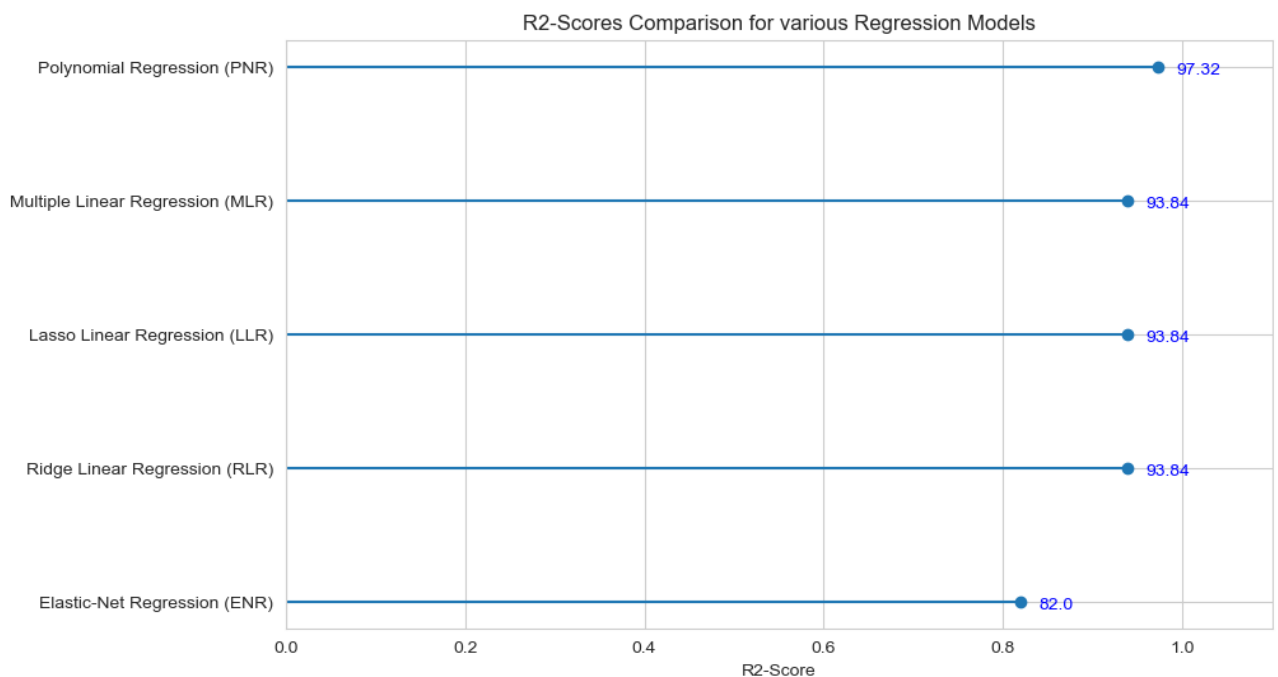


Рисунок 5.8 – Графік порівняння помилки R2 (рисунок виконано самостійно)

З графіку можна побачити, що поліноміальна регресія має найвищий R^2 (97.32%) — це свідчить про ідеальну точність на тренувальному наборі, але, як видно з попередніх таблиць — сильно перенавчена. Множинна, хребтова та модель ласо мають однаковий $R^2 = 93.84\%$ — це добрий результат, а також стабільні й узагальнюванні моделі.

Наступним кроком буде порівняння середньоквадратичної помилки для різних регресійних моделей. Наведемо програмну реалізацію порівняння середньоквадратичної помилки:

```
cc = Model_Evaluation_Comparison_Matrix.columns.values
s=5
plt.bar(np.arange(5),
Model_Evaluation_Comparison_Matrix[cc[6]].values, width=0.3,
label='RMSE (Training)')
plt.bar(np.arange(5)+0.3,
Model_Evaluation_Comparison_Matrix[cc[7]].values, width=0.3,
label='RMSE (Testing)')
plt.xticks(np.arange(5),EMC.index, rotation =35)
plt.legend()
plt.ylim([0,500000])
plt.show()
```

Цей код створює стовпчикову діаграму, яка візуально порівнює значення середньоквадратичної помилки (RMSE) для тренувального та тестового наборів даних серед п'яти моделей регресії. Зі змінної `Model_Evaluation_Comparison_Matrix` беруться назви стовпців, і вважається, що під індексами `cc[6]` і `cc[7]` знаходяться відповідно значення RMSE для тренування та тестування. Далі побудовано дві групи стовпчиків: перша — для тренувальної RMSE, друга — для тестової, з невеликим зсувом по осі x (на 0.3), щоб вони не накладалися.

Після виконання коду отримаємо графік, який демонструє середньоквадратичну помилку для тренувального та тестового наборів для кожної використаної моделі (див. рис. 5.9).




Рисунок 5.9 – Графік середньоквадратичної помилки (рисунок виконано самостійно)

З графіку можна побачити, що множинна, хребтова та модель ласо мають найнижчу та збалансовану середньоквадратичну помилку, тобто моделі навчаються і добре працюють на нових даних. Поліноміальна регресія має перенавчання, тому що дуже мала помилка на тренуванні, що означає – модель надто складна. Дуже велика помилка на тестовому наборі даних означає, що модель не узагальнює дані.

Таким чином, після аналізу всіх представлених графіків і метрик було прийнято рішення використовувати саме множинну лінійну регресію (MLR), оскільки вона демонструє найкращий баланс між точністю на тренувальних даних та здатністю узагальнювати на нові, тестові дані. Модель показує високе значення коефіцієнта детермінації ($R^2 \approx 0.927$) на обох наборах, що свідчить про її ефективність у поясненні варіації залежної змінної. Також вона має низькі значення середньоквадратичної помилки, і що найважливіше — різниця між помилками на тренувальному та тестовому наборах мінімальна, що вказує на відсутність перенавчання.

ВИСНОВКИ

У ході виконання кваліфікаційної роботи було досліджено важливу та актуальну проблему — прогнозування попиту в продуктовому бізнесі. У сучасних умовах ринкової конкуренції точне передбачення попиту є критично важливим для забезпечення ефективного управління ланцюгом постачання, мінімізації витрат, уникнення надлишкових запасів або нестачі товару, а також для прийняття обґрунтованих рішень щодо планування закупівель, логістики та виробництва. Неправильна оцінка попиту може призвести до серйозних фінансових втрат, втрати клієнтів і зниження рівня сервісу. Саме тому дана проблема має як економічне, так і практичне значення для діяльності підприємств, що працюють у сфері роздрібно́ї торгівлі.

У теоретичній частині роботи було проаналізовано різні методи прогнозування попиту, зокрема класичні статистичні моделі та сучасні підходи машинного навчання. Розглянуто їх математичні основи, сильні та слабкі сторони в контексті бізнес-задач, а також приділено увагу тому, які саме моделі доцільно застосовувати в умовах високої мінливості ринку, сезонності та наявності великої кількості факторів, що впливають на попит. Особливу увагу було приділено регресійним моделям як базовим і водночас потужним інструментам прогнозування.

Практична частина дослідження включала проведення експерименту з побудови моделей прогнозування на реальних або синтетичних даних, що імітують структуру продажів у продуктовому бізнесі. Було протестовано кілька моделей регресії, зокрема множинну лінійну регресію, хребтову (Ridge), ласо (Lasso), еластичну мережу (Elastic-Net) та поліноміальну регресію. На основі порівняльного аналізу моделей за ключовими метриками якості, такими як коефіцієнт детермінації (R^2), середньоквадратична помилка (MSE) та корінь середньоквадратичної помилки (RMSE), а також на основі візуалізації результатів і графіків залишків, було зроблено висновок про доцільність використання саме множинної лінійної регресії. Ця модель продемонструвала найкраще поєднання

точності, стабільності та здатності до узагальнення результатів без перенавчання, що є критично важливим для прогнозування в динамічному середовищі продуктової торгівлі.

Таким чином, результати дослідження підтверджують, що застосування математичних моделей, зокрема лінійної регресії, дозволяє істотно підвищити ефективність процесу прогнозування попиту. Це відкриває підприємствам можливості для прийняття більш точних і стратегічно вивірених управлінських рішень, знижує ризики, покращує обслуговування клієнтів і забезпечує конкурентні переваги на ринку. Проведена робота не лише продемонструвала на практиці ефективність конкретних методів, а й надала системне бачення вирішення прикладної бізнес-проблеми з використанням інструментів аналітики та машинного навчання.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Штучний інтелект у бізнесі: від автоматизації до трансформації моделей [Електронний ресурс] / Автори колективу IBM Research. – URL: <https://www.ibm.com/research/ai-business>. – Дата звернення: 26.10.2024.
2. Курпа, Н. В. Штучний інтелект: сучасні тенденції розвитку та застосування / Н. В. Курпа, О. С. Мельник. – Київ: Видавництво «Наукова думка», 2020. – 256 с.
3. McKinsey Global Institute. Artificial Intelligence in Business: A Deep Dive into Impact and Potential // McKinsey & Company. – 2022. – 72 с.
4. Russell, Stuart, and Peter Norvig. *Artificial Intelligence: A Modern Approach*. 4th ed. Hoboken, NJ: Pearson, 2020.
5. Bostrom, Nick. *Superintelligence: Paths, Dangers, Strategies*. Oxford: Oxford University Press, 2016.
6. Методичні вказівки до комплексного курсового проектування для здобувачів спеціальності 121 – Інженерія програмного забезпечення, освітньо-наукова програма «Інженерія програмного забезпечення», другий (магістерський) рівень вищої освіти / Упоряд.: З.В. Дудар, В.І. Каук, І.А. Ревенчук, І.П. Сокорчук - Харків: ХНУРЕ, 2024. -30с.
7. IEEE 830-1993 - IEEE Recommended Practice for Software Requirements Specifications / IEEE Standards Associations. URL: <https://ieeexplore.ieee.org/document/392555> (дата звернення: 27.06.2024).
8. ДСТУ 2391-2010 Система технологічної документації. Терміни та визначення основних понять. Державний комітет стандартизації метрології та сертифікації України - К.: Видання офіційне, 2011. 38 с.
9. ДСТУ 3008-2015 Інформація та документація. Звіти у сфері науки і техніки. Структура та правила оформлювання. К. ДП «УкрНДНЦ»: Видання офіційне, 2016. 31 с.
10. Інформація та документація. Бібліографічне посилання. Загальні положення та правила складання. ДСТУ 8302:2015.К. ДП «УкрНДНЦ»: Видання

офіційне, 2016. 20 с.

11. Нормативно-правова база з академічної доброчесності. URL: <https://nure.ua/universytet/normativno-pravova-baza> (дата звернення: 27.06.2024.)

12. Мазурова, Оксана Алексеевна. 2012. "Method of Making Decision Purpose Decomposition Supporting Based on Classification Model". *Eastern-European Journal of Enterprise Technologies* 3 (4(57):60-63. <https://doi.org/10.15587/1729-4061.2012.4018>.

13. Mazurova, Oksana, and V. I. Sadovnikov. "Дослідження методів оптимізації алгоритмів розпізнавання обличчя для роботи у системах з обмеженими ресурсами." *Наукові досягнення та відкриття сучасної молоді: Міжнародна науково-практична конференція, 28 квітня 2021 р.* Тези дослідження. Україна, 2021.

14. Kuptsov A. Прогнозування попиту з використанням методів машинного навчання [Електронний ресурс] // GitHub. URL: <https://github.com/ardad14/Kuptsov-Artem-IPZm-23-1-diploma>

**ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ ЗА НАУКОВИМИ НАПРЯМАМИ
КЕРІВНИКА ТА НАУКОВЦІВ КАФЕДРИ ПРОГРАМНОЇ ІНЖЕНЕРІЇ**

12. Мазурова, Оксана Алексеевна. 2012. "Method of Making Decision Purpose Decomposition Supporting Based on Classification Model". *Eastern-European Journal of Enterprise Technologies* 3 (4(57):60-63. <https://doi.org/10.15587/1729-4061.2012.4018>.

13. Mazurova, Oksana, and V. I. Sadovnikov. "Дослідження методів оптимізації алгоритмів розпізнавання обличчя для роботи у системах з обмеженими ресурсами." *Наукові досягнення та відкриття сучасної молоді: Міжнародна науково-практична конференція, 28 квітня 2021 р. Тези дослідження*. Україна, 2021.