

Вінницький національний технічний університет  
Факультет інтелектуальних інформаційних технологій та автоматизації  
Кафедра системного аналізу та інформаційних технологій


**Бакалаврська дипломна робота на тему:**


**«АНАЛІЗ ТА ПРОГНОЗУВАННЯ ЦІНИ НА АКЦІЇ NETFLIX»**

Виконав: студент 4 курсу, групи СА-206  
спеціальності 124 «Системний аналіз»

 Вадим РУДИК

Керівник: к.т.н., доц. каф. САІТ  
 Ілона ВАРЧУК


«03»  2024 р.

Рецензент: к.т.н., доц. каф. КН  
 Володимир ОЗЕРАНСЬКИЙ

«11»  2024 р.

**Допущено до захисту**

Завідувач кафедри САІТ

 д.т.н., проф. Віталій МОКІН

«04»  2024 р.

Вінниця ВНТУ – 2024 рік

Вінницький національний технічний університет  
Факультет інтелектуальних інформаційних технологій та автоматизації  
Кафедра системного аналізу та інформаційних технологій  
Рівень вищої освіти – перший (бакалаврський)  
Галузь знань – 12 Інформаційні технології  
Спеціальність 124 – «Системний аналіз»  
Освітньо-професійна програма – Системний аналіз

ЗАТВЕРДЖУЮ

Завідувач кафедри САІТ

Мокін д.т.н., проф. Віталій МОКІН

“05” 03 2024 року

**ЗАВДАННЯ**  
**НА БАКАЛАВРСЬКУ ДИПЛОМНУ РОБОТУ СТУДЕНТУ**  
Рудику Вадиму Васильовичу

1. Тема роботи: «Аналіз та прогнозування ціни на акції Netflix»

керівник роботи: Варчук І.В., к.т.н., доц. каф. САІТ

затверджені наказом ВНТУ від «11» 03 2024 року № 80

2. Термін подання студентом роботи 31.05

3. Вихідні дані до роботи:

1) Дані ціни на акції компанії Netflix за 2014 – 2023 рр.

3. Зміст звіту (перелік питань, які потрібно розробити):

1) Загальна характеристика стрімінгових сервісів та ціноутворення на їх акції;

2) Розвідувальний аналіз даних та інженерія ознак;

3) Тренування моделей машинного навчання.

4) Результат застосування технології на реальних даних

5. Перелік ілюстративного матеріалу:

1) Графік ціни на акції Netflix за 2014 – 2023 рр ;

2) Графік важливості ознак;

3) Графік прогнозування моделлю Prophet;

3) Графік прогнозованих даних;

4) Таблиця порівняння оцінок точності прогнозування моделей.



6. Консультанти розділів роботи:

| Розділ | Прізвище, ініціали та посада консультанта | Підпис, дата   |                  |
|--------|-------------------------------------------|----------------|------------------|
|        |                                           | завдання видав | завдання прийняв |
|        |                                           |                |                  |
|        |                                           |                |                  |
|        |                                           |                |                  |

7. Дата видачі завдання 11.03

КАЛЕНДАРНИЙ ПЛАН

| № з/п | Назва та зміст етапу                                 | Термін виконання |            | Примітка |
|-------|------------------------------------------------------|------------------|------------|----------|
|       |                                                      | початок          | закінчення |          |
| 1     | Аналіз предметної області                            | 11.03            | 31.03      | вик      |
| 2     | Порівняльний аналіз методів прогнозування ціни акцій | 01.04            | 15.04      | вик      |
| 3     | Розвідувальний аналіз даних та інженерія ознак       | 16.04            | 30.04      | вик      |
| 4     | Прогнозування ціни акцій Netflix                     | 01.05            | 15.05      | вик      |
| 5     | Оформлення матеріалів до захисту БДР                 | 16.05            | 31.05      | вик      |

Студент

Керівник роботи

Вадим РУДИК

Ілона ВАРЧУК

## АНОТАЦІЯ

Бакалаврська дипломна робота складається з 74 сторінок формату А4, на яких є 45 рисунка, список використаних джерел містить 25 найменувань.

Метою роботи є аналіз та прогнозування ціни акцій Netflix.

В роботі проведено огляд стрімінгових компаній Netflix, Amazon Prime, Disney+, HBO Max. Проаналізовано ціноутворення на акції стрімінгової компанії Netflix. Розглянуто альтернативні методи прогнозування ціни на акції Netflix.

Проведено розвідувальний аналіз даних ціни акцій Netflix. Виконано інженерію ознак за допомогою TSFRESH. Сформовано набір ознак для використання їх у моделях машинного навчання для прогнозування ціни на акції Netflix.

Для прогнозування ціни акцій Netflix використано моделі машинного навчання Prophet, ARIMA, XGBoost. Проведено тренування обраних моделей на тренувальних даних. Проведено тестування натренованих моделей на тестовому наборі даних. Візуалізовано прогнозовані дані на графіках. Проведено оцінку використаних моделей та обрано оптимальну модель для прогнозування ціни на акції Netflix. Для реалізації роботи використано мову Python.

Ключові слова: системний аналіз, передбачення даних, машинне навчання, Python.

## **ABSTRACT**

The bachelor thesis consists of 74 pages of A4 format, on which there are 45 figures, the list of used sources contains 25 names.

The purpose of the work is to analyze and forecast the price of Netflix shares.

The work includes an overview of the streaming companies Netflix, Amazon Prime, Disney+, and HBO Max. The pricing of shares of the streaming company Netflix has been analyzed. Considered alternative methods of forecasting the price of Netflix shares.

Exploratory analysis of Netflix share price data. Performed feature engineering using TSFRESH. A set of features was formed for use in machine learning models to predict the price of Netflix shares.

Prophet, ARIMA, XGBoost machine learning models were used to forecast the price of Netflix shares. The selected models were trained on the training data. The trained models were tested on the test data set. The forecasted data is visualized on the graphs. The used models were evaluated and the optimal model was selected for forecasting the price of Netflix shares. The Python language was used to implement the work.

Keywords: system analysis, data prediction, machine learning, Python.

## ЗМІСТ

|                                                                                         |    |
|-----------------------------------------------------------------------------------------|----|
| ВСТУП.....                                                                              | 3  |
| 1. ЗАГАЛЬНА ХАРАКТЕРИСТИКА ОБ'ЄКТУ ДОСЛІДЖЕНЬ.....                                      | 5  |
| 1.1 Аналіз стрімінгових сервісів .....                                                  | 5  |
| 1.2 Огляд методів прогнозування ціни на акції Netflix.....                              | 13 |
| 1.3 Висновки.....                                                                       | 20 |
| 2. РОЗВІДУВАЛЬНИЙ АНАЛІЗ ДАНИХ ТА ІНЖЕНЕРІЯ ОЗНАК ЦІНИ НА NETFLIX.....                  | 22 |
| 2.1 Розвідувальний аналіз даних ціни на Netflix .....                                   | 22 |
| 2.2 Відбір ознак для передбачення даних .....                                           | 28 |
| 2.3 Вибір моделей прогнозування ціни на акції .....                                     | 30 |
| 2.4 Висновки.....                                                                       | 31 |
| 3. РЕЗУЛЬТАТИ ПРОГНОЗУВАННЯ ЦІНИ НА АКЦІЇ .....                                         | 32 |
| 3.1 Прогнозування моделлю Prophet .....                                                 | 32 |
| 3.2 Прогнозування моделлю ARIMA.....                                                    | 39 |
| 3.3 Прогнозування моделлю XGBoost.....                                                  | 45 |
| 3.4 Висновки.....                                                                       | 51 |
| ВИСНОВКИ .....                                                                          | 52 |
| СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....                                                         | 54 |
| Додаток А(обов'язковий). Технічне завдання .....                                        | 57 |
| Додаток Б(обов'язковий). Протокол перевірки БДР на наявність текстових запозичень ..... | 59 |
| Додаток В(довідниковий). Фрагмент лістингу програми.....                                | 60 |
| Додаток Г (обов'язковий). Ілюстративна частина.....                                     | 69 |

## ВСТУП

**Актуальність теми.** Netflix є лідером у галузі стрімінгових медіа, і будь-які зміни в їхніх стратегіях, такі як ціноутворення, рекламні стратегії, або нові релізи контенту, можуть впливати на їхні фінансові показники та ціну акцій.

Збільшення конкуренції від таких компаній, як Amazon Prime, Disney+, HBO Max, та інших, може впливати на ринкову частку Netflix та їхню дохідність. Аналіз цих тенденцій допомагає інвесторам розуміти потенційні ризики та можливості.

Технологічний прогрес у галузі штучного інтелекту та машинного навчання відкриває нові можливості для персоналізації контенту та покращення користувацького досвіду, що також може впливати на акції Netflix.

Регуляторні зміни у різних країнах, де Netflix працює, можуть впливати на їхню діяльність і прибутки.

Загальноекономічні фактори, такі як ставки процентів, інфляція, або рецесії, також можуть впливати на інвестиційну привабливість акцій Netflix.

Аналіз цих аспектів дозволяє краще розуміти, як зміни в бізнесі, технологіях, ринковому середовищі та макроекономічних умовах можуть вплинути на вартість акцій Netflix. Прогнозування ціни акцій на основі цих даних є важливим інструментом для інвесторів та аналітиків.

**Мета і задачі дослідження.** Метою дослідження є аналіз та прогнозування ціни акцій Netflix .

Для досягнення поставленої мети необхідно розв'язати такі задачі:

- Провести аналіз ціноутворення на акції;
- Провести розвідувальний аналіз даних;
- Провести інженерію ознак;
- Натренувати та застосувати моделі машинного навчання для прогнозування ціни на акції компанії Netflix.

**Об’єктом дослідження** є застосування методів машинного навчання для прогнозування ціни на акції Netflix.

**Предметом дослідження** є моделі машинного навчання для прогнозування ціни на акції Netflix.



# 1. ЗАГАЛЬНА ХАРАКТЕРИСТИКА ОБ'ЄКТУ ДОСЛІДЖЕНЬ

## 1.1 Аналіз стрімінгових сервісів

Netflix Inc. — американська транснаціональна медіа-компанія, яка надає послуги стрімінгового відео на вимогу, виробництво та розповсюдження оригінального контенту. Була заснована 29 серпня 1997 року у Скоттс-Веллі, Каліфорнія, Рідом Гастінгсом і Марком Рендольфом. Ідея компанії виникла після того, як Гастінгс отримав великий штраф за пізнє повернення DVD, що спонукало його створити зручніший сервіс прокату фільмів. Спочатку Netflix пропонувала прокат DVD поштою через інтернет-сайт, де клієнти могли обирати фільми для доставки додому (рис. 1.1) [1].




Рисунок 1.1 – Головна сторінка Netflix

У 1999 році Netflix запровадила модель підписки, яка дозволяла клієнтам платити фіксовану щомісячну плату за необмежену кількість прокатів DVD без термінів повернення, що зробило сервіс ще зручнішим і популярнішим. Ця модель допомогла компанії залучити більше клієнтів та значно збільшити свою базу підписників.

У січні 2007 року Netflix запустила свою послугу потокового відео, що дозволяло клієнтам миттєво дивитися телевізійні шоу та фільми онлайн. Це стало важливим кроком у розвитку компанії, оскільки технології потокового передавання почали швидко розвиватися, і споживачі все більше цікавилися можливістю перегляду відео в режимі реального часу.

У 2013 році Netflix розпочала виробництво власного оригінального контенту, випустивши серіал "House of Cards". Цей крок виявився дуже успішним і започаткував еру активного створення оригінальних фільмів, серіалів та документальних стрічок. Інші успішні проекти включають "Stranger Things", "The Crown", "Orange Is the New Black", "Narcos" та багато інших [1].

З 2010 року Netflix почала розширювати свою присутність за межами США. Спочатку компанія запустила свої послуги в Канаді, а потім поступово вийшла на ринки Латинської Америки, Європи, Азії та інших регіонів. Сьогодні Netflix доступна у понад 190 країнах світу, пропонуючи контент на різних мовах і враховуючи культурні особливості різних регіонів.

Netflix активно співпрацює з різними партнерами для покращення якості своїх послуг. Компанія використовує потужні алгоритми аналізу даних для персоналізації рекомендацій, покращує інтерфейс користувача, інвестує в технології адаптивного стрімінгу та розробляє інтерактивний контент, наприклад, "Black Mirror: Bandersnatch".

Фінансовий успіх Netflix значною мірою зумовлений її стратегією інвестування у власний контент та міжнародну експансію. Компанія продовжує залучати мільйони нових підписників щороку, що призводить до постійного зростання доходів. Водночас Netflix має значні боргові зобов'язання через великі інвестиції в контент, але компанія зберігає стабільне фінансове становище завдяки зростанню кількості передплатників та доходів.

Netflix реалізує різноманітні програми соціальної відповідальності, включаючи підтримку різноманітності та інклюзії, створення контенту, що відображає різні культури та досвіди, а також екологічні ініціативи, спрямовані на зменшення вуглецевого сліду.

Netflix продовжує інвестувати в технологічні інновації, щоб покращити якість стрімінгу та користувацький досвід:

- Використання машинного навчання для покращення рекомендацій та персоналізованого контенту.
- Технологія, яка автоматично налаштовує якість відео залежно від швидкості інтернет-з'єднання.
- Розробка інтерактивних фільмів та серіалів, таких як "Black Mirror: Bandersnatch", що дозволяють глядачам приймати рішення щодо розвитку сюжету.

Netflix продовжує активно розширювати свою бібліотеку оригінального контенту. Компанія інвестує мільярди доларів у виробництво нових фільмів, серіалів та документальних стрічок, щоб залучити та утримати передплатників. Одні з найбільш значущих нових проєктів включають [1]:

"The Queen's Gambit": Серіал, що став феноменом і значно збільшив інтерес до шахів.

"Bridgerton": Романтичний серіал, який швидко здобув велику популярність.

"The Witcher": Епічний фентезійний серіал, заснований на популярних книгах та відеоіграх.

Netflix активно інвестує в місцевий контент у різних країнах для залучення регіональних аудиторій. Наприклад:

Індія – виробництво індійських фільмів і серіалів, таких як "Sacred Games" та "Delhi Crime".

Південна Корея – випуск популярних корейських драм, таких як "Kingdom" та "Sweet Home".

Європа – виробництво місцевих серіалів, таких як німецький "Dark" та іспанський "Money Heist".

Netflix продовжує залишатися лідером на ринку стрімінгових послуг, активно розвиваючи свій оригінальний контент та технологічні можливості. Конкуренція з боку інших гравців, таких як Amazon Prime Video, Disney+, HBO

Мах та інших, стимулює компанію до подальших інновацій та покращення користувацького досвіду. Враховуючи тенденції зростання споживання стрімінгового контенту, Netflix має добрі перспективи для подальшого розвитку та зміцнення своїх позицій на світовому ринку.

Amazon Prime Video — це відеострімінговий сервіс, який належить і управляється американською компанією Amazon. Він був офіційно запущений 7 вересня 2006 року як частина платформи Amazon Instant Video. Спочатку Amazon Instant Video пропонував своїм користувачам можливість оренди або покупки фільмів та телевізійних шоу (рис 1.2) [2].




Рисунок 1.2 – Головна сторінка Amazon Prime Video

Однак сервіс розширився, коли Amazon запустив Amazon Prime, програму передплати, яка надавала доступ до безкоштовної доставки товарів та інших переваг. Пізніше Amazon почав включати в цю програму доступ до Amazon Prime Video, що дозволяло передплатникам переглядати тисячі фільмів та телевізійних шоу в межах однієї передплати.

Протягом наступних років Amazon Prime Video активно розвивався та розширював свій контентний каталог. Крім того, компанія почала виробляти

власний оригінальний контент, включаючи серіали та фільми, які стали відомими і популярними серед глядачів.

Ключові події та досягнення [2]:

2006–2011: Початок розвитку

2006 рік: Amazon запускає Amazon Unbox, відеосервіс для оренди та покупки фільмів та телевізійних шоу.

2011 рік: Amazon запускає Amazon Prime, програму з безкоштовною доставкою товарів та іншими перевагами для передплатників.

2011–2015: Початок відеострімінгу

2011 рік: Amazon запускає Amazon Instant Video, відеострімінговий сервіс, доступний для передплатників Amazon Prime.

2013 рік: Amazon починає виробництво оригінальних контенту, випустивши пілотні серії для серіалу "Alpha House" та "Betas".

З 2015 року: Зростання та розвиток

2015 рік: Amazon розширює доступність Prime Video за межі США, включаючи такі країни, як Об'єднане Королівство, Німеччина та Японія.

2016 рік: Amazon випускає великі оригінальні серіали, такі як "The Man in the High Castle" та "Transparent", які отримують високу оцінку критиків.

2017 рік: Amazon оголошує придбання прав на великі спортивні події, такі як "Thursday Night Football" у Національній футбольній лізі (NFL).

2018 рік: Amazon випускає серіал "The Marvelous Mrs. Maisel", який стає популярним та отримує безліч нагород, включаючи премію "Еммі".

З 2020 року: Міжнародний розширення та нові проекти

2020 рік: Amazon Prime Video активно розширює свою присутність у світі, надаючи доступ до великого каталогу в країнах Азії, Європи та Латинської Америки.

2021 рік: Amazon випускає серіал "The Lord of the Rings: The Rings of Power", який стає одним з найбільш очікуваних проектів в історії стрімінгового телебачення.



Amazon Prime Video відомий своїми великими інвестиціями в оригінальний контент, включаючи серіали, фільми та документальні фільми.

Amazon активно придбає права на спортивні події, такі як футбольні матчі NFL та тенісні турніри.

Сервіс постійно розширює свою глобальну присутність, надаючи доступ до контенту в різних країнах.

Amazon використовує передові технології для покращення якості стрімінгу та користувацького досвіду.

Amazon Prime Video продовжує залучати аудиторію своїм оригінальним контентом, розширює свою присутність у різних країнах світу і вдосконалює користувацький досвід для своїх передплатників [2].

Disney+ — це відеострімінговий сервіс, який належить і управляється американською медіакомпанією The Walt Disney Company. Офіційно запусканий 12 листопада 2019 року, Disney+ став додатковим способом для Disney поширювати свій великий каталог відеоконтенту (рис 1.3) [3].



Рисунок 1.3 – Головна сторінка Disney+

У серпні 2017 року Disney оголосив про свій намір створити власний відеострімінговий сервіс. У квітні 2019 року компанія представила назву Disney+ та деякі деталі щодо контенту. Сам сервіс був запусканий у листопаді 2019 року у США, Канаді та Нідерландах [3].

Після успішного запуску в США, Канаді та Нідерландах Disney+ почав розширювати свою присутність у різних країнах світу. У листопаді 2019 року сервіс був запусканий у кількох країнах Європи, а згодом поширився на багато інших ринків.

Disney+ швидко став популярним завдяки своєму великому каталогу класичних анімаційних фільмів Disney, фільмів Marvel та серіалів Star Wars. Крім

того, Disney+ активно виробляв оригінальний контент, такий як серіали "The Mandalorian", "WandaVision" та "The Falcon and the Winter Soldier", які здобули велику популярність серед глядачів.

Disney+ укладав різноманітні партнерства та угоди з іншими медіа-компаніями, що допомагало розширити його каталог контенту та привернути нових передплатників. Також Disney+ приступив до виробництва нових серіалів та фільмів, які спрямовані на різні аудиторії та демографічні групи.

Disney+ продовжує залучати нових передплатників, розширюючи свій каталог контенту та розвиваючи нові серіали та фільми. Компанія також досліджує можливості впровадження технологічних інновацій для поліпшення користувацького досвіду.

HBO Max – це відеострімінговий сервіс, який належить і управляється американським медіаконгломератом WarnerMedia, дочірньою компанією AT&T. Він був запущений 27 травня 2020 року в Сполучених Штатах, згодом розширився на інші країни світу (рис.1.4) [4].



Рисунок 1.4 – Логотип HBO Max

Анонс HBO Max відбувся у липні 2019 року. Сервіс був офіційно запущений у травні 2020 року. Він поєднав в собі вміст каналу HBO, а також інші

відомі бренди та фірмовий контент WarnerMedia, такі як Warner Bros., DC, Cartoon Network, Turner Classic Movies та інші.

Запуск HBO Max супроводжувався прем'єрою оригінального контенту, включаючи серіали "Love Life", "The Not-Too-Late Show with Elmo", "Legendary", "Raised by Wolves" та інші. Крім того, HBO Max оголосив про багато нових оригінальних проєктів, що мають вийти в майбутньому.

Після успішного запуску в США HBO Max почав розширюватися на міжнародні ринки. У 2021 році сервіс був запусканий у кількох країнах Європи та Латинської Америки, і він планує подальше розширення.

WarnerMedia уклав різноманітні партнерства та угоди з іншими компаніями, щоб привернути нових передплатників та розширити свій контентний каталог. Наприклад, угода з HBO Max та Roku дозволила платформі отримати доступ до мільйонів нових передплатників [3].

HBO Max продовжує активно розвиватися, додаючи новий оригінальний контент, розширюючи свою глобальну присутність та підписуючи нові партнерські угоди.

Цілком можливо, що в майбутньому HBO Max продовжить свій розвиток та розширення, а також буде продовжувати виробляти оригінальний та високоякісний контент для своїх передплатників.

## 1.2 Огляд методів прогнозування ціни на акції Netflix

Формування ціни на акції стрімінгового сервісу Netflix. На рисунку 1.7 зображено зміни на ціну даної компанії за останні 3 роки [4].




Рисунок 1.5 – Зміна ціни на акції Netflix

#### 1. Фінансові показники компанії:

- Публікація фінансових звітів, що показують доходи, прибутки, витрати та інші ключові фінансові показники, безпосередньо впливає на ціну акцій. Високі доходи та прибутки зазвичай підвищують вартість акцій [4].
- Прогнози майбутніх доходів та прибутків також впливають на ціну акцій. Якщо прогнози перевищують очікування інвесторів, ціна акцій може зрости.

#### 2. Рівень підписників:

- Збільшення кількості підписників Netflix свідчить про зростаючу популярність сервісу, що позитивно впливає на ціну акцій.

- Втрата підписників або менше очікуваного зростання може негативно вплинути на ціну акцій.

### 3. Конкуренція:

- Поява нових конкурентів або агресивні дії існуючих конкурентів (наприклад, Disney+, Amazon Prime Video, HBO Max) можуть вплинути на ринкову позицію Netflix, що може відобразитися на ціні акцій.

- Інновації або успішні стратегії конкурентів можуть зменшити частку ринку Netflix.

### 4. Новини та події:

- Позитивні новини, такі як успішні випуски нових серіалів або фільмів, укладення вигідних угод, можуть підвищити ціну акцій.

- Зміни в економічній ситуації, новини про технологічний сектор і ринок стрімінгових послуг також впливають на акції Netflix.

### 5. Макроекономічні фактори [4]:

- Загальний стан економіки, включаючи показники ВВП, рівень безробіття, інфляцію, впливає на фондові ринки загалом і на акції Netflix зокрема.

- Політичні рішення, такі як регулювання інтернет-індустрії, міжнародна торгівля, можуть мати значний вплив.

### 6. Аналітичні оцінки та рекомендації:

- Рекомендації аналітиків з інвестиційних банків і дослідницьких фірм можуть впливати на попит на акції. Підвищення рейтингів або цільових цін зазвичай підвищує ціну акцій, і навпаки.

- Звіти та дослідження, що вказують на перспективи зростання або ризику, можуть також впливати на ціну акцій.

### 7. Інсайдерська інформація:



– Купівля або продаж акцій керівництвом компанії може подавати сигнали ринку про їхні очікування щодо майбутнього компанії, що впливає на ціну акцій.

– Зміни у складі керівництва або ключових менеджерів можуть впливати на ринкові очікування та ціну акцій.

Ноутбук «Time-Series-Analysis-Netflix-Stock-Price». Основні методи аналізу включають перевірку стаціонарності серій, використання ADF тесту, та сезонне декомпонування. Через низьку стаціонарність даних вдається до сезонного декомпонування та ресемплінгу даних для аналізу [5].

Для прогнозування майбутніх цін, автор застосував модель SARIMAX (рис. 1.6 , 1.7).

```
# Assuming your time series data is in a column named 'stock_price'
ts = df_timeseries_filtered_monthly['typical']

# Define and fit the SARIMA model
model = SARIMAX(ts, order=(1, 1, 1), seasonal_order=(1, 1, 1, 12))
results = model.fit()

# Forecast future values
forecast = results.forecast(steps=12) # Forecast for a year

# Plot the original data and the forecast
plt.plot(ts.index, ts, label='Original Data')
plt.plot(forecast.index, forecast, label='Forecast')
plt.xlabel('Date')
plt.ylabel('Typical Stock Price')
plt.title('Time Series Forecasting with SARIMA')
plt.legend()
plt.show()
```

Рисунок 1.6 – Налаштування моделі SARIMAX в ноутбуці «Time-Series-Analysis-Netflix-Stock-Price»

Модель SARIMAX (Seasonal AutoRegressive Integrated Moving Average with eXogenous variables) є розширенням моделі ARIMA, що включає сезонні компоненти та зовнішні змінні. Ця модель часто використовується для аналізу часових рядів, де є як сезонність, так і зовнішні впливи на дані. SARIMAX дозволяє моделювати вплив незалежних змінних на часовий ряд, що робить її особливо корисною в економетриці, фінансах та інших галузях, де потрібно прогнозувати майбутні значення з урахуванням додаткових факторів [5].




Рисунок 1.7 – Результат роботи SARIMAX в ноутбучі «Time-Series-Analysis-Netflix-Stock-Price»

Ноутбук «Garch 1». Автор використав модель GARCH (Generalized Autoregressive Conditional Heteroskedasticity) — це статистична модель, яка використовується для аналізу і прогнозування часових рядів, особливо тих, що показують волатильність, як у фінансових ринках. Модель GARCH дозволяє

моделювати і передбачати зміни волатильності часових рядів, залежно від часу, що робить її дуже корисною для фінансових даних, де волатильність не є постійною або однорідною. GARCH часто використовується для оцінювання ризику і управління інвестиційними портфелями (рис. 1.8 , 1.9) [6].

```

model = arch_model(returns, vol='GARCH', p=5, o=2, q=0)
res = model.fit(update_freq=5)
print(res.summary())

```

```

Iteration:      5,   Func. Count:      60,   Neg. LLF: 5626.111069952705
Iteration:     10,   Func. Count:     116,   Neg. LLF: 4270.291888851274
Iteration:     15,   Func. Count:     171,   Neg. LLF: 4248.749690160375
Optimization terminated successfully   (Exit mode 0)
      Current function value: 4248.7436034518805
      Iterations: 19
      Function evaluations: 211
      Gradient evaluations: 19
      Constant Mean - GJR-GARCH Model Results
=====
Dep. Variable:              Close   R-squared:                0.000
Mean Model:                Constant Mean   Adj. R-squared:          0.000
Vol Model:                 GJR-GARCH   Log-Likelihood:        -4248.74
Distribution:              Normal   AIC:                   8515.49
Method:                   Maximum Likelihood   BIC:                   8564.74
                                     No. Observations:         1759
Date:                     Sun, Apr 14 2024   Df Residuals:          1758
Time:                     10:54:28   Df Model:               1
                                     Mean Model
=====
              coef    std err          t      P>|t|  95.0% Conf. Int.
-----
mu           0.0976    0.204        0.477    0.633 [ -0.303,  0.498]
      Volatility Model
=====
              coef    std err          t      P>|t|  95.0% Conf. Int.
-----
omega        4.4335    1.302        3.406  6.595e-04 [  1.882,  6.985]
alpha[1]     0.2194    0.475        0.462    0.644 [ -0.711,  1.150]
alpha[2]     0.0316  7.317e-02    0.432    0.666 [ -0.112,  0.175]
alpha[3]     0.0757    0.459        0.165    0.869 [ -0.823,  0.974]
alpha[4]     0.2141    0.145        1.480    0.139 [-6.945e-02,  0.498]
alpha[5]     0.0247  4.970e-02    0.496    0.620 [-7.274e-02,  0.122]
gamma[1]     -0.0267    0.390  -6.836e-02    0.946 [ -0.792,  0.738]
gamma[2]     4.5829e-03  9.570e-02  4.789e-02    0.962 [ -0.183,  0.192]
=====
Covariance estimator: robust

```

Рисунок 1.8 – Використання моделі GARCH

Результати, представлені на зображенні 2., відносяться до аналізу моделі GJR-GARCH, використаної для вимірювання волатильності цін на закриття (змінної `Close`). Модель включає декілька параметрів [6]:

- $\mu$  ( $\mu$ ) – середнє значення моделі, коефіцієнт становить 0.0976 зі стандартною помилкою 0.204 і р-значенням 0.633, що свідчить про те, що воно не є статистично значущим.
- $\omega$  – коефіцієнт базової волатильності дорівнює 4.4335 з р-значенням, близьким до 0, що підтверджує його значимість.
- $\alpha[1]$  до  $\alpha[5]$  та  $\gamma[1]$  і  $\gamma[2]$  – параметри, що відображають вплив минулих значень та асиметрії шоків на поточну волатильність. більшість з них не є статистично значущими, окрім  $\omega$ .

Модель не має значущого R-квадрату, що вказує на низьку пояснювальну здатність моделі для змінної `Close`. Загалом, ця модель дозволяє зрозуміти динаміку волатильності, але має певні обмеження в прогнозуванні точних значень цін закриття.




Рисунок 1.9 – Результат роботи моделі GARCH

Інші автори використовували моделі: лінійна регресія, градієнтний бустинг та Prophet. Лінійна регресія показала точність 0,97, але оскільки автор рішення не перевіряв дані на автокореляцію, що викликає підозру до надійності моделі. Така ж ситуація і для моделі XGBoost Regressor. У автора рішення точність моделі 0,997. Такий результат говорить про те, що модель перенавчилась і є ненадійною [7,8].

Публікації використані в роботі охоплюють різні аспекти аналізу та прогнозування цін на акції за допомогою сучасних технічних підходів, включаючи нейронні мережі, алгоритми машинного навчання, і гібридні моделі. Вони досліджують ефективність таких методів, як GARCH, ARIMA у контексті фінансових ринків. Статті аналізують волатильність, вплив зовнішніх чинників на ціни акцій, а також практичне застосування передових моделей для оптимізації інвестиційних стратегій [9-15].

У деяких статтях описується прогнозування ціни на акції з використанням рекурентних нейронних мереж[15-26].

Найчастіше зустрічається мережа LSTM (Long Short-Term Memory) — це тип рекурентної нейронної мережі (RNN), оптимізований для вирішення проблеми зникнення градієнту, що часто зустрічається в традиційних RNN. LSTM дизайновано так, щоб краще запам'ятовувати інформацію на тривалі часові проміжки. Це робить його особливо корисним для завдань, де необхідно враховувати контекст і довгострокові залежності, таких як прогнозування часових рядів, обробка природної мови та розпізнавання рукописного тексту.

### 1.3 Висновки

В першому розділі проаналізовано загальну тематику стрімінгових сервісів. Проведено порівняльний аналіз популярних стрімінгів у світі, таких як Netflix, Amazon Prime Video, Disney+. За даними аналізу найбільш популярний стрімінг це Netflix.

Розглянуто процес ціноутворення акцій стрімінгових сервісів. Визначено основні характеристики за якими може утворюватися ціна акцій, а саме фінансові показники компанії, рівень підписників, конкуренція, новини та події, макроекономічні фактори, аналітичні оцінки та рекомендації інсайдерська інформація.

Проведено огляд основних підходів до аналізу та прогнозуванню ціни на акції Netflix в Kaggle Notebooks:

- «Time-Series-Analysis-Netflix-Stock-Price»,
- «Garch 1»,
- «XGboost: Predict "next\_day\_close"»,
- «Very Simple Prediction of Next Day Stock (99.76%)».

В даних підходах використано методи ARIMA, Garch, XGboost та лінійна регресія.

## 2. РОЗВІДУВАЛЬНИЙ АНАЛІЗ ДАНИХ ТА ІНЖЕНЕРІЯ ОЗНАК ЦІНИ НА NETFLIX

### 2.1 Розвідувальний аналіз даних ціни на Netflix

Для виконання роботи обрано датасет ціни на акції Netflix «Netflix Stock Price With Indicators». Цей набір даних містить інформацію про зміни ціни компанії з 2014 року по 2023 рік [27].

Першим кроком завантажимо дані в Kaggle notebook, що зображено на рисунку 2.1.

```
df = pd.read_csv('/kaggle/input/netflix-stock-price-with-indicators/nflx_2014_2023.csv')
df.head()
```

Рисунок 2.1 – Завантаження даних для аналізу

Переглянемо дані доступні для аналізу (рис. 2.2).

|   | date       | open      | high      | low       | close     | volume   | rsi_7     | rsi_14    | cci_7       |
|---|------------|-----------|-----------|-----------|-----------|----------|-----------|-----------|-------------|
| 0 | 2014-01-02 | 52.401428 | 52.511429 | 51.542858 | 51.831429 | 12325600 | 34.729664 | 49.183584 | -89.573201  |
| 1 | 2014-01-03 | 52.000000 | 52.495712 | 51.842857 | 51.871429 | 10817100 | 35.587886 | 49.457208 | -65.820581  |
| 2 | 2014-01-06 | 51.889999 | 52.044285 | 50.475716 | 51.367142 | 15501500 | 29.820674 | 46.087900 | -121.472559 |
| 3 | 2014-01-07 | 49.684284 | 49.698570 | 48.152859 | 48.500000 | 36167600 | 14.371863 | 32.522091 | -206.762171 |
| 4 | 2014-01-08 | 48.104286 | 49.425713 | 48.074287 | 48.712856 | 20001100 | 18.049045 | 34.073549 | -117.836707 |

| cci_7       | cci_14      | sma_50    | ema_50    | sma_100   | ema_100   | macd      | bollinger | TrueRange | atr_7    | atr_14   | next_day_close |
|-------------|-------------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|----------|----------|----------------|
| -89.573201  | -131.288579 | 50.112828 | 50.235157 | 46.385428 | 46.650698 | 0.751929  | 52.607357 | 1.052857  | 1.161182 | 1.247748 | 51.871429      |
| -65.820581  | -103.026189 | 50.228771 | 50.299327 | 46.537571 | 46.754726 | 0.624259  | 52.656143 | 0.664283  | 1.090197 | 1.206072 | 51.367142      |
| -121.472559 | -139.640566 | 50.312571 | 50.341203 | 46.680971 | 46.846621 | 0.476890  | 52.666928 | 1.568569  | 1.158535 | 1.231965 | 48.500000      |
| -206.762171 | -238.029120 | 50.336228 | 50.268997 | 46.791957 | 46.879558 | 0.127277  | 52.560214 | 3.214283  | 1.452214 | 1.373559 | 48.712856      |
| -117.836707 | -180.766801 | 50.373257 | 50.207969 | 46.917071 | 46.916075 | -0.131106 | 52.455357 | 1.351426  | 1.437815 | 1.371978 | 48.150002      |

Рисунок 2.2 – Дані доступні для аналізу



За допомогою команди `info()` переглянемо інформацію про дані, такі як назви ознак, кількість даних в кожній ознаці та тип даних (рис. 2.3).

```

RangeIndex: 2516 entries, 0 to 2515
Data columns (total 20 columns):
 #   Column                Non-Null Count  Dtype
---  -
 0   date                  2516 non-null   object
 1   open                  2516 non-null   float64
 2   high                  2516 non-null   float64
 3   low                   2516 non-null   float64
 4   close                 2516 non-null   float64
 5   volume                2516 non-null   int64
 6   rsi_7                 2516 non-null   float64
 7   rsi_14                2516 non-null   float64
 8   cci_7                 2516 non-null   float64
 9   cci_14                2516 non-null   float64
10   sma_50                2516 non-null   float64
11   ema_50                2516 non-null   float64
12   sma_100               2516 non-null   float64
13   ema_100               2516 non-null   float64
14   macd                  2516 non-null   float64
15   bollinger              2516 non-null   float64
16   TrueRange              2516 non-null   float64
17   atr_7                 2516 non-null   float64
18   atr_14                2516 non-null   float64
19   next_day_close        2516 non-null   float64
dtypes: float64(18), int64(1), object(1)
memory usage: 393.2+ KB

```

Рисунок 2.3 – Інформація про дані

Зробимо опис кожної ознаки:

- Відкриття (Open): Ціна акції на момент відкриття торгів;
- Максимум (High): Найвища ціна акції протягом торгового дня;
- Мінімум (Low): Найнижча ціна акції протягом дня;
- Закриття (Close): Ціна акції на кінець торгового дня;

- Об'єм (Volume): Загальна кількість акцій, що були продані протягом дня;
- RSI\_7 / RSI\_14 (Індекс відносної сили): Цей індекс показує швидкість та зміни цінових рухів за 7 або 14 днів;
- CCI\_7 / CCI\_14 (Індекс каналу товару): Цей індикатор допомагає виявляти нові тренди або екстремальні умови на ринку за 7 або 14 днів;
- SMA\_50 / SMA\_100 (Проста ковзна середня): Розрахунок середньої ціни акції за останні 50 або 100 днів;
- EMA\_50 / EMA\_100 (Експоненційна ковзна середня): Дає більшу вагу недавнім цінам і швидше реагує на зміни цін за останні 50 або 100 днів;
- MACD (Індикатор конвергенції/дивергенції ковзних середніх): Показує відносини між двома ковзними середніми цінами акції;
- Боллінджерові стрічки (Bollinger Bands): Встановлені на відстані двох стандартних відхилень від простої ковзної середньої ціни акції, можуть вказувати на рівні підтримки або опору;
- Істинний діапазон (True Range): Найбільший із наступних: поточний максимум мінус поточний мінімум, абсолютна величина поточного максимуму мінус попереднє закриття, або абсолютна величина поточного мінімуму мінус попереднє закриття;
- ATR\_7 / ATR\_14 (Середній істинний діапазон): Міра волатильності, що показує, наскільки середньо змінюється ціна акції за 7 або 14 днів;
- Ціна закриття наступного дня (Next Day Close): Ціна закриття акції на наступний торговий день, використовується для прогнозування.

За допомогою функції `describe()` сформуємо звіт описової статистики по даним ціни акції Netflix (рис.2.4).

|       | open        | high        | low         | close       | volume       | rsi_7       | rsi_14      | cci_7       | cci_14      | sma_50      | ema_50      | sma_100     | ema_100     |
|-------|-------------|-------------|-------------|-------------|--------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| count | 2516.000000 | 2516.000000 | 2516.000000 | 2516.000000 | 2.516000e+03 | 2516.000000 | 2516.000000 | 2516.000000 | 2516.000000 | 2516.000000 | 2516.000000 | 2516.000000 | 2516.000000 |
| mean  | 274.455767  | 278.638946  | 270.124592  | 274.487023  | 1.049230e+07 | 53.399584   | 53.424079   | 11.920763   | 15.705041   | 270.416745  | 270.522273  | 266.760420  | 266.813442  |
| std   | 166.005094  | 168.205188  | 163.612279  | 165.902954  | 9.173072e+06 | 17.763862   | 13.088270   | 100.831995  | 111.396602  | 164.404981  | 163.454752  | 163.189487  | 161.050027  |
| min   | 44.605713   | 45.842857   | 42.785713   | 44.887142   | 1.144000e+06 | 4.374756    | 9.152344    | -233.333333 | -424.012878 | 49.679943   | 49.409771   | 46.385428   | 46.650698   |
| 25%   | 109.982502  | 111.887501  | 107.117498  | 110.064998  | 5.017050e+06 | 40.015924   | 43.731175   | -74.565801  | -71.870319  | 107.627900  | 105.923105  | 105.662982  | 102.490532  |
| 50%   | 288.000000  | 292.690002  | 282.660004  | 288.229995  | 7.795950e+06 | 53.953919   | 53.668026   | 25.632766   | 27.165946   | 286.034599  | 287.382611  | 287.634151  | 291.379066  |
| 75%   | 384.542511  | 391.317505  | 377.795006  | 384.560005  | 1.299060e+07 | 67.151119   | 63.378696   | 94.212764   | 100.321908  | 376.592201  | 381.284113  | 365.740875  | 369.343945  |
| max   | 692.349976  | 700.989990  | 686.090027  | 691.690002  | 1.333875e+08 | 96.305710   | 91.547868   | 233.333333  | 356.795719  | 648.592997  | 642.765550  | 616.771798  | 610.750059  |

Рисунок 2.4 – Описова статистика ціни на акції Netflix

Загальна кількість записів становить 2516. Середня ціна відкриття становить 274,46 USD, з максимумом у 692,35 USD. Об'єм торгів в середньому дорівнює близько 10 мільйонів акцій за день. Індекс RSI\_7 має середнє значення 53,40, а RSI\_14 — 53,42, що вказує на не дуже високий рівень зміни ціни. Індикатор CCI для 7 днів середньо становить 11,92, а для 14 днів — 15,71, що відображає тренди та екстремальні умови ринку. Вказані також середні та експоненційні ковзні середні (SMA та EMA) за 50 і 100 днів, які допомагають аналізувати довгострокові тренди.

Побудуємо графік динаміки зміни ціни на акції (рис. 2.5)



Рисунок 2.5 – Зміна ціни на акції з 2014 по 2023 рік

Створимо динамічний графік ціни на акції за допомогою бібліотек Python (рис. 2.6, 2.7) [28].

```
def c_chart(data, label):
    # Thanks to https://www.kaggle.com/code/fangya/cryptocurrency-data-visualization-arma
    candlestick = go.Figure(data = [go.Candlestick(x=data.index,
                                                    open = data['open'],
                                                    high = data['high'],
                                                    low = data['low'],
                                                    close = data['close'])])

    candlestick.update_xaxes(title_text = 'Time',
                             rangelslider_visible = True)

    candlestick.update_layout(
        title = {
            'text': '{:} Candelstick Chart'.format(label),
            "y":0.8,
            "x":0.5,
            'xanchor': 'center',
            'yanchor': 'top'})

    candlestick.update_yaxes(title_text = 'Price in USD', ticksuffix = '$')
    return candlestick
```

Рисунок 2.6 – Функція побудови динамічного графіку




Рисунок 2.7 – Динамічний графік ціни на акції

Перевіримо дані на сезонність та побудуємо відповідні графіки, що зображено на рисунках 2.8 та 2.9.

```
result = seasonal_decompose(df['close'], model='additive', period=252) # 252 торгові дні у році
result.plot()

plt.show()
```

Рисунок 2.8 – Код візуалізації даних для розбиття на сезони




Рисунок 2.9 – Декомпозиція даних

Графіки декомпозиції часового ряду для цін закриття акцій:

1. Перший графік (вгорі) – відображає денні ціни закриття акцій протягом часу. Ви можете бачити загальний тренд зростання до середини періоду, потім зниження, і знову зростання ближче до кінця періоду.

2. Другий графік – показує тренд цін закриття, який було отримано за допомогою видалення сезонності та випадковостей із даних. Тренд зростає до 2018 року, після чого спостерігається зниження та стабілізація.

3. Третій графік – показує сезонні коливання в даних. Видно, що коливання мають досить регулярний характер, хоча і не виражені дуже сильно.

4. Четвертий графік (внизу) – відображає випадкові компоненти або "шум" даних, який залишається після вилучення тренду та сезонності. Ці залишки показують коливання, які не можна пояснити трендом чи сезонними факторами.

## 2.2 Відбір ознак для передбачення даних

Використаємо бібліотеку TSFRESH для створення нових ознак.

TSFRESH - це бібліотека для автоматичного виділення та екстракції ознак з часових рядів. Вона розроблена для вирішення задач машинного навчання, де вхідні дані є часовими рядами, наприклад, у сенсорних даних або в задачах моніторингу технічного стану.

Основні функції TSFRESH включають [28]:

1. TSFRESH може автоматично створювати великий набір статистичних ознак з часових рядів, таких як середнє значення, медіана, стандартне відхилення, автокореляція, та багато інших.

2. TSFRESH дозволяє використовувати додаткові знання про дані для налаштування процесу екстракції ознак.

3. Бібліотека підтримує роботу з різними типами часових рядів, включаючи часові ряди з однією змінною, мультизмінні часові ряди та декілька часових рядів.

4. Ознаки, що витягуються за допомогою TSFRESH, можуть бути використані як вхідні дані для класифікаційних та регресійних моделей машинного навчання.

|      | index_sum_values | index_abs_energy | index_median | index_mean | index_root_mean_square | index_maximum | index_absolute_maximum | index_minimum | index_benford_correlation | index_qu |
|------|------------------|------------------|--------------|------------|------------------------|---------------|------------------------|---------------|---------------------------|----------|
| 0    | 0.0              | 0.0              | 0.0          | 0.0        | 0.0                    | 0.0           | 0.0                    | 0.0           | NaN                       |          |
| 1    | 1.0              | 1.0              | 1.0          | 1.0        | 1.0                    | 1.0           | 1.0                    | 1.0           | 0.864123                  |          |
| 2    | 2.0              | 4.0              | 2.0          | 2.0        | 2.0                    | 2.0           | 2.0                    | 2.0           | 0.295657                  |          |
| 3    | 3.0              | 9.0              | 3.0          | 3.0        | 3.0                    | 3.0           | 3.0                    | 3.0           | 0.062915                  |          |
| 4    | 4.0              | 16.0             | 4.0          | 4.0        | 4.0                    | 4.0           | 4.0                    | 4.0           | -0.064614                 |          |
| ...  | ...              | ...              | ...          | ...        | ...                    | ...           | ...                    | ...           | ...                       | ...      |
| !511 | 2511.0           | 6305121.0        | 2511.0       | 2511.0     | 2511.0                 | 2511.0        | 2511.0                 | 2511.0        | 0.295657                  |          |
| !512 | 2512.0           | 6310144.0        | 2512.0       | 2512.0     | 2512.0                 | 2512.0        | 2512.0                 | 2512.0        | 0.295657                  |          |
| !513 | 2513.0           | 6315169.0        | 2513.0       | 2513.0     | 2513.0                 | 2513.0        | 2513.0                 | 2513.0        | 0.295657                  |          |
| !514 | 2514.0           | 6320196.0        | 2514.0       | 2514.0     | 2514.0                 | 2514.0        | 2514.0                 | 2514.0        | 0.295657                  |          |
| !515 | 2515.0           | 6325225.0        | 2515.0       | 2515.0     | 2515.0                 | 2515.0        | 2515.0                 | 2515.0        | 0.295657                  |          |

516 rows × 51 columns

Рисунок 2.10 – Результат роботи TSFRESH

Сформовано 51 нова ознака, які можна використати для тренування моделей прогнозування. Об'єднаємо основний та додатковий набори даних, результат на рисунку 2.11.

```
df = pd.merge(df, extracted_features_clean, how='left', on='date')
df
```

|      | date       | open       | high       | low        | close      | volume   | rsi_7     | rsi_14    | cci_7       |     |
|------|------------|------------|------------|------------|------------|----------|-----------|-----------|-------------|-----|
| 0    | 2014-01-02 | 52.401428  | 52.511429  | 51.542858  | 51.831429  | 12325600 | 34.729664 | 49.183584 | -89.573201  | -1. |
| 1    | 2014-01-03 | 52.000000  | 52.495712  | 51.842857  | 51.871429  | 10817100 | 35.587886 | 49.457208 | -65.820581  | -1. |
| 2    | 2014-01-06 | 51.889999  | 52.044285  | 50.475716  | 51.367142  | 15501500 | 29.820674 | 46.087900 | -121.472559 | -1. |
| 3    | 2014-01-07 | 49.684284  | 49.698570  | 48.152859  | 48.500000  | 36167600 | 14.371863 | 32.522091 | -206.762171 | -2. |
| 4    | 2014-01-08 | 48.104286  | 49.425713  | 48.074287  | 48.712856  | 20001100 | 18.049045 | 34.073549 | -117.836707 | -1. |
| ...  | ...        | ...        | ...        | ...        | ...        | ...      | ...       | ...       | ...         | ... |
| 2511 | 2023-12-22 | 494.000000 | 496.019989 | 485.450012 | 486.760010 | 2701100  | 61.286700 | 62.629263 | 42.406864   | ... |
| 2512 | 2023-12-26 | 489.390015 | 491.480011 | 486.380005 | 491.190002 | 2034500  | 65.324458 | 64.613544 | 31.476352   | ... |
| 2513 | 2023-12-27 | 491.239990 | 494.019989 | 489.250000 | 491.790009 | 2561300  | 65.886676 | 64.885498 | 54.412289   | ... |
| 2514 | 2023-12-28 | 492.000000 | 492.890015 | 489.070007 | 490.510010 | 1710500  | 63.331047 | 63.759744 | -14.020755  | ... |
| 2515 | 2023-12-29 | 490.369995 | 492.230011 | 481.940002 | 486.880005 | 2739500  | 56.127883 | 60.551251 | -157.815293 | ... |

2516 rows × 70 columns

Рисунок 2.11 – Результат об'єднання даних



Для перевірки точності моделей будемо прогнозувати ціну на акції в 2023 році. Для цього надані дані розділимо на два набори, перший з 2014 по 2022 рік та другий — 2023 рік (рис. 2.12).

```
split_date = pd.Timestamp('2022-12-31')
train = df[df['date'] < split_date]
test = df[df['date'] >= split_date]
```

Рисунок 2.12 – Розбиття на тренувальний та тестовий набір даних

## 2.3 Вибір моделей прогнозування ціни на акції

Вибір моделей машинного навчання для прогнозування цін на акції залежить від багатьох факторів, включаючи тип даних, масштаб задачі, доступні обчислювальні ресурси, та бажану точність. Ось деякі популярні моделі та техніки, які використовуються в аналізі фінансових ринків:

1. Лінійна регресія. Це одна з найпростіших і найбільш традиційних моделей для прогнозування. Вона добре працює, коли існує лінійний зв'язок між незалежними змінними та ціною акцій.

2. Лінійні моделі для часових рядів:

- ARIMA/SARIMA: Ефективні для даних, де важливі тренди та сезонність;
- Експоненціальне згладжування, добре підходить для даних з вираженою сезонністю;
- Prophet.

3. Моделі на основі дерев рішень:

- Random Forest та Gradient Boosting Machines (GBM) – потужні ансамблеві методи, які можуть враховувати нелінійність і взаємодії між змінними;

- XGBoost, LightGBM – ці моделі широко використовуються в індустрії завдяки своїй високій продуктивності та швидкості.

#### 4. Моделі на основі нейронних мереж:

- Штучні нейронні мережі (ANN) – гнучкі та потужні, можуть моделювати складні взаємозв'язки між вхідними змінними.

- Рекурентні нейронні мережі (RNN), особливо LSTM та GRU – ідеальні для моделювання секвенційних даних, які часто зустрічаються в фінансових часових рядах.

Для прогнозування ціни на акції компанії Netflix використаємо моделі Prophet, ARIMA та XGBoost.

## 2.4 Висновки

В другому розділі проведено розвідувальний аналіз ціни на акції компанії Netflix. Дані про ціну на акції перевірено на аномалії та викиди.

Проведено інженерію ознак. Використано TSFRESH для генерації нових ознак. Перевірено дані на аномалії та викиди. Визначено вплив ознак Open, High, Low на ознаку Close, що є цільовою.

Проаналізовано стандартні моделі машинного навчання для прогнозування ціни та обрано 3 моделі для виконання роботи, а саме Prophet, ARIMA та XGBoost.

### 3. РЕЗУЛЬТАТИ ПРОГНОЗУВАННЯ ЦІНИ НА АКЦІЇ

#### 3.1 Прогнозування моделлю Prophet

Для прогнозування ціни на акції використаємо бібліотеку Prophet. Для цього сформуємо новий набір даних який складається з дати та ціни закриття акції (рис. 3.1) [29].

```
df_p = df[['date', 'close']]
```

+ Code   + Markdown

```
df_p.rename(columns={'date': 'ds', 'close': 'y'}, inplace=True)
```

Рисунок 3.1 – Результат роботи коду

Наступним кроком натренуємо модель на основі наших даних, що зображено на рисунку 3.2.

```
model = Prophet()
|
model.fit(df_p)
```

```
16:23:25 - cmdstanpy - INFO - Chain [1] start processing
16:23:26 - cmdstanpy - INFO - Chain [1] done processing
<prophet.forecaster.Prophet at 0x7abc122fb580>
```

Рисунок 3.2 – Прогнозування ціни на акції

Для перевірки роботи моделі порівняємо дані за 2023 рік та зроблений прогноз (рис. 3.3) та зробимо оцінку точності роботи моделі за допомогою метрики RMSE та MAPE (рис. 3.4).




Рисунок 3.3 – Порівняння реальних та прогнозованих даних

```
rmse = np.sqrt(mean_squared_error(test_p['y'], forecast_t['yhat']))
mape = np.mean(np.abs((test_p['y'] - forecast_t['yhat']) / forecast_t['yhat'])) * 100
print("Root Mean Squared Error (RMSE):", rmse)
print(f"MAPE: {mape}%")
```

```
Root Mean Squared Error (RMSE): 69.36505993869258
MAPE: 16.556988081727265%
```

Рисунок 3.4 – Оцінка точності

Як видно з рисунку 3.4, точність моделі дуже низька і складає 16,6%. Отже потрібно провести тюнінг моделі Prophet та перевірити результат (рис 3.5).

Параметри, які можна тюнити:

- seasonality\_mode – вибір між "additive" та "multiplicative" сезонністю залежно від характеру даних.
- changepoint\_prior\_scale – регулювання гнучкості моделі для виявлення змін у тренді; більше значення веде до більш чутливої моделі.
- seasonality\_prior\_scale – Налаштування гнучкості сезонних компонентів.

– holidays\_prior\_scale – Впливає на ступінь впливу святкових днів на модель.

```
model1 = Prophet(
    daily_seasonality=True,
    weekly_seasonality=True,
    yearly_seasonality=True,
    changepoint_range=1,
    changepoint_prior_scale = 0.01,
    seasonality_mode = 'multiplicative'
)

# Додавання зовнішніх регресорів, якщо вони є
# model.add_regressor('additional_regressor')
model1.add_country_holidays(country_name='US')

# Навчання моделі
model1.fit(train_p)

# Створення майбутніх дат для прогнозування
future1 = model1.make_future_dataframe(periods=10, freq='D')

# Прогнозування
forecast1 = model1.predict(future1)

# Виведення результатів
print(forecast1[['ds', 'yhat', 'yhat_lower', 'yhat_upper']].tail())
```

```
20:09:10 - cmdstanpy - INFO - Chain [1] start processing
20:09:15 - cmdstanpy - INFO - Chain [1] done processing
```

|      | ds         | yhat       | yhat_lower | yhat_upper |
|------|------------|------------|------------|------------|
| 2511 | 2023-12-20 | 432.493369 | 403.300154 | 461.194184 |
| 2512 | 2023-12-21 | 433.492956 | 404.649510 | 463.621173 |
| 2513 | 2023-12-22 | 432.811235 | 401.061531 | 465.793047 |
| 2514 | 2023-12-23 | 364.062085 | 334.722477 | 393.966730 |
| 2515 | 2023-12-24 | 364.941586 | 333.087175 | 394.386197 |

Рисунок 3.5 – Оновлені параметри моделі Prophet

Для покращення результату період прогнозування зменшили з 365 днів до 10. За заданими параметрами проведемо навчання та побудуємо графік (рис. 3.6)




Рисунок 3.6 – Прогноз налаштованої моделі (розділити на тест та трейн)

Основні спостереження:

- Ціна акцій показує явний тренд на зростання протягом декількох років до 2020, після чого спостерігається волатильність із значними коливаннями;
- Прогноз на 2023-2024 роки показує тренд на відновлення після падіння, хоча з великою невизначеністю в довгостроковій перспективі.

Проведемо декомпозицію графіка та проаналізуємо його на рисунку 3.7.




Рисунок 3.7 – Декомпозиція графіка прогнозу на 10 днів

#### Тренд (Trend):

- Видно стабільне зростання з 2014 по 2020 рік;
- Після 2020 року спостерігається зниження, за яким слід швидке відновлення.

#### Тижнева сезонність (Weekly):

- Найменша активність (негативні значення) спостерігається у вихідні дні, що може відображати знижену торгівельну активність в ці дні;
- Відносно вищі значення в середу та четвер, що може вказувати на підвищену торгівельну активність.

Річна сезонність (Yearly):

- Видно циклічні коливання, з піками влітку та восени;
- Найнижчі точки спостерігаються взимку, що може вказувати на сезонні коливання в інвестиційній активності або корпоративних фінансових циклах.

Проведемо оцінку точності налаштованої моделі, що зображено на рисунку 3.8.

```
#Обрізання прогнозу до тестового періоду
forecast1 = forecast1[-10:]

# Розрахунок метрик
mse1 = mean_squared_error(test_p['y'], forecast1['yhat'])
rmse1 = np.sqrt(mse1)
mae1 = mean_absolute_error(test_p['y'], forecast1['yhat'])
mape1 = np.mean(np.abs((test_p['y'] - forecast1['yhat']) / test_p['y'])) * 100
#r2_score1 = round(r2_score(test_p['y'], forecast1['yhat']),2)
print(f'MSE: {mse1}')
print(f'RMSE: {rmse1}')
print(f'MAE: {mae1}')
print(f'MAPE: {mape1}%')
#print(f'r2_score: {r2_score1}')
```

MSE: 8343.503365145332  
 RMSE: 91.34277949102125  
 MAE: 84.08384661304396  
 MAPE: 17.19711349603453%

Рисунок 3.8 – Оцінку точності налаштованої моделі

– MSE (Mean Squared Error) = 8343.50. Це середньоквадратична помилка, яка вимірює середнє з квадратів відхилень прогнозованих значень від фактичних. Велике значення MSE вказує на потенційно великі помилки прогнозування.

– RMSE (Root Mean Squared Error) = 91.34. Це квадратний корінь з MSE, що дає помилку в оригінальних одиницях даних. RMSE є більш інтуїтивно зрозумілою мірою помилок прогнозування, оскільки вона в тих же одиницях, що й дані. Високе значення RMSE вказує на великі відхилення прогнозованих значень від фактичних.



– MAE (Mean Absolute Error) = 84.08. Це середнє абсолютне відхилення прогнозованих значень від фактичних. MAE надає пряме уявлення про середню помилку в абсолютних термінах. Як і RMSE, велике значення MAE вказує на значні помилки в прогнозах.

– MAPE (Mean Absolute Percentage Error) = 17.2%. Це середнє абсолютне відсоткове відхилення прогнозованих значень від фактичних. MAPE є важливим показником, оскільки він вимірює помилку як відсоток від фактичних значень, що дозволяє легше оцінити масштаб помилки у контексті даних. Відсоток близько 18% може бути прийнятним у деяких контекстах, але зазвичай вказує на можливість покращення моделі.

Отже, налаштування не дали значного покращення. Застосуємо автоматизацію підбору параметрів моделі Prophet.

Автоматизація налаштувань параметрів для моделі Prophet може значно покращити процес моделювання, забезпечуючи більш точні та надійні прогнози. Для цього використаємо бібліотеку `hyperopt`, яка дозволяє автоматично підбирати гіперпараметри за допомогою різних методів оптимізації, таких як "дерева пошукових алгоритмів" (TPE) (рис. 3.9).

```
# Функція для оптимізації
def objective(params):
    m = Prophet(
        changepoint_prior_scale=params['changepoint_prior_scale'],
        seasonality_prior_scale=params['seasonality_prior_scale'],
        holidays_prior_scale=params['holidays_prior_scale'],
        seasonality_mode=params['seasonality_mode']
    )
    m.fit(train_p)

    df_cv = cross_validation(m, initial='730 days', period='180 days', horizon = '365 days')
    df_p = performance_metrics(df_cv)
    rmse = df_p['rmse'].values[0]

    return {'loss': rmse, 'status': STATUS_OK}

# Простір параметрів
space = {
    'changepoint_prior_scale': hp.loguniform('changepoint_prior_scale', np.log(0.01), np.log(0.5)),
    'seasonality_prior_scale': hp.loguniform('seasonality_prior_scale', np.log(0.1), np.log(10)),
    'holidays_prior_scale': hp.loguniform('holidays_prior_scale', np.log(0.01), np.log(10)),
    'seasonality_mode': hp.choice('seasonality_mode', ['additive', 'multiplicative'])
}

# Запуск оптимізації
trials = Trials()
best = fmin(fn=objective, space=space, algo=tpe.suggest, max_evals=100, trials=trials)

print(best)
```

Рисунок 3.9 – Автоматизація оптимізації параметрів Prophet

Оцінимо точність налаштованої моделі на рисунку 3.10.

```
#Обрізання прогнозу до тестового періоду
forecast2 = forecast2[-10:]

# Розрахунок метрик
mse2 = mean_squared_error(test_p['y'], forecast2['yhat'])
rmse2 = np.sqrt(mse2)
mae2 = mean_absolute_error(test_p['y'], forecast2['yhat'])
mape2 = np.mean(np.abs((test_p['y'] - forecast2['yhat']) / test_p['y'])) * 100
#r2_score1 = round(r2_score(test_p['y'], forecast1['yhat']),2)
print(f'MSE: {mse2}')
print(f'RMSE: {rmse2}')
print(f'MAE: {mae2}')
print(f'MAPE: {mape2}%')
#print(f'r2_score: {r2_score1}')
```

MSE: 6004.911648278265  
 RMSE: 91.34277949102125  
 MAE: 77.27146258124796  
 MAPE: 15.817967214952905%

Рисунок 3.10 – Оцінка точності оптимізованої моделі Prophet

Оскільки точність моделі не підвищилась, можна зробити висновок, що дану модель для прогнозування цього часового ряду використовувати недоцільно.

### 3.2 Прогнозування моделлю ARIMA

Для порівняння методів створимо та натренуємо модель ARIMA. У статистиці та економетриці, і зокрема в аналізі часових рядів, модель авторегресійної інтегрованої ковзної середньої, ARIMA є узагальненням моделі авторегресійної ковзної середньої (ARIMA). Обидві ці моделі адаптуються до даних часових рядів або для кращого розуміння даних, або для прогнозування. Моделі ARIMA застосовуються в деяких випадках, коли дані демонструють докази нестационарності. Коли сезонність відображається в часовому ряді, можна застосувати сезонну різницю, щоб усунути сезонний компонент.

Для початку визначимо параметри  $p$ ,  $d$ ,  $q$  для моделі ARIMA:

–  $p$  — порядок авторегресії: Визначає кількість лагових термінів, які включаються в модель. Для його вибору можна використовувати часткову автокореляційну функцію (PACF).

–  $d$  — ступінь диференціювання: Визначає, скільки разів потрібно диференціювати часовий ряд, щоб зробити його стаціонарним. Це можна визначити, використовуючи тест Дікі-Фуллера на стаціонарність або спостерігаючи за характером ряду.

–  $q$  — порядок рухомого середнього: Визначає кількість лагових термінів помилок прогнозу, які включаються в модель. Для його вибору можна використовувати автокореляційну функцію (ACF).

Зазвичай починають з моделі ARIMA(0,0,0) та послідовно збільшують  $p$ ,  $d$ , і  $q$ , використовуючи критерії, такі як AIC (Akaike Information Criterion) чи BIC (Bayesian Information Criterion), для визначення найкращої моделі (рис.3.11).

```
from statsmodels.tsa.stattools import adfuller, acf, pacf
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf

# Завантаження даних

series = train_p['y']

# Перевірка на стаціонарність
result = adfuller(series)
print('ADF Statistic: %f' % result[0])
print('p-value: %f' % result[1])

# Якщо ряд нестационарний, можна диференціювати
if result[1] > 0.05:
    series = series.diff().dropna()

# Аналіз ACF та PACF
plot_acf(series)
plot_pacf(series)
plt.show()

# Встановлення значень p, d, q
p = 1 # Виберіть на основі PACF
d = 1 # 1 якщо було виконано диференціювання, інакше 0
q = 1 # Виберіть на основі ACF
```

ADF Statistic: -1.348610  
p-value: 0.606651

Рисунок 3.11 – Перевірка даних для налаштування параметрів моделі

При перевірці, отримали наступні дані ADF Statistic: -1.34, p-value: 0,6. Вони вказують на те, що ваш часовий ряд не є стаціонарним., що нульова гіпотеза про нестационарність часового ряду не відкидається. Це означає, що в часовому ряді ймовірно присутній тренд або сезонність, які потребують додаткової обробки перед використанням у прогнозних моделях. Графік автокореляційної функції (рис.3.12).




Рисунок 3.12 – Автокореляційна функція ряду

Графік автокореляції (ACF) показує, що відбувається згасання автокореляції з часом, що означає наявність можливого кореляційного зв'язку в часовому ряду на багатьох лагах. Однак, їх вплив зменшується зі збільшенням лагу.

Графік часткової автокореляції (PACF) показує стрибок на першому лагу, за яким слідує швидке згасання на наступних лагах. Це типова поведінка для процесу  $AR(1)$  – авторегресивної моделі першого порядку.

Вибір параметрів ARIMA:

Параметр  $p$ , значення 1 вказується як параметр  $p$  у моделі ARIMA, оскільки на PACF ми бачимо значущий пік на першому лагу;

Параметр  $d$ , для визначення параметра  $d$  (ступінь диференціювання), потрібно звернути увагу на результати тесту АДФ (Augmented Dickey-Fuller), які показують, що часовий ряд може бути нестационарним ( $p$ -значення  $0.66651 > 0.05$ ). Це може вказувати на необхідність виконання першого рівня диференціювання ( $d=1$ );

Параметр  $q$ , значення 0 для параметра  $q$  у моделі ARIMA, оскільки на ACF не бачимо значущих піків після лагу, що вказує на відсутність MA (Moving Average) компоненти.

Код реалізації ARIMA з параметрами (1,1,0) на рисунку 3.13.

```

from statsmodels.tsa.arima.model import ARIMA

#
# Вибір ряду даних
ts = train_p['y']

# Підгонка моделі ARIMA
model_ar = ARIMA(ts, order=(p, d, q)) # p - порядок авторегресії, d - ступінь інтеграції, q - порядок ру.
results = model_ar.fit()

# Прогнозування
preds = results.get_forecast(steps=10) # Прогноз на 10 кроків вперед
forecast_ar = preds.predicted_mean
conf_int = preds.conf_int()

# Візуалізація результатів
plt.figure(figsize=(10, 5))
plt.plot(ts[:200], label='Original')
plt.plot(forecast_ar, label='Forecast')
plt.fill_between(forecast_ar.index, conf_int.iloc[:, 0], conf_int.iloc[:, 1], color='pink', alpha=0.3)
plt.legend()
plt.show()

```

Рисунок 3.13 – Код ARIMA

Результат роботи моделі ARIMA на рисунку 3.14.




Рисунок 3.14 – Прогнозування ARIMA

Як видно з рисунка 3.14, точність моделі надто низька. Потрібно змінити параметри на потрібні. Використаємо AutoARIMA для налаштування параметрів моделі (рис.3.15).

```

model = auto_arima(series, start_p=0, start_q=0, max_p=5, max_q=5, seasonal=False,
                  stepwise=True, suppress_warnings=True, error_action="ignore", trace=True)

# Найкращі параметри від auto_arima
print("Найкращі параметри:")
print(model.get_params())

# Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,0,0)[0] intercept : AIC=17863.232, Time=0.06 sec
ARIMA(1,1,0)(0,0,0)[0] intercept : AIC=17863.332, Time=0.15 sec
ARIMA(0,1,1)(0,0,0)[0] intercept : AIC=17863.400, Time=0.25 sec
ARIMA(0,1,0)(0,0,0)[0] : AIC=17862.186, Time=0.04 sec
ARIMA(1,1,1)(0,0,0)[0] intercept : AIC=17864.304, Time=0.80 sec

Best model: ARIMA(0,1,0)(0,0,0)[0]
Total fit time: 1.310 seconds
Найкращі параметри:
{'maxiter': 50, 'method': 'lbfgs', 'order': (0, 1, 0), 'out_of_sample': False}

```

Рисунок 3.15 – Налаштування моделі за допомогою AutoARIMA

Застосуємо найкращі параметри до моделі ARIMA та побудуємо графік прогнозування на рисунку 3.16.




Рисунок 3.16 – Використання ARIMA з найкращими параметрами

Проаналізувавши графік, можна зробити висновок, що модель має велику похибку та не може використовуватись для прогнозування ціни на акції

### 3.3 Прогнозування моделлю XGBoost

Оскільки попередні моделі не дали позитивного результату використаємо модель градієнтного бустингу XGBoost.

Створимо тренувальний та тестовий набори даних за допомогою `train_test_split` (рис. 3.17).

```
from sklearn.model_selection import train_test_split
X = df.drop(['close', 'date'], axis=1)
y = df['close']
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
```

Рисунок 3.17 – Створення тренувального та тестового наборів даних

X – це ознаки, що характеризують цільову ознаку `close`. А y – це досліджувана функція. Розділимо дані на два набори тренувальний та тестовий з коефіцієнтом поділу 0,2 – це означає, що тренувальний набір даних містить 80% даних. Відповідно тренувальний містить 20% даних.

Переглянемо дані для моделі (рис. 3.18). Дані складаються зі 68 колонок. Всі ознаки мають числовий тип даних.



Data columns (total 68 columns):

| #  | Column                     | Non-Null Count | Dtype   |
|----|----------------------------|----------------|---------|
| 0  | open                       | 2516 non-null  | float64 |
| 1  | high                       | 2516 non-null  | float64 |
| 2  | low                        | 2516 non-null  | float64 |
| 3  | volume                     | 2516 non-null  | int64   |
| 4  | rsi_7                      | 2516 non-null  | float64 |
| 5  | rsi_14                     | 2516 non-null  | float64 |
| 6  | cci_7                      | 2516 non-null  | float64 |
| 7  | cci_14                     | 2516 non-null  | float64 |
| 8  | sma_50                     | 2516 non-null  | float64 |
| 9  | ema_50                     | 2516 non-null  | float64 |
| 10 | sma_100                    | 2516 non-null  | float64 |
| 11 | ema_100                    | 2516 non-null  | float64 |
| 12 | macd                       | 2516 non-null  | float64 |
| 13 | bollinger                  | 2516 non-null  | float64 |
| 14 | TrueRange                  | 2516 non-null  | float64 |
| 15 | atr_7                      | 2516 non-null  | float64 |
| 16 | atr_14                     | 2516 non-null  | float64 |
| 17 | next_day_close             | 2516 non-null  | float64 |
| 18 | index__sum_values          | 2516 non-null  | float64 |
| 19 | index__abs_energy          | 2516 non-null  | float64 |
| 20 | index__median              | 2516 non-null  | float64 |
| 21 | index__mean                | 2516 non-null  | float64 |
| 22 | index__root_mean_square    | 2516 non-null  | float64 |
| 23 | index__maximum             | 2516 non-null  | float64 |
| 24 | index__absolute_maximum    | 2516 non-null  | float64 |
| 25 | index__minimum             | 2516 non-null  | float64 |
| 26 | index__benford_correlation | 2515 non-null  | float64 |
| 27 | index__quantile__q_0.1     | 2516 non-null  | float64 |
| 28 | index__quantile__q_0.2     | 2516 non-null  | float64 |
| 29 | index__quantile__q_0.3     | 2516 non-null  | float64 |
| 30 | index__quantile__q_0.4     | 2516 non-null  | float64 |
| 31 | index__quantile__q_0.6     | 2516 non-null  | float64 |
| 32 | index__quantile__q_0.7     | 2516 non-null  | float64 |
| 33 | index__quantile__q_0.8     | 2516 non-null  | float64 |

Рисунок 3.18 – Інформація про дані

Для автоматизації підбору даних використаємо GridSearchCV. Використання GridSearchCV з бібліотеки scikit-learn для автоматизації підбору параметрів моделі є чудовим способом оптимізувати моделі машинного навчання. GridSearchCV систематично перевіряє комбінації параметрів, задані у вигляді сітки, і використовує перехресну валідацію для визначення найкращих значень параметрів для моделі.

На рисунку 3.19 зображена модель XGBoost з параметрами для GridSearchCV.

```

param_grid = {
    'n_estimators': [50, 100, 150 ],
    'max_depth': [3, 5, 7],
    'learning_rate': [0.01]
}
model = xgb.XGBRegressor(objective ='reg:squarederror')

grid_search = GridSearchCV(estimator=model, param_grid=param_grid,

# Запуск grid search
grid_search.fit(X_train, y_train)
best_model = grid_search.best_estimator_

```

Рисунок 3.19 – модель XGBoost з параметрами для GridSearchCV

Застосуємо натреновану модель на тренувальних даних та оцінимо натреновану модель відповідними метриками (рис. 3.20).

```

y_pred_gb = best_model.predict(X_train)
mse = mean_squared_error(y_pred_gb, y_train)
mae = mean_absolute_error(y_pred_gb, y_train)
r2 = r2_score(y_pred_gb, y_train)
# Виведення результатів
print(f"Mean Squared Error: {mse:.2f}")
print(f"Mean Absolute Error: {mae:.2f}")
print(f"R-squared Score: {r2:.2f}")

```

Mean Squared Error: 1395.26

Mean Absolute Error: 32.13

R-squared Score: 0.91

Рисунок 3.20 – Оцінка моделі XGBoost

Mean Squared Error (MSE) = 1395.26. Високе значення MSE може вказувати на великі відхилення прогнозів від фактичних даних, особливо при роботі з великими числами.

Mean Absolute Error (MAE) = 32.13. Значення 32.13 може бути хорошим або поганим в залежності від контексту даних і масштабу значень у датасеті.

$R^2 = 0.91$ . Значення 0.91 є дуже високим, що вказує на те, що модель дуже добре пояснює варіацію даних. Це вказує на високу якість моделі.

Застосуємо натреновану модель на тестових даних. На рисунку 3.21 зображено прогнозування на тестових даних та оцінка точності моделі.

```
y_pred = best_model.predict(X_test)
mse_t = mean_squared_error(y_pred, y_test)
mae_t = mean_absolute_error(y_pred, y_test)
r2_t = r2_score(y_pred, y_test)
# Виведення результатів
print(f"Mean Squared Error: {mse_t:.2f}")
print(f"Mean Absolute Error: {mae_t:.2f}")
print(f"R-squared Score: {r2_t:.2f}")
```

Mean Squared Error: 1478.05

Mean Absolute Error: 33.40

R-squared Score: 0.91

Рисунка 3.21 – Оцінка точності на тестових даних

Оскільки точність моделі не має високої різниці між тренувальним та тестовим наборами даних, можна зробити висновок, що модель навчилася нормально та є адекватною.

Побудуємо графік важливості ознак на рисунку 3.22, 3.23.

```
fig = plt.figure(figsize = (10,8))
axes = fig.add_subplot(111)
xgb.plot_importance(best_model,ax = axes,height = 0.5)
plt.show();
plt.close()
```

Рисунок 3.22 – Код графіка важливості ознак




Рисунок 3.23 – Графік важливості ознак

Ознаки та їх F-бали:

- close\_sum\_values, значення 3464.0 — це найбільший внесок, що може свідчити про те, що сума значень закриття (можливо, за певний період) є дуже значущим індикатором для моделі;
- low, значення 149.0 — наступна за значенням ознака, що вказує на те, що мінімальні ціни в ряду також мають великий вплив на прогноз;

- high, значення 129.0 — високі ціни також важливі, але трохи менше, ніж низькі;
- open, значення 94.0 — ціни відкриття також відіграють роль, але вже менш важливу;
- rsi\_7, значення 55.0 — індекс відносної сили за 7 днів вказує на важливість моментуму у моделі;
- volume, значення 36.0 — обсяги торгівлі мають деяку, але невелику значимість;
- close\_benford\_correlation, next\_day\_close, cci\_7, sma\_50, index\_sum\_values, macd, atr\_7 — ці ознаки мають нижчі значення F-балів, що вказує на їх меншу важливість у моделі.

На рисунку 3.24 відобразимо графік прогнозованих та реальних даних.




Рисунок 3.24 – Графік прогнозованих та реальних даних

На графіку ви відобразили реальні та прогнозовані дані, де реальні дані позначені синіми крапками, а прогнозовані — червоними хрестиками. Цей графік дозволяє оцінити точність моделі шляхом візуального порівняння між

реальними значеннями та їхніми прогнозами на одному графіку. Ось деякі спостереження та аналіз:

- Розподіл даних. Видно, що реальні дані (сині крапки) та прогнозовані дані (червоні хрестики) охоплюють подібні діапазони значень, проте є помітні відмінності в їх розміщенні по осі у;
- Згущення значень. Червоні хрестики, як правило, здаються менш розсіяними, ніж сині крапки, що може вказувати на меншу варіативність у прогнозах порівняно з реальними даними;
- Високі та низькі значення. Здається, що модель може недооцінювати піки та недооцінювати провали, особливо в крайніх значеннях.

На рисунку 3.25 зображена порівняльна таблиця точності результатів прогнозування ціни на акції Netflix.

|   | Model   | Точність на тренувальних даних MSE | Точність на тестових даних MSE | Точність на тренувальних даних MAE | Точність на тестових даних MAE | Точність на тренувальних даних R2 | Точність на тестових даних R2 |
|---|---------|------------------------------------|--------------------------------|------------------------------------|--------------------------------|-----------------------------------|-------------------------------|
| 0 | Prophet | 2698.335730                        | 3646.411677                    | 32.475711                          | 58.689257                      | 0.900000                          | -101.710000                   |
| 1 | ARIMA   | 74.150846                          | 370.064045                     | 5.042152                           | 18.291012                      | 0.997298                          | -9.423483                     |
| 2 | XGBoost | 1395.255825                        | 1478.054292                    | 32.134727                          | 33.397530                      | 0.910000                          | 0.910000                      |

Рисунок 3.25 – Таблиця точності моделей прогнозування ціни акцій Netflix

### 3.4 Висновки

В третьому розділі використано три моделі прогнозування даних, а саме Prophet, ARIMA та XGBoost. Проведено оптимізацію та автоматизацію підбору параметрів відповідних моделей прогнозування ціни на акції.

При оцінюванні моделей прогнозування даних, модель Prophet та ARIMA показали низьку точність за метрикою R2\_score.

На відміну від моделей Prophet та ARIMA, XGBoost має точність 0,91.

За результатами оцінки важливості ознак визначено, що найбільший вплив має ознака close\_sum\_values.

Отже модель XGBoost обрана, як найкраща модель для прогнозування ціни на акції компанії Netflix.

## ВИСНОВКИ

В першому розділі проаналізовано загальну тематику стрімінгових сервісів. Проведено порівняльний аналіз популярних стрімінгів у світі, таких як Netflix, Amazon Prime Video, Disney+. За даними аналізу найбільш популярний стрімінг це Netflix.

Розглянуто процес ціноутворення акцій стрімінгових сервісів. Визначено основні характеристики за якими може утворюватися ціна акцій, а саме фінансові показники компанії, рівень підписників, конкуренція, новини та події, макроекономічні фактори, аналітичні оцінки та рекомендації інсайдерська інформація.

Проведено огляд основних підходів до аналізу та прогнозуванню ціни на акції Netflix в Kaggle Notebooks:

- «Time-Series-Analysis-Netflix-Stock-Price»,
- «Garch 1»,
- «XGboost: Predict "next\_day\_close"»,
- «Very Simple Prediction of Next Day Stock (99.76%)».

В даних підходах використано методи ARIMA, Garch, XGboost та лінійна регресія.

В другому розділі проведено розвідувальний аналіз ціни на акції компанії Netflix. Дані про ціну на акції перевірено на аномалії та викиди.

Проведено інженерію ознак. Використано TSFRESH для генерації нових ознак. Перевірено дані на аномалії та викиди. Визначено вплив ознак Open, High, Low на ознаку Close, що є цільовою.

Проаналізовано стандартні моделі машинного навчання для прогнозування ціни та обрано 3 моделі для виконання роботи, а саме Prophet, ARIMA та XGBoost.

В третьому розділі використано три моделі прогнозування даних, а саме Prophet, ARIMA та XGBoost. Проведено оптимізацію та автоматизацію підбору параметрів відповідних моделей прогнозування ціни на акції.

При оцінюванні моделей прогнозування даних, модель Prophet та ARIMA показали низьку точність за метрикою  $R^2\_score$ .

На відміну від моделей Prophet та ARIMA, XGBoost має точність 0,91.

За результатами оцінки важливості ознак визначено, що найбільший вплив має ознака `close_sum_values`.

Отже модель XGBoost обрано, як найкращу модель для прогнозування ціни на акції компанії Netflix.

Бакалаврська дипломна робота виконана в повному обсязі.



## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Netflix. (н.д.). Офіційний сайт. URL: <https://www.netflix.com>
2. Amazon Prime Video. (н.д.). Офіційний сайт. URL: <https://www.primevideo.com>
3. Disney+. (н.д.). Офіційний сайт. URL: <https://www.disneyplus.com>
4. HBO Max. (н.д.). Офіційний сайт. URL: <https://www.hbomax.com>
5. Kaggle Notebook «Time-Series-Analysis-Netflix-Stock-Price». URL: <https://www.kaggle.com/code/lydia70/time-series-analysis-netflix-stock-price>
6. Kaggle Notebook «Garch 1». URL: <https://www.kaggle.com/code/kkimiraik/garch-1>
7. Kaggle Notebook «XGboost: Predict "next\_day\_close"». URL: <https://www.kaggle.com/code/lko9911/xgboost-predict-next-day-close>
8. Kaggle Notebook «Very Simple Prediction of Next Day Stock (99.76%)». URL: <https://www.kaggle.com/code/queenlover/very-simple-prediction-of-next-day-stock-99-76>
9. Yun, K.K., Yoon, S.W., & Won, D. (2021). Prediction of stock price direction using a hybrid GA-XGBoost algorithm with a three-stage feature engineering process. *Expert Systems with Applications*, 186, 115716. DOI : <https://doi.org/10.1016/j.eswa.2021.115716>
10. Lahmiri, S. (2016). A variational mode decomposition approach for analysis and forecasting of economic and financial time series. *Expert Systems with Applications*, 55, 268-273. DOI: <https://doi.org/10.1016/j.eswa.2016.02.025>
- Siarni-Namini, S. (2017). A Comparative Analysis of Forecasting Financial Time Series Using ARIMA, LSTM, and BiLSTM. *International Journal of Economics and Financial Issues*, 7(4), 603-607. DOI : <https://doi.org/10.48550/arXiv.1911.09512>
11. He, F.(Eric), Feng, Y., & Hao, J. (2022). Information disclosure source, investors' searching and stock price crash risk. *Economics Letters*, 210, 110202. DOI : <https://doi.org/10.1016/j.econlet.2021.110202>

12. Razavi Hajiagha, S.H., & Farahani, M.S. (Comparison Year Not Specified). Forecasting stock price using integrated artificial neural network and metaheuristic algorithms compared to time series models. DOI : <https://doi.org/10.1007/s00500-021-05775-5>
13. He, M., Zhang, Y., & Li, S. (2023). Geopolitical risk and stock market volatility: A global perspective. *Finance Research Letters*, 53, 103620. DOI: <https://doi.org/10.1016/j.frl.2022.103620>
14. Kim, H.Y., & Won, C.H. (2018). Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models. *Expert Systems with Applications*, 103, 25-37. DOI: <https://doi.org/10.1016/j.eswa.2018.03.002>
15. Kannianen, J., Iosifidis, A., Tran, D.T., & Gabbouj, M. (2018). Temporal attention-augmented bilinear network for financial time-series data analysis. *IEEE Transactions on Neural Networks and Learning Systems*, 30(5), 1407-1418. DOI : <https://doi.org/10.1109/TNNLS.2018.2869225>
- Taylor, S., Areal, N.M.P.C., & Taylor, S.J. (1994). The realized volatility of FTSE-100 futures prices. *Journal of Financial and Quantitative Analysis*, 29(01), 57-74. DOI : <https://doi.org/10.1002/fut.10018>
16. Degiannakis, S., & Filis, G. (2017). Forecasting oil price realized volatility using information channels from other asset classes. *Journal of International Money and Finance*, 76, 28-49. DOI : <https://doi.org/10.1016/j.jimonfin.2017.05.006>
17. Khashei, M., & Hajirahimi, Z. (2019). A comparative study of series ARIMA/MLP hybrid models for stock price forecasting. *Communications in Statistics-Simulation and Computation*, 48(9), 2625-2640. DOI: <https://doi.org/10.1080/03610918.2018.1458138>
18. Zheng, T., Weng, Q., & Liu, R. (2022). Forecasting Tesla's Stock Price Using the ARIMA Model. *Proceedings of Business and Economic Studies*, 5(5), 38-45. DOI: <https://doi.org/10.26689/pbes.v5i5.4331>

19. Wang, Y., Wei, Y., Zhang, J., & Bai, L. (2023). Time-and frequency-domain evidence based on TVP-VAR model. *Renewable Energy*. DOI: <https://doi.org/10.1016/j.renene.2022.11.098>
20. Esfahanipour, A., Khodaei, P., & Taheri, H.M. (2016). Forecasting turning points in stock price by applying a novel hybrid CNN-LSTM-ResNet model fed by 2D segmented images. *Neural Computing and Applications*, 27, 651-658. DOI: <https://doi.org/10.1016/j.engappai.2022.105464>
21. Iosifidis, A., Ntakaris, M., Magris, M., Kannianen, J., & Gabbouj, M. (2018). Forecasting stock prices from the limit order book using convolutional neural networks. *Journal of Forecasting*, 37(8), 852-866. DOI: <https://doi.org/10.1109/CBI.2017.23>
22. Dutta, A., Sen, J., Mehtab, S., & Mondal, S. (2021). Precise Stock Price Prediction for Robust and Optimized Portfolio Design Using an LSTM Model. URL : [https://www.researchgate.net/profile/Jaydip-Sen-3/publication/355339185\\_Precise\\_Stock\\_Price\\_Prediction\\_for\\_Robust\\_and\\_Optimized\\_Portfolio\\_Design\\_Using\\_an\\_LSTM\\_Model\\_-\\_Presentation/links/61726ae7435dab3b7594bcaa/Precise-Stock-Price-Prediction-for-Robust-and-Optimized-Portfolio-Design-Using-an-LSTM-Model-Presentation.pdf](https://www.researchgate.net/profile/Jaydip-Sen-3/publication/355339185_Precise_Stock_Price_Prediction_for_Robust_and_Optimized_Portfolio_Design_Using_an_LSTM_Model_-_Presentation/links/61726ae7435dab3b7594bcaa/Precise-Stock-Price-Prediction-for-Robust-and-Optimized-Portfolio-Design-Using-an-LSTM-Model-Presentation.pdf)
23. Kaggle dataset «Netflix Stock Price With Indicators» URL: <https://www.kaggle.com/datasets/aspillai/netflix-stock-price-with-indicators>
24. Mokin V.B. Notebook «crypto–btc advanced analysis forecasting» URL: <https://www.kaggle.com/code/vbmokin/crypto-btc-advanced-analysis-forecasting>
25. В. Б. Мокін, А. В. Лосенко, і М. В. Дратований, «Інтелектуальна технологія аналізу та передбачення цін на вживані автомобілі», *Вісник ВПІ*, вип. 6, с. 62–72, Груд. 2019.

Додаток А  
(обов'язковий)

Міністерство освіти і науки України  
Вінницький національний технічний університет  
Факультет інтелектуальних інформаційних технологій та автоматизації

ЗАТВЕРДЖУЮ

Завідувач кафедри САІТ

\_\_\_\_\_ д.т.н., проф. Віталій МОКІН

« \_\_\_\_ » \_\_\_\_\_ 2024 р.

ТЕХНІЧНЕ ЗАВДАННЯ

на бакалаврську дипломну роботу

АНАЛІЗ ТА ПРОГНОЗУВАННЯ ЦІНИ НА АКЦІЇ NETFLIX

08-34.БДР.003.00.000 ТЗ

Керівник: к.т.н., доц.

\_\_\_\_\_ Ілона ВАРЧУК

« \_\_ » \_\_\_\_\_ 2024 р.

Розробив студент гр. СА-206

\_\_\_\_\_ Вадим РУДИК

« \_\_ » \_\_\_\_\_ 2024 р.

Вінниця 2024

### 1. Підстава для проведення робіт.

Підставою для виконання роботи є наказ №\_\_ по ВНТУ від «\_\_» \_\_\_\_\_2024р., та індивідуальне завдання на БДР, затверджене протоколом №\_\_ засідання кафедри САІТ від «\_\_» \_\_\_\_\_ 2024р.

### 2. Джерела розробки: (зі списку літератури)

1) Mokin V.B. Notebook «crypto–btc advanced analysis forecasting» URL: <https://www.kaggle.com/code/vbmokin/crypto-btc-advanced-analysis-forecasting>

2) В. Б. Мокін, А. В. Лосенко, і М. В. Дратований, «Інтелектуальна технологія аналізу та передбачення цін на вживані автомобілі», *Вісник ВПІ*, вип. 6, с. 62–72, Груд. 2019.

3) Kaggle Notebook «XGboost: Predict "next\_day\_close"». URL: <https://www.kaggle.com/code/lko9911/xgboost-predict-next-day-close>

### 3. Мета і призначення роботи.

Метою дослідження є аналіз та прогнозування ціни акцій Netflix

### 4. Вихідні дані для проведення робіт:

Kaggle Dataset «Netflix Stock Price With Indicators» <https://www.kaggle.com/datasets/aspillai/netflix-stock-price-with-indicators>.

### 5. Методи дослідження:

Моделі машинного навчання, мова програмування Python.

### 6. Етапи роботи і терміни їх виконання:

а) Аналіз предметної області \_\_\_\_\_ – \_\_\_\_\_

б) Порівняльний аналіз проблематики \_\_\_\_\_ – \_\_\_\_\_

в) Порівняльний аналіз методів прогнозування ціни акцій \_\_\_\_\_ – \_\_\_\_\_

г) Розвідувальний аналіз даних та інженерія ознак \_\_\_\_\_ – \_\_\_\_\_

д) Прогнозування ціни на акції Netflix \_\_\_\_\_ – \_\_\_\_\_

е) Оформлення матеріалів до захисту БДР \_\_\_\_\_ – \_\_\_\_\_

### 7. Очікувані результати та порядок реалізації

Отримання оптимальної моделі машинного навчання для прогнозування ціни на акції Netflix.

### 8. Вимоги до розробленої документації

Текстова та ілюстративна частини роботи оформлені у відповідності до вимог «Методичних вказівок до виконання бакалаврських кваліфікаційних робіт для студентів спеціальностей: 124 «Системний аналіз», 126 «Інформаційні системи та технології» (освітня програма «Прикладні інформаційні технології»).

### 9. Порядок приймання роботи

Публічний захист «\_\_» \_\_\_\_\_ 2024 р.

Початок розробки «\_\_» \_\_\_\_\_ 2024 р.

Граничні терміни виконання БДР «\_\_» \_\_\_\_\_ 2024 р.

Розробив студент гр. СА-206 \_\_\_\_\_

Вадим РУДИК

## Додаток Б

(обов'язковий)

## Протокол перевірки бакалаврської дипломної роботи на наявність текстових запозичень

Назва роботи: «Аналіз та прогнозування ціни на акції Netflix»Тип роботи: бакалаврська дипломна роботаПідрозділ: кафедра САІТ

## Показники звіту подібності Unichек

Оригінальність 97,1Схожість 2,9

Аналіз звіту подібності (відмітити потрібне)

- Запозичення, виявлені у роботі, оформлені коректно і не містять ознак плагіату.
  - Виявлені у роботі запозичення не мають ознак плагіату, але їх надмірна кількість викликає сумніви щодо цінності роботи і самостійності її автора. Роботу направити на розгляд експертної комісії кафедри.
  - Виявлені у роботі запозичення є недобросовісними і мають ознаки плагіату та/або в ній містяться навмисні спотворення тексту, що вказують на спроби приховування недобросовісних запозичень.


Особа, відповідальна за перевірку

  
(підпис)

Сергій ЖУКОВ


Ознайомлені з повним звітом подібності, який був згенерований системою Unichек щодо роботи.

Автор роботи

  
(підпис)

Вадим РУДИК

Керівник роботи

  
(підпис)

Ілона ВАРЧУК

## Додаток В

### (довідниковий)

### Фрагмент лістингу програми

```

import numpy as np # linear algebra
import pandas as pd # data processing, CSV file I/O (e.g. pd.read_csv)

# Input data files are available in the read-only "../input/" directory
# For example, running this (by clicking run or pressing Shift+Enter) will list all files under the input directory
from sklearn.metrics import mean_squared_error, mean_absolute_error
import os
for dirname, _, filenames in os.walk('/kaggle/input'):
    for filename in filenames:
        print(os.path.join(dirname, filename))

# You can write up to 20GB to the current directory (/kaggle/working/) that gets preserved as output when you create a
version using "Save & Run All"
# You can also write temporary files to /kaggle/temp/, but they won't be saved outside of the current session

# Import libraries
import random
import os
import numpy as np
import pandas as pd
import requests
import pandas_datareader as web

# Date
import datetime as dt
from datetime import date, timedelta, datetime

# EDA
import matplotlib.pyplot as plt
from matplotlib.pylab import rcParams
import plotly.express as px
import plotly.graph_objects as go
from plotly.offline import init_notebook_mode
init_notebook_mode(connected=True)

# FE
from tsfresh import extract_features, select_features, extract_relevant_features
from tsfresh.utilities.dataframe_functions import impute
from sklearn.inspection import permutation_importance
import eli5
from eli5.sklearn import PermutationImportance
import shap

# Time Series - EDA and Modelling
import statsmodels.api as sm
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf
from statsmodels.tsa.stattools import adfuller
from statsmodels.tsa.seasonal import seasonal_decompose
from statsmodels.tsa.arima_model import ARIMA

# Metrics
from sklearn.metrics import r2_score
from sklearn.metrics import mean_squared_error, mean_absolute_percentage_error
from sklearn.metrics import mean_absolute_error

```

```

# Modeling and preprocessing
from sklearn.preprocessing import StandardScaler, MinMaxScaler
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.linear_model import LinearRegression
from sklearn.svm import SVR, LinearSVR
from sklearn.neighbors import KNeighborsRegressor
from sklearn.ensemble import RandomForestRegressor
from sklearn.ensemble import BaggingRegressor, AdaBoostRegressor
from sklearn.neural_network import MLPRegressor
from prophet import Prophet
import xgboost as xgb
from xgboost import XGBRegressor
import lightgbm as lgb
from lightgbm import LGBMRegressor

import warnings
warnings.filterwarnings("ignore")

df = pd.read_csv('/kaggle/input/netflix-stock-price-with-indicators/nflx_2014_2023.csv')
df['date'] = pd.to_datetime(df['date'])
df.set_index('date', inplace=True)
df.head()

df.tail()

df.info()

df.describe()

df['close'].plot(grid=True, figsize=(12,8))

def c_chart(data,label):
    # Thanks to https://www.kaggle.com/code/fangya/cryptocurrency-data-visualization-arima
    candlestick = go.Figure(data = [go.Candlestick(x=data.index,
                                                    open = data['open'],
                                                    high = data['high'],
                                                    low = data['low'],
                                                    close = data['close'])])
    candlestick.update_xaxes(title_text = 'Time',
                             rangelslider_visible = True)

    candlestick.update_layout(
        title = {
            'text': '{:} Candelstick Chart'.format(label),
            "y":0.8,
            "x":0.5,
            'xanchor': 'center',
            'yanchor': 'top'})

    candlestick.update_yaxes(title_text = 'Price in USD', ticksuffix = '$')
    return candlestick

%matplotlib inline
netflix_price=c_chart(df, label="Netflix Price")
netflix_price.show()

result = seasonal_decompose(df['close'], model='additive', period=252) # 252 торгові дні у році

fig = result.plot()
fig.set_size_inches((12, 10))
fig.tight_layout()
plt.show()

```



```

df1=df

df1['close'].plot()

def get_tsfresh_features(data):
    # Get statistic features using library TSFRESH
    # Thanks to https://www.kaggle.com/code/vbmokin/btc-growth-forecasting-with-advanced-fe-for-ohlcv

    data = data.reset_index(drop=False).reset_index(drop=False)

    # Extract features
    extracted_features = extract_features(data, column_id="date", column_sort="date")

    # Drop features with NaN
    extracted_features_clean = extracted_features.dropna(axis=1, how='all').reset_index(drop=True)

    # Drop features with constants
    cols_std_zero = []
    for col in extracted_features_clean.columns:
        if extracted_features_clean[col].std()==0:
            cols_std_zero.append(col)
    extracted_features_clean = extracted_features_clean.drop(columns = cols_std_zero)

    extracted_features_clean['date'] = data['date'] # For the merging

    return extracted_features_clean

extracted_features_clean = get_tsfresh_features(df1['close'])
extracted_features_clean

df = pd.merge(df, extracted_features_clean, how='left', on='date')
df

def check_stationarity(series):
    # Thanks to https://machinelearningmastery.com/time-series-data-stationary-python/

    result = adfuller(series.values)

    print('ADF Statistic: %f % result[0])
    print('p-value: %f % result[1])
    print('Critical Values:')
    for key, value in result[4].items():
        print('\t%s: %.3f % (key, value))

    if (result[1] <= 0.05) & (result[4]['5%'] > result[0]):
        print("\u001b[32mStationary\u001b[0m")
    else:
        print("\x1b[31mNon-stationary\x1b[0m")

check_stationarity(df1['close'])

check_stationarity(df1['close'].diff().dropna())

df1 = df[['date','close']]

df1.rename(columns={'date': 'ds', 'close': 'y'}, inplace=True)

train_p = df1.iloc[:-10] # Всі дані крім останніх 10 днів
test_p = df1.iloc[-10:] # Останні 10 днів

model = Prophet()

model.fit(train_p)

```

```

futue = model.make_future_dataframe(periods=10) # For example, predict the next 365 days
forecast = model.predict(future)

# Plot the forecast
fig = model.plot(forecast)
fig2 = model.plot_components(forecast)

#Обрізання прогнозу до тестового періоду
forecast = forecast[-10:]

# Розрахунок метрик
mse = mean_squared_error(test_p['y'], forecast['yhat'])
rmse = np.sqrt(mse)
mae = mean_absolute_error(test_p['y'], forecast['yhat'])
mape = np.mean(np.abs((test_p['y'] - forecast['yhat']) / test_p['y'])) * 100
r2_score_p = r2_score(test_p['y'], forecast['yhat'])
print(f'MSE: {mse}')
print(f'RMSE: {rmse}')
print(f'MAE: {mae}')
print(f'MAPE: {mape}%')
print(f'r2_score_p: {r2_score_p}')

model1 = Prophet(
    daily_seasonality=True,
    weekly_seasonality=True,
    yearly_seasonality=True,
    changepoint_range=1,
    changepoint_prior_scale = 0.01,
    seasonality_mode = 'multiplicative'
)

# Додавання зовнішніх регресорів, якщо вони є
# model.add_regressor('additional_regressor')
model1.add_country_holidays(country_name='US')

# Навчання моделі
model1.fit(train_p)

# Створення майбутніх дат для прогнозування
future1 = model1.make_future_dataframe(periods=10, freq='D')

# Прогнозування
forecast1 = model1.predict(future1)

# Виведення результатів
print(forecast1[['ds', 'yhat', 'yhat_lower', 'yhat_upper']].tail())

# Plot the forecast
fig = model.plot(forecast1)
fig2 = model.plot_components(forecast1)

# %% [code]

#Обрізання прогнозу до тестового періоду
forecast1 = forecast1[-10:]
# Розрахунок метрик
mse1 = mean_squared_error(test_p['y'], forecast1['yhat'])
rmse1 = np.sqrt(mse1)
mae1 = mean_absolute_error(test_p['y'], forecast1['yhat'])
mape1 = np.mean(np.abs((test_p['y'] - forecast1['yhat']) / test_p['y'])) * 100
r2_score1 = round(r2_score(test_p['y'], forecast1['yhat']),2)
print(f'MSE: {mse1}')
print(f'RMSE: {rmse1}')

```

```

print(f'MAE: {mae}')
print(f'MAPE: {mape}%')
print(f'r2_score: {r2_score}')

from prophet.diagnostics import cross_validation, performance_metrics
from hyperopt import hp, fmin, tpe, Trials, STATUS_OK

# Функція для оптимізації
def objective(params):
    m = Prophet(
        changepoint_prior_scale=params['changepoint_prior_scale'],
        seasonality_prior_scale=params['seasonality_prior_scale'],
        holidays_prior_scale=params['holidays_prior_scale'],
        seasonality_mode=params['seasonality_mode']
    )
    m.fit(train_p)

    df_cv = cross_validation(m, initial='730 days', period='180 days', horizon='365 days')
    df_p = performance_metrics(df_cv)
    rmse = df_p['rmse'].values[0]

    return {'loss': rmse, 'status': STATUS_OK}

# Простір параметрів
space = {
    'changepoint_prior_scale': hp.loguniform('changepoint_prior_scale', np.log(0.01), np.log(0.5)),
    'seasonality_prior_scale': hp.loguniform('seasonality_prior_scale', np.log(0.1), np.log(10)),
    'holidays_prior_scale': hp.loguniform('holidays_prior_scale', np.log(0.01), np.log(10)),
    'seasonality_mode': hp.choice('seasonality_mode', ['additive', 'multiplicative'])
}

# Запуск оптимізації
trials = Trials()
best = fmin(fn=objective, space=space, algo=tpe.suggest, max_evals=10, trials=trials)

print(best)

best

# Використання найкращих гіперпараметрів від оптимізації
best_params = {
    'changepoint_prior_scale': np.exp(best['changepoint_prior_scale']),
    'seasonality_prior_scale': np.exp(best['seasonality_prior_scale']),
    'holidays_prior_scale': np.exp(best['holidays_prior_scale']),
    'seasonality_mode': ['additive', 'multiplicative'][best['seasonality_mode']]
}

# Ініціалізація та навчання моделі Prophet з оптимальними параметрами
model2 = Prophet(
    changepoint_prior_scale=best_params['changepoint_prior_scale'],
    seasonality_prior_scale=best_params['seasonality_prior_scale'],
    holidays_prior_scale=best_params['holidays_prior_scale'],
    seasonality_mode=best_params['seasonality_mode']
)
model2.fit(train_p)

# Створення датасету для майбутніх прогнозів
future2 = model2.make_future_dataframe(periods=10) # Прогноз на наступний рік

# Прогнозування
forecast2 = model2.predict(future2)

# Візуалізація прогнозу

```

```

fig1 = model.plot(forecast2)
plt.title("Прогнозовані ціни акцій на наступний рік")

# Візуалізація компонентів прогнозу
fig2 = model.plot_components(forecast2)

mseT = mean_squared_error(train_p['y'], forecast2['yhat'][:-10])
rmseT = np.sqrt(mse1)
maeT = mean_absolute_error(train_p['y'], forecast2['yhat'][:-10])
mapeT = np.mean(np.abs((train_p['y'] - forecast2['yhat'][:-10]) / train_p['y'])) * 100
r2_score2_tren = round(r2_score(train_p['y'], forecast2['yhat'][:-10]),2)
print(f'MSE: {mseT}')
print(f'RMSE: {rmseT}')
print(f'MAE: {maeT}')
print(f'MAPE: {mapeT}%')
print(f'r2_score: {r2_score2_tren}')

#Обрізання прогнозу до тестового періоду
forecast3 = forecast2[-10:]

# Розрахунок метрик
mse2 = mean_squared_error(test_p['y'], forecast3['yhat'])
rmse2 = np.sqrt(mse1)
mae2 = mean_absolute_error(test_p['y'], forecast3['yhat'])
mape2 = np.mean(np.abs((test_p['y'] - forecast3['yhat']) / test_p['y'])) * 100
r2_score2_test = round(r2_score(test_p['y'], forecast3['yhat']),2)
print(f'MSE: {mse2}')
print(f'RMSE: {rmse2}')
print(f'MAE: {mae2}')
print(f'MAPE: {mape2}%')
print(f'r2_score: {r2_score2_test}')

train_p
test_p

from statsmodels.tsa.stattools import adfuller, acf, pacf
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf

# Завантаження даних

series = train_p['y']

# Перевірка на стаціонарність
result = adfuller(series)
print('ADF Statistic: %f' % result[0])
print('p-value: %f' % result[1])

# Якщо ряд нестационарний, можна диференціювати
if result[1] > 0.05:
    series = series.diff().dropna()

# Аналіз ACF та PACF
plot_acf(series)
plot_pacf(series)
plt.show()

# Встановлення значень p, d, q
p = 1 # Виберіть на основі PACF
d = 1 # 1 якщо було виконано диференціювання, інакше 0
q = 1 # Виберіть на основі ACF

```

```

# Встановлення значень p, d, q
p = 1 # Виберіть на основі PACF
d = 1 # 1 якщо було виконано диференціювання, інакше 0
q = 0 # Виберіть на основі ACF

from statsmodels.tsa.arima.model import ARIMA

#
# Вибір ряду даних
ts = train_p['y']

# Підгонка моделі ARIMA
model_ar = ARIMA(ts, order=(p, d, q)) # p - порядок авторегресії, d - ступінь інтеграції, q - порядок рухомого
середнього
results = model_ar.fit()

# Прогнозування
preds = results.get_forecast(steps=10) # Прогноз на 10 кроків вперед
forecast_ar = preds.predicted_mean
conf_int = preds.conf_int()

# Візуалізація результатів
plt.figure(figsize=(10, 5))
plt.plot(ts[:: 200], label='Original')
plt.plot(forecast_ar, label='Forecast')
plt.fill_between(forecast_ar.index, conf_int.iloc[:, 0], conf_int.iloc[:, 1], color='pink', alpha=0.3)
plt.legend()
plt.show()

!pip install pmdarima
from pmdarima import auto_arima
from pmdarima import ARIMA

model_ara = auto_arima(ts, start_p=0, start_q=0, max_p=5, max_q=5, d=None,
                        seasonal=False, trace=True, error_action='ignore', suppress_warnings=True,
                        stepwise=True, information_criterion='aic')

print(model_ara.summary())

series = train_p['y']

model = auto_arima(series, start_p=0, start_q=0, max_p=5, max_q=5, seasonal=False,
                    stepwise=True, suppress_warnings=True, error_action="ignore", trace=True)

# Найкращі параметри від auto_arima
print("Найкращі параметри:")
print(model.get_params())

# Побудова моделі ARIMA з найкращими параметрами
final_model = ARIMA(order=model.order, seasonal_order=model.seasonal_order)
final_model.fit(series)

# Прогнозування
n_periods = 10 # Кількість періодів для прогнозування
forecast, conf_int = final_model.predict(n_periods=n_periods, return_conf_int=True)

# Створення DataFrame для збереження прогнозів
future_dates = pd.date_range(start=train_p['ds'].iloc[-1], periods=n_periods + 1, freq='D')[1:]
forecast_df = pd.DataFrame(data=forecast, index=future_dates, columns=['Forecast'])

# Візуалізація

```

```

import matplotlib.pyplot as plt

plt.figure(figsize=(10, 5))
plt.plot(ts[:: 200], label='Original')
plt.plot(forecast, label='Forecast')
plt.fill_between(forecast.index, conf_int[:, 0], conf_int[:, 1], color='pink', alpha=0.3)
plt.legend()
plt.show()

import pandas as pd
import matplotlib.pyplot as plt
from pmdarima import auto_arima
from statsmodels.tsa.arima.model import ARIMA
series = train_p['y'] # Дані для тренування
# Використання auto_arima для визначення найкращих параметрів
model = auto_arima(series, start_p=0, start_q=0, max_p=5, max_q=5, seasonal=False,
                    stepwise=True, suppress_warnings=True, error_action="ignore", trace=True)
# Виведення найкращих параметрів
print("Найкращі параметри:")
print(model.get_params())

# Побудова моделі ARIMA з найкращими параметрами
final_model = ARIMA(series, order=model.order)
fitted_model = final_model.fit()

# Прогнозування
n_periods = 10
forecast_object = fitted_model.get_forecast(steps=n_periods)
forecast = forecast_object.predicted_mean
conf_int = forecast_object.conf_int(alpha=0.05)

# Створення DataFrame для збереження прогнозів
future_dates = pd.date_range(start=series.index[-1], periods=n_periods + 1, freq='D')[1:]
forecast_df = pd.DataFrame(forecast, index=future_dates, columns=['Forecast'])

# Візуалізація
plt.figure(figsize=(10, 5))
plt.plot(series, label='Original')
plt.plot(forecast_df['Forecast'], label='Forecast')
plt.fill_between(future_dates, conf_int.iloc[:, 0], conf_int.iloc[:, 1], color='pink', alpha=0.3)
plt.legend()
plt.show()

from sklearn.metrics import mean_squared_error, mean_absolute_error

# Прогнозування на тренувальних даних для оцінки
train_forecast = fitted_model.predict(start=series.index[0], end=series.index[-1])

# Оцінка на тренувальних даних
train_mse = mean_squared_error(series, train_forecast)
train_mae = mean_absolute_error(series, train_forecast)
r2_ar = r2_score(series, train_forecast)
# Прогнозування на тестових даних
test_series = test_p['y'] # Припустимо, тестові дані
test_forecast = fitted_model.predict(start=test_series.index[0], end=test_series.index[-1])

# Оцінка на тестових даних
test_mse = mean_squared_error(test_series, test_forecast)
test_mae = mean_absolute_error(test_series, test_forecast)
r2_ar_t = r2_score(test_series, test_forecast)
print(f'Training MSE: {train_mse}, Training MAE: {train_mae}, Training r2: {r2_ar}')
print(f'Test MSE: {test_mse}, Test MAE: {test_mae}, Test r2: {r2_ar_t}')

```

```

from sklearn.model_selection import train_test_split
X = df.drop(['close','date'], axis=1)
y = df['close']
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
X.info()
from sklearn.model_selection import GridSearchCV
import xgboost as xgb
param_grid = {
    'n_estimators': [50, 100, 150 ],
    'max_depth': [3, 5, 7],
    'learning_rate': [0.01]
}
model = xgb.XGBRegressor(objective='reg:squarederror')
grid_search = GridSearchCV(estimator=model, param_grid=param_grid, cv=3, scoring='neg_mean_squared_error',
verbose=1)
# Запуск grid search
grid_search.fit(X_train, y_train)
best_model = grid_search.best_estimator_
# Зробити прогнози
y_pred = best_model.predict(X_test)
y_pred_gb = best_model.predict(X_train)
mse = mean_squared_error(y_pred_gb, y_train)
mae = mean_absolute_error(y_pred_gb, y_train)
r2 = r2_score(y_pred_gb, y_train)
# Виведення результатів
print(f'Mean Squared Error: {mse:.2f}')
print(f'Mean Absolute Error: {mae:.2f}')
print(f'R-squared Score: {r2:.2f}')
mse_t = mean_squared_error(y_pred, y_test)
mae_t = mean_absolute_error(y_pred, y_test)
r2_t = r2_score(y_pred, y_test)
# Виведення результатів
print(f'Mean Squared Error: {mse_t:.2f}')
print(f'Mean Absolute Error: {mae_t:.2f}')
print(f'R-squared Score: {r2_t:.2f}')
fig = plt.figure(figsize = (10,8))
axes = fig.add_subplot(111)
xgb.plot_importance(best_model,ax = axes,height = 0.5)
plt.show();
plt.close()
plt.figure(figsize=(12, 6))
plt.scatter(range(len(y_test)),y_test, label='Тестові дані', color='blue', marker='o')
plt.scatter(range(len(y_test)),y_pred, label='Прогнозовані дані', color='red', marker='x')
plt.title("Тестові та прогнозовані дані")
plt.xlabel("Індекс даних")
plt.ylabel("Значення")
plt.legend()
plt.grid(True)
plt.show()
results = pd.DataFrame({
    'Model': ['Prophet', 'ARIMA', 'XGBoost'],
    'Точність на тренувальних даних MSE': [mseT , train_mse, mse],
    'Точність на тестових даних MSE': [mse2, test_mse, mse_t],
    'Точність на тренувальних даних MAE': [maeT , train_mae, mae],
    'Точність на тестових даних MAE': [mae2, test_mae, mae_t],
    'Точність на тренувальних даних R2': [r2_score2_tren , r2_ar, round(r2,2)],
    'Точність на тестових даних R2': [r2_score2_test, r2_ar_t, round(r2_t,2)]
})

# Виводимо результати
results

```

Додаток Г  
(обов'язковий)

## **ІЛЮСТРАТИВНА ЧАСТИНА**

**АНАЛІЗ ТА ПРОГНОЗУВАННЯ ЦІНИ НА АКЦІЇ NETFLIX**

Нормоконтроль: к.т.н., доцент

\_\_\_\_\_ Сергій ЖУКОВ

«\_\_» \_\_\_\_\_ 2024 р.






Рисунок Г.1 – Зміна ціни на акції з 2014 по 2023 рік




Рисунок Г.2 – Графік важливості ознак




Рисунок Г.3 – Графік прогнозування моделлю Prophet




Рисунок Г.4 – Графік прогнозованих даних

|   | Model   | Точність на тренувальних даних MSE | Точність на тестових даних MSE | Точність на тренувальних даних MAE | Точність на тестових даних MAE | Точність на тренувальних даних R2 | Точність на тестових даних R2 |
|---|---------|------------------------------------|--------------------------------|------------------------------------|--------------------------------|-----------------------------------|-------------------------------|
| 0 | Prophet | 2698.335730                        | 3646.411677                    | 32.475711                          | 58.689257                      | 0.900000                          | -101.710000                   |
| 1 | ARIMA   | 74.150846                          | 370.064045                     | 5.042152                           | 18.291012                      | 0.997298                          | -9.423483                     |
| 2 | XGBoost | 1395.255825                        | 1478.054292                    | 32.134727                          | 33.397530                      | 0.910000                          | 0.910000                      |

Рисунок Г.5 – Таблиця порівняння оцінок точності прогнозування моделей