

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

ЛЬВІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ІВАНА ФРАНКА

Факультет прикладної математики та інформатики

Кафедра дискретного аналізу та інтелектуальних систем

Дипломна робота

ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ ТЕНДЕНЦІЙ
ЦІН КРИПТОВАЛЮТ

Виконав: студент групи ПМі-45с
спеціальності

122 «Комп'ютерні науки»

(шифр і назва спеціальності)

Дмитрук Ю. Р.

(підпис)

(прізвище та ініціали)

Керівник

Пелюшкевич О. В.

(підпис)

(прізвище та ініціали)

Рецензент

(підпис)

(прізвище та ініціали)

2023

ЛЬВІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ІВАНА ФРАНКА

Факультет Прикладної математики та інформатики

Кафедра Дискретного аналізу та інтелектуальних систем

Спеціальність 122 «Комп'ютерні науки»

(шифр і назва)

«ЗАТВЕРДЖУЮ»

Завідувач кафедри _____

"31 _"серпня_ 2022 року

З А В Д А Н Н Я

НА ДИПЛОМНУ У РОБОТУ СТУДЕНТУ

Дмитрук Юрій Романович

(прізвище, ім'я, по батькові)

1. Тема роботи Використання нейронних мереж для прогнозування тенденцій цін криптовалют

керівник роботи Пелюшкевич Ольга Володимирівна канд. фіз.-мат. наук, доцент,

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затвержені Вченою радою факультету від " 13" вересня 2022 року № 15 _____

2. Строк подання студентом роботи 13.06.2023р. _____

3. Вихідні дані до роботи Операційна система Windows 10, середовище розробки – Visual Studio Code, мова програмування – Python, фреймворк машинного навчання – Tensorflow, бібліотеки: Yfinance, Scikit-learn, Pandas, Padas та, Numpy, Matplotlib, Keras

4. Зміст дипломної роботи (перелік питань, які потрібно розробити)

Формулювання задачі прогнозування, дослідження та обробка даних на основі яких буде зроблено прогнозування, використання нейромережі типу LSTM для прогнозування часових рядів, дослідження впливу індикаторів на результат прогнозування нейронної мережі, дослідження впливу кількості епох на результат прогнозування нейронної мережі, дослідження впливу історичного елемента на результат прогнозування нейронної мережі

5. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень)

РЕФЕРАТ

Робота складається із вступу, трьох розділів, висновків та списку використаної літератури. Обсяг дипломної роботи: 52 сторінки тексту та 42 рисунки. Список використаних джерел складається із 25 найменувань

Мета даної роботи полягає у використанні нейронної мережі LSTM для ефективного прогнозування ціни криптовалюти. Точні і надійні прогнози ціни є важливими для криптовалют, оскільки вони мають значний вплив на світову економіку. Однак, нестабільна і непередбачувана природа даних криптовалют ускладнює завдання прогнозування. Для вирішення цієї задачі використано нейронну мережу LSTM, яка здатна аналізувати послідовності протягом тривалого часового періоду. Результати роботи алгоритму демонструються на вибірці цін Bitcoin і полягають у прогнозуванні ціни закриття криптовалюти.

У даній роботі розглянуто прогнозування ціни криптовалюти за допомогою нейронної мережі LSTM. Використання цієї передової технології дозволяє глибше аналізувати дані та забезпечує кращі результати порівняно з традиційними методами прогнозування

У даній роботі було проведено дослідження та аналіз впливу окремих індикаторів та параметрів, а також впливу кількості епох та об'єму історичних даних на результати прогнозування ціни криптовалюти.

ЗМІСТ

ВСТУП.....	4
РОЗДІЛ 1. ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ АНАЛІЗУ КРИПТОВАЛЮТНИХ РИНКІВ ТА ПРОГНОЗУВАННЯ ЇХ ЦІН.....	6
1.1 Формулювання задачі	6
1.2 Задача прогнозування в контексті аналізу часового ряду криптовалюти ...	7
1.3 Нейронні мережі та їхні види.....	8
1.4 Теоретичні аспекти та методи прогнозування цін.....	12
1.5 Види криптовалют та індикатори їхньої ринкової активності	12
РОЗДІЛ 2. ВИКОРИСТАНІ ТЕХНОЛОГІЇ	15
2.1 Використаний тип неймережі	15
2.2 Мова програмування та опис бібліотек	19
2.3 Використані показники та індикатори криптовалюти	24
РОЗДІЛ 3. РЕАЛІЗАЦІЯ ПРОГРАМИ ДЛЯ ПЕРЕДБАЧЕННЯ ЦІН КРИПТОВАЛЮТИ	31
3.1 Програма та алгоритми.....	31
3.2 Показники та індикатори.....	34
3.3 Історичні елементи.....	43
3.4 Епохи	44
ВИСНОВОК.....	47
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	49

ВСТУП

У сучасному світі криптовалюти стають все більш популярним інвестиційним інструментом. Ціни на криптовалюти можуть змінюватися дуже швидко, що створює великі можливості для заробітку, але також і великі ризики. Для зменшення ризиків і отримання прибутку з інвестицій в криптовалюті необхідно ретельно аналізувати ринок і прогнозувати тенденції цін.

Аналізувати ринок криптовалют і прогнозувати тенденції цін можна різними способами. Традиційні методи аналізу фундаментальних та технічних показників використовують статистичні моделі і методи аналізу даних. Однак, такі методи можуть бути недостатньо ефективними для прогнозування в умовах складного та непередбачуваного ринку криптовалют.

Проте, за допомогою нейронних мереж можна отримати більш точний прогноз цін на криптовалюти. Нейронні мережі - це математичні моделі, які наслідують роботу людського мозку та можуть навчатися на великій кількості даних. Використання нейронних мереж для аналізу цін на криптовалюти дозволяє враховувати багато факторів, які можуть впливати на ринок, включаючи новини, політичні та економічні події, технічний аналіз і багато іншого. Такий аналіз забезпечує зростання точності прогнозування цін на криптовалюти, що дозволяє зменшити ризики і збільшити прибутковість інвестицій в ці цифрові активи. Використання нейронних мереж для прогнозування тенденцій цін криптовалют має великий потенціал і може бути ефективним інструментом для інвесторів та трейдерів.

Дослідження застосування нейронних мереж для прогнозування тенденцій цін криптовалют є актуальним та важливим напрямком дослідження в галузі машинного навчання та фінансів, що може допомогти інвесторам та трейдерам впевненіше приймати рішення на ринку криптовалют та забезпечити їм більш успішний результат інвестування.

Актуальність даної роботи полягає у використанні нейронних мереж для прогнозування тенденцій цін криптовалют. Це актуально оскільки, зростає

популярність цього фінансового інструменту та збільшились обсяги торгівлі криптовалютами. Ціни на криптовалюти змінюються дуже швидко, що може призвести до великих втрат для інвесторів та трейдерів. В цьому контексті розробка ефективних методів та інструментів для прогнозування тенденцій цін на криптовалюти є дуже важливою задачею.

Застосування нейронних мереж для прогнозування тенденцій цін на криптовалюти має великий потенціал і може допомогти знизити ризики та забезпечити більш точні прогнози цін на криптовалюти. Також важливою є можливість розробки нових методів та підходів до аналізу та прогнозування ринку криптовалют, що може допомогти інвесторам та трейдерам забезпечити кращі результати в своїй діяльності. Тому дослідження використання нейронних мереж для прогнозування тенденцій цін на криптовалюти є дуже актуальним і важливим напрямом в сучасній фінансовій аналітиці.

В дипломній роботі потрібно дослідити різні архітектури нейронних мереж, щоб отримати найбільш точні результати прогнозування. Також буде проведено аналіз ринку криптовалют та визначено чинники, які мають найбільший вплив на коливання цін.

Завдання полягає у написанні програми за допомогою якої можна вибрати проміжок історичних даних з деякого інтервалу для певної криптовалюти, задати параметри та індикатори, а також кількість епох та розмірність історичного елемента для навчання нейронної мережі та для отримання прогнозів ціни закриття криптовалюти.

РОЗДІЛ 1. ПОСТАНОВКА ЗАДАЧІ ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ АНАЛІЗУ КРИПТОВАЛЮТНИХ РИНКІВ ТА ПРОГНОЗУВАННЯ ЇХ ЦІН

1.1. Формулювання задачі

Задача дипломної роботи полягає в наступному:

- Дослідити різні архітектури нейронних мереж та вибрати оптимальну для розв'язання задачі
- Завантажити дані про криптовалюту
- Обчислити індикатори
- Відфільтрувати дані та нормалізувати їх
- Навчити модель на оброблених даних та провести тести
- Дослідити як різні показники впливають на успішність передбачення нейронної мережі
- Дослідити як різна кількість епох впливає на успішність передбачення нейронної мережі
- Дослідити як історичний елемент впливає на успішність передбачення нейронної мережі

Перш за все, потрібно завантажити дані про криптовалюту, які будуть використовуватися для аналізу. Далі, необхідно вирахувати індикатори, і визначити, які мають вплив на прогнозування цін. Після цього, дані слід відфільтрувати та нормалізувати.

Після попередньої підготовки даних можна перейти до навчання моделі на оброблених даних. Необхідно встановити архітектуру LSTM, включаючи кількість шарів та кількість нейронів у кожному шарі. Далі, провести тренування моделі з використанням навчальних даних та перевірити її ефективність шляхом проведення тестів на відокремленому наборі даних.

Після цього можна провести дослідження впливу різних показників на успішність передбачення нейронної мережі. За допомогою цих досліджень можна визначити, які індикатори найбільше впливають на передбачення ціни криптовалют та використовувати їх у моделі.

Далі, слід дослідити вплив різної кількості епох на успішність передбачення нейронної мережі. Шляхом тренування моделі з різною кількістю епох можна визначити оптимальну кількість, яка забезпечує найкращі результати прогнозування.

Нарешті, варто дослідити, як історичний елемент впливає на успішність передбачення нейронної мережі. Це можна зробити, додавши історичні дані різної тривалості до навчального набору даних. Шляхом порівняння результатів прогнозування для моделей, навчених на різних історичних періодах, можна оцінити, як далеко в минуле необхідно зазирати для досягнення найкращих результатів передбачення.

Усі ці дослідження допоможуть визначити оптимальну архітектуру нейронної мережі LSTM для аналізу часового ряду криптовалют. Результати цих досліджень дозволять зробити висновки про найкращі практики та параметри моделі, які забезпечують найвищу точність прогнозування цін криптовалют.

1.2. Задача прогнозування в контексті аналізу часового ряду криптовалют

Задача прогнозування в контексті аналізу часового ряду криптовалют полягає у прогнозуванні майбутніх значень цін або інших показників криптовалют на основі історичних даних.

Для розв'язання цієї задачі використовуються тип нейронної мережі LSTM (Long Short-Term Memory), яка спеціалізується на аналізі послідовних даних, таких як часові ряди. LSTM має здатність зберігати та використовувати інформацію з попередніх часових кроків, дозволяючи моделі визнавати складні залежності в часових рядах.

Задача прогнозування може включати прогнозування майбутніх цін закриття криптовалют, обсягів торгів або інших показників. В процесі вирішення цієї задачі важливо виконати попередню обробку даних, таку як видалення аномальних значень, нормалізація або стандартизація даних.

У результаті розв'язання задачі передбачення можна отримати прогнозовані значення, які допоможуть приймати рішення щодо торгівлі криптовалютами, розробки інвестиційних стратегій або моніторингу ринку. Результати прогнозування можуть бути використані як один з інструментів для оцінки ризику та прийняття обґрунтованих фінансових рішень у контексті криптовалютних ринків.

1.3. Нейронні мережі та їхні види

Нейронні мережі - це математичні моделі, які підтримуються багатьма обчислювальними вузлами, що працюють разом для вирішення різних задач.

Нейронні мережі можуть використовуватись для різних завдань, включаючи класифікацію, прогнозування, розпізнавання зображень та мовлення, аналіз текстів та багато іншого. Вони здатні навчатися на прикладах, що робить їх дуже ефективними для розв'язання завдань, які складно описати за допомогою традиційних програмних методів.

Принцип роботи нейронних мереж полягає в тому, що вони складаються з взаємопов'язаних шарів, кожен з яких містить нейрони. Кожен нейрон отримує вхідні дані, обробляє їх і відправляє вихідні дані на наступний шар мережі. Під час навчання нейронної мережі вхідні дані передаються через мережу з різними вагами, і зважені значення обробляються кожним нейроном. Після цього мережа порівнює результат з очікуваним вихідним значенням і коригує ваги, щоб підвищити точність прогнозування.

Також принцип роботи нейронних мереж можна порівняти з роботою мозку людини, де кожен нейрон здатний обробляти сигнали та передавати їх іншим нейронам. При вивченні задач нейронні мережі можуть адаптуватися та змінювати свою структуру, що робить їх гнучким і потужним інструментом для розв'язання різноманітних задач, включаючи прогнозування тенденцій цін криптовалют.

Процес роботи нейронної мережі складається з двох етапів: навчання та тестування. Під час навчання, мережа отримує набір вхідних даних, із відомими

вихідними значеннями. На цьому етапі, ваги кожного нейрона в мережі змінюються, з метою мінімізації різниці між вихідними значеннями та очікуваними значеннями.

Після навчання, мережу можна використовувати для тестування на нових наборах вхідних даних. На цьому етапі, мережа використовує набір ваг, які були встановлені під час навчання, для розрахунку відповідей на нові вхідні дані.

Узагальнюючи, нейронна мережа працює шляхом обробки вхідних даних за допомогою великої кількості взаємопов'язаних штучних нейронів. В процесі навчання, мережа змінює ваги кожного нейрона з метою покращення точності відповіді.

На етапі тестування, мережа використовує отримані ваги, щоб передбачити вихідні значення для нових вхідних даних. Таким чином, нейронні мережі можуть бути використані для вирішення широкого спектру задач, включаючи класифікацію, прогнозування, розпізнавання образів та інші [1].

Прямі нейронні мережі - це тип нейронних мереж, в якому інформаційний потік переміщується лише в одному напрямку, від вхідних вузлів до вихідних вузлів. Ці мережі складаються з кількох шарів нейронів: вхідного шару, одного або декількох прихованих шарів та вихідного шару. Кожен шар містить певну кількість нейронів, інтерпретація вихідного сигналу яких залежить від функції активації, що використовується.

Прямі нейронні мережі широко використовуються в різних задачах, зокрема в обробці природних мов, комп'ютерному зорі та розпізнаванні образів. Вони також застосовуються для розв'язання задач класифікації, регресії та кластеризації даних [2].

Згорткові нейронні мережі (Convolutional Neural Networks, CNNs) є типом нейронних мереж, що використовуються для обробки зображень і відео. Вони використовують згортки, щоб ефективно виявляти локальні ознаки в зображеннях, такі як границі, кути, текстури і форми, і побудовані на основі ідеї, що сусідні пікселі в зображенні взаємопов'язані.

У згорткових нейронних мережах використовуються спеціальні шари згортки, які складаються з фільтрів. Кожен фільтр обробляє частину зображення і виконує згортку з цими даними, щоб створити карту ознак. Після цього застосовуються шари пулінгу, які зменшують розмір отриманої карти ознак, зберігаючи при цьому найважливіші ознаки.

Такі мережі зазвичай мають кілька шарів згортки та пулінгу, що дозволяє їм виявляти більш складні ознаки в зображеннях, такі як форми об'єктів і їх розташування. Після цього можуть бути додані повнозв'язні шари, що дозволяють зв'язати отримані ознаки з класами, до яких належить зображення.

Згорткові нейронні мережі широко використовуються в різних задачах комп'ютерного зору, таких як розпізнавання обличчя, класифікація зображень, детекція об'єктів, сегментація зображень та інші. Вони є одним з найбільш ефективних типів нейронних мереж для обробки зображень і відео [2].

Рекурентні нейронні мережі - це тип нейронних мереж, які зазвичай використовуються для обробки послідовностей даних, таких як текст, мовлення або часові ряди.

Одна з головних відмінностей рекурентних мереж від прямих та зворотних мереж полягає в тому, що вони мають зв'язки між нейронами, що дозволяють передавати інформацію від одного кроку часу до наступного. Це дозволяє рекурентним мережам використовувати контекст попередніх даних для кращої обробки поточного вхідного сигналу.

Одним з найпоширеніших варіантів рекурентних мереж є Long Short-Term Memory (LSTM) мережі, які здатні запам'ятовувати довгострокові залежності в послідовностях даних. LSTM використовуються в багатьох задачах, включаючи машинний переклад, аналіз тональності текстів, генерацію тексту, розпізнавання мовлення, класифікацію та прогнозування часових рядів [2].

Використання нейронних мереж для аналізу криптовалютних ринків стало дуже популярним в останні роки. Це пов'язано з тим, що криптовалютний

ринок є дуже складним і непередбачуваним, а отже, потребує великої кількості даних та аналізу, щоб зрозуміти його рухи та прогнозувати майбутні тренди.

За допомогою нейронних мереж можна аналізувати дані про ціни, обсяги торгів та інші показники на ринку криптовалют. За результатами аналізу, нейронні мережі можуть давати прогнози щодо майбутніх цін та рухів на ринку, що дозволяє трейдерам та інвесторам приймати кращі рішення та знижувати ризики в інвестуванні.

Також, нейронні мережі можуть бути використані для виявлення аномалій на ринку, таких як штучно створені підйоми та падіння цін, які можуть бути зумовлені маніпулюваннями на ринку. Це допомагає уникати обману та зберігати інвестиції в безпеці.

Одним з підходів до використання нейронних мереж для прогнозування цін криптовалют є навчання мережі на історичних даних цін та інших показників ринку. Наприклад, нейронна мережа може бути навчена на історичних даних цін на Bitcoin за певний період часу, а також інших показників, таких як обсяг торгів, кількість активних гаманців, кількість транзакцій тощо. Після навчання мережі на історичних даних, вона може бути використана для прогнозування цінових рухів на майбутньому часовому проміжку.

Інший підхід до використання нейронних мереж для прогнозування цін криптовалют полягає у використанні нейронної мережі для аналізу та прогнозування рухів цін на основі живих даних з ринку. У цьому випадку, нейронна мережа може бути навчена на живих даних з криптовалютних бірж та інших джерел, щоб прогнозувати цінові рухи на майбутній часовий проміжок.

Однак, важливо зазначити, що нейронні мережі не є повністю точними та можуть містити помилки. Тому, використання їх результатів повинно бути підтримане аналізом фундаментальних показників та інших даних, щоб приймати найбільш обґрунтовані рішення.

1.4. Теоретичні аспекти та методи прогнозування їх цін

Аналіз фундаментальних та технічних показників є важливим для розуміння тенденцій на криптовалютному ринку. Фундаментальний аналіз базується на оцінці фінансової, економічної та політичної ситуації, яка може впливати на ціну криптовалюти. Технічний аналіз, з іншого боку, використовує графіки та інші інструменти для визначення тенденцій ціни та прогнозування майбутніх змін.

Обидва типи аналізу можуть бути корисними для передбачення тенденцій цін на криптовалютних ринках. Проте, на практиці, кращі результати можуть бути досягнуті за допомогою комбінації обох підходів.

Нейронні мережі можуть використовуватись для обробки фундаментальних та технічних показників та прогнозування цін на криптовалютному ринку. Зазвичай використовуються рекурентні нейронні мережі для цього типу завдань. Однак, важливо враховувати, що ринок криптовалют дуже волатильний та залежить від багатьох факторів, тому результати прогнозування ціни можуть бути неточними та залежати від обраної стратегії [3].

1.5. Види криптовалют та індикаторів їхньої ринкової активності

Криптовалюти - це цифрові або віртуальні валюти, що використовують криптографію для захисту транзакцій та контролю емісії одиниць валюти. Кожна криптовалюта має свою унікальну технологію та особливості, які визначають її принципи функціонування та використання. Основні види криптовалют включають:

- Біткоїн (Bitcoin) - це перша та найбільш відома криптовалюта, яка була створена у 2009 році. Біткоїн базується на технології блокчейн та використовується як засіб платежу та зберігання вартості.
- Ефір (Ethereum) - це криптовалюта, створена у 2015 році, що базується на технології блокчейн та має можливості для створення децентралізованих додатків та контрактів.

Кожна з цих криптовалют має свої особливості та принципи роботи, що впливають на їхню вартість та популярність на ринку [4].

Аналіз ринкової активності криптовалют може включати в себе використання різних індикаторів, що дозволяють оцінити поточний стан ринку та передбачити можливу його динаміку. Деякі з найбільш популярних індикаторів включають в себе:

- Цінові індикатори це індикатори, які базуються на ціновій динаміці криптовалюти. Найпоширеніші з них - це середні ціни за певний період (наприклад, проста середня або експоненційна середня ціна) та індикатори зміни ціни (наприклад, RSI, MACD).
- Індикатори волатильності це індикатори, які допомагають визначити, наскільки сильно коливається ціна криптовалюти протягом певного періоду часу. Їх можна використовувати для передбачення можливих змін ціни в майбутньому.
- Індикатори обсягів це індикатори, які вказують на зміну обсягу торгів, що може бути показником можливих змін на ринку.
- Індикатори трендів це індикатори, які допомагають визначити, в якому напрямку розвивається ціна криптовалюти. Вони включають в себе, наприклад, лінії підтримки та опору, а також індикатори, які визначають нахил тренду (наприклад, ADX).

Індикатори можуть бути корисними для аналізу ринку, але слід пам'ятати, що жоден індикатор не може гарантувати точний прогноз цін на криптовалютному ринку. Для здійснення більш точного прогнозу необхідно враховувати більш широкий спектр факторів, включаючи фундаментальний аналіз та технічний аналіз, а також використовувати інші методи аналізу, наприклад, нейронні мережі. Однак, індикатори можуть бути корисними для інформаційного аналізу, показуючи певні тенденції на ринку та допомагаючи трейдерам приймати рішення щодо відкриття або закриття позицій [5].

Використання індикаторів для прогнозування цін криптовалют є популярним методом серед трейдерів та інвесторів.

Вони дозволяють оцінювати сили тренду, аналізувати обсяги торгів та багато іншого. Таким чином, вони можуть стати корисним інструментом для прийняття рішень на ринку.

Однак, слід зазначити, що індикатори мають певні недоліки, які можуть призвести до неточностей у прогнозуванні цін. Наприклад, більшість індикаторів базуються на історичних даних, тому вони можуть бути менш ефективними у непередбачуваних ринкових ситуаціях. Крім того, індикатори можуть бути підроблені, що може призвести до неправильних сигналів.

Таким чином, використання індикаторів для прогнозування цін криптовалют може бути корисним, але слід пам'ятати, що вони не є універсальним інструментом та їх потрібно використовувати в поєднанні з іншими методами аналізу ринку.

РОЗДІЛ 2 ВИКОРИСТАНІ ТЕХНОЛОГІЇ

2.1. Використаний тип неймережі

Отже, було з'ясовано що таке криптовалюта та як її можна аналізувати, а також оглянули декілька різних видів неймереж. Тепер потрібно визначити який конкретно вид неймережі потрібно використати для передбачення тенденції ціни криптовалюти.

Є декілька методів аналізу криптовалюти а саме:

- Фундаментальний аналіз - оцінюється реальна цінність криптовалюти, враховуючи фактори, такі як фінансові звіти, реальні доходи компаній, геополітичні та економічні події.
- Технічний аналіз - вивчення графіків цін криптовалют з метою знаходження шаблонів та індикаторів, що можуть допомогти в передбаченні майбутніх цінових рухів.

Найкраще нейронна мережа справиться саме з технічним аналізом. Якщо ми завантажимо історію будь якої криптовалюти ми побачимо часовий ряд в кожному з елементів якого будуть декілька показників таких як, ціна відкриття та закриття, мінімальна та максимальна ціна за проміжок часу і тд. Як згадувалось раніше саме рекурентна нейронна мережа найкраще працює для передбачення часових рядів.

Рекурентні нейронні мережі мають властивість зберігати інформацію про попередні стани входів, що дозволяє їм аналізувати послідовності даних, такі як часові ряди. Це дозволяє рекурентним нейронним мережам "пам'ятати" попередні стани та використовувати їх для прогнозування майбутніх значень.

Кроки, які відбуваються в рекурентній нейронній мережі (RNN), можна описати наступним чином:

- На вхід мережі надходить вектор даних x_t . Цей вектор може містити інформацію про поточний час, ціну криптовалюти та інші параметри.

- Мережа використовує внутрішній стан h_t , який відображає попередній стан мережі на час $t-1$. Спочатку внутрішній стан може бути встановлений на 0 або випадковий.
- На кожному кроці мережа обчислює новий внутрішній стан h_t за допомогою формули: $h_t = f(W_x * x_t + W_h * h_{t-1})$, де f - функція активації, W_x - матриця ваг між вхідними вузлами та внутрішнім станом, а W_h - матриця ваг між попереднім внутрішнім станом та поточним внутрішнім станом.
- Мережа використовує внутрішній стан h_t для генерації вихідного сигналу y_t за допомогою формули: $y_t = g(W_y * h_t)$, де g - функція активації, а W_y - матриця ваг між внутрішнім станом та вихідним вузлом.
- Новий внутрішній стан h_t стає попереднім внутрішнім станом наступного кроку часу.
- Процес повторюється для кожного кроку часу, що дозволяє мережі запам'ятовувати попередній стан та використовувати його для прогнозування наступного стану.
- Навчання мережі полягає у зміні ваг матриць W_x , W_h та W_y з використанням зворотного поширення помилки.

Після навчання мережу можна використовувати для прогнозування цін криптовалют на основі попередніх даних. Для цього спочатку необхідно підготувати дані, що будуть використовуватися для прогнозування. Це можуть бути, наприклад, історичні дані про ціни криптовалют за певний період часу. Далі ці дані подаються на вхід мережі, яка застосовує свої внутрішні ваги та функції активації для обробки інформації та отримання прогнозованих значень цін криптовалют на майбутній період.

Також слід зазначити що існує кілька типів рекурентних нейронних мереж (RNN), які використовуються в машинному навчанні для роботи з послідовністю даних [6]. Деякі з них включають:

- Проста RNN (Simple RNN): Це базова форма RNN, де кожен нейрон приймає на вхід попередній стан мережі разом з новим вхідним значенням. Проста RNN часто має проблему зі зниклими градієнтами при тренуванні на довгих послідовностях.
- LSTM (Long Short-Term Memory): LSTM мережі були розроблені для того, щоб вирішити проблему зі зниклими градієнтами, що виникають в простих RNN. LSTM мережі використовують внутрішні вентиля, щоб вирішити, які деталі потрібно зберегти в пам'яті та які можна викинути. Це дозволяє LSTM мережам ефективно працювати з довгими послідовностями даних.
- GRU (Gated Recurrent Unit): GRU - це інша форма RNN, яка була розроблена для того, щоб вирішити проблему зі зниклими градієнтами. GRU мережі використовують менше параметрів, ніж LSTM, та мають менше внутрішніх вентилів, що робить їх швидшими та менш складними для тренування [7].

Для нашої задачі краще підходить LSTM оскільки вибірка даних буде великою, а прогнозувати ми будемо ціну закриття на наступний день тож швидкість не є дуже важливою.

LSTM (Long Short-Term Memory) - це один із видів рекурентних нейронних мереж, який був розроблений для роботи з послідовностями даних, що мають тривалу залежність в часі. LSTM здатний зберігати та використовувати інформацію про попередні стани входу, що робить його особливо корисним для завдань, пов'язаних із змінною тривалістю залежності.

Основні складові LSTM - це комірка пам'яті (memory cell), забувальні ворота (forget gate), ворота входу (input gate) та ворота виходу (output gate).

Комірка пам'яті - це структура, яка зберігає попередній стан входу та попередній стан пам'яті. Вона може додавати нову інформацію до свого стану, якщо ворота входу відкриті, а ворота забування - закриті.

Ворота забування - це механізм, який дозволяє мережі вирішувати, яку інформацію з попереднього стану пам'яті варто забути, щоб не забивати нову інформацію.

Ворота входу - це механізм, який дозволяє мережі вирішувати, яку нову інформацію з вхідного сигналу слід додати до стану пам'яті.

Вихідні ворота - це механізм, який дозволяє мережі вирішувати, який стан пам'яті слід використовувати для вихідного сигналу.

Загалом, LSTM здатна зберігати та використовувати довгострокові залежності в даних, що робить його корисним для багатьох завдань.

Описуючи покроково, як працює LSTM, можна виділити наступні етапи:

- Вхідні дані передаються до мережі у вигляді послідовності векторів.
- Кожен вектор переходить через чотири основних шари LSTM: вхідний шар, забувальний шар, шар пам'яті та вихідний шар.
- Вхідний шар відповідає за обробку вхідних даних та визначає, яку інформацію зберегти або забути.
- Забувальний шар відповідає за визначення, яку інформацію потрібно видалити з попереднього стану мережі.
- Шар пам'яті відповідає за оновлення інформації, яка зберігається в попередньому стані мережі.
- Вихідний шар відповідає за створення вихідного значення на основі вхідних даних та попереднього стану мережі.
- Кожен з чотирьох шарів LSTM містить декілька нейронів, далі у дипломній роботі буде описано кількість нейронів яка буде використовуватися при тестах, кожен з яких має внутрішні змінні, які дозволяють мережі зберігати інформацію і контролювати, як ця

інформація перетворюється від одного часового кроку до наступного.

Після того, як мережа пройшла навчання та побудована модель, можна використовувати LSTM для прогнозування майбутніх значень. Для цього необхідно передати вхідні дані в мережу та запустити її на виконання. Результатом роботи мережі є прогнозовані значення цін криптовалют на певний період часу [8].

2.2. Мова програмування та опис бібліотек

Python - це високорівнева інтерпретована мова програмування, створена Гвідо ван Россумом у 1991 році. Вона має простий і зрозумілий синтаксис, що дозволяє швидко розробляти програми. Python має велику стандартну бібліотеку, яка містить багато корисних модулів для різних задач, таких як робота зі звуком і зображеннями, обробка тексту, мережеві операції та багато іншого. Python використовується для розробки веб-додатків, наукових досліджень, машинного навчання, обробки даних, розробки ігор, робототехніки та інших задач. Мова Python є дуже популярною серед програмістів завдяки своїй простоті та ефективності [9].

Yfinance - це бібліотека мови Python, яка надає інтерфейс для отримання фінансової інформації з різних джерел. Бібліотека базується на Yahoo Finance API, який забезпечує доступ до історичних та поточних даних з більш ніж 60 бірж і фондових ринків у всьому світі.

Завдяки yfinance можна отримати інформацію про ціни акцій, дивіденди, обсяги торгів, фінансові звіти та багато іншого. Бібліотека дозволяє отримувати дані як в режимі реального часу, так і за історичними даними. За допомогою yfinance можна вивчати тенденції на ринку, створювати фінансові моделі та робити прогнози на основі історичних даних [10].

Scikit-learn (або sklearn) - це відкрита бібліотека для машинного навчання на мові програмування Python. Вона містить інструменти для класифікації, регресії, кластеризації, аналізу даних та підготовки даних.

Функція `MinMaxScaler` з бібліотеки `Scikit-learn` використовується для нормалізації даних в заданому діапазоні. Нормалізація є важливим кроком при підготовці даних для навчання моделі машинного навчання, оскільки багато алгоритмів чутливі до масштабування даних.

`MinMaxScaler` перетворює кожен ознаку (змінну) на нове значення в діапазоні від 0 до 1, що дозволяє зберегти форму розподілу даних. Формула для обчислення нового значення ознаки x :

$$x_{new} = \frac{x - \min(x)}{\max(x) - \min(x)}$$

де $\min(x)$ і $\max(x)$ - мінімальне і максимальне значення ознаки x .

Процес використання `MinMaxScaler` може бути розглянутий в такі кроки:

1. Створити об'єкт класу `MinMaxScaler`.
2. Викликати метод `fit` для обчислення мінімального та максимального значень кожної ознаки (змінної).
3. Викликати метод `transform` для перетворення даних в діапазон від 0 до 1 за допомогою обчислених мінімальних та максимальних значень.
4. Опціонально викликати метод `inverse_transform` для зворотного перетворення даних в їх оригінальний масштаб [11].

`Pandas` - це бібліотека мови програмування `Python` для обробки та аналізу даних. Вона надає зручний і ефективний інтерфейс для створення, редагування та аналізу табличних даних.

Основними структурами даних у `Pandas` є серії (`Series`) та `DataFrame`. Серії - це одновимірний масив з індексами, тоді як `DataFrame` - це двовимірний масив з індексами та назвами стовпців. `Pandas` дозволяє виконувати широкий спектр операцій над даними, таких як фільтрування, сортування, групування, об'єднання та зведення даних [12].

`Pandas_ta` - це бібліотека, яка надає широкий набір індикаторів технічного аналізу для `Pandas DataFrame`. Вона дозволяє зручно додавати різноманітні індикатори без необхідності вручну писати складні формули.

`Pandas_ta` містить більше 100 різних індикаторів, таких як середні, стохастичні, регресійні, `OBV`, `RSI`, `MACD` і т.д. [13].

Бібліотека NumPy (Numerical Python) - це відкрита бібліотека для мови програмування Python, призначена для роботи з багатовимірними масивами і матрицями чисел. Вона забезпечує широкі можливості для виконання математичних операцій, включаючи лінійну алгебру, обробку масивів і матриць, генерацію псевдовипадкових чисел і роботу з ними, статистичний аналіз, фур'є-аналіз і інші. NumPy надає ефективні функції для обробки даних у вигляді масивів, що дозволяє здійснювати обчислення на великих об'ємах даних з високою швидкістю.

Основна структура даних, що використовується в NumPy - це масив (array), який може бути одновимірним, двовимірним і більш високо вимірним. Масиви NumPy підтримують швидку обробку і виконання операцій, в тому числі математичних, логічних, індексації, зрізання, перестановок та інших.

Бібліотека NumPy є однією з основних компонентів для наукових обчислень в мові програмування Python, і є необхідною для багатьох інших наукових і інженерних бібліотек, таких як SciPy, Matplotlib, Pandas, Scikit-learn і інші [14].

Matplotlib - це бібліотека Python для візуалізації даних. Вона дозволяє створювати різноманітні типи графіків, включаючи лінійні діаграми, стовпчасті діаграми, гістограми, діаграми розсіювання, кругові діаграми та інші.

Matplotlib дозволяє змінювати розмір, колір та тип ліній, додавати підписи до осей та графіків, створювати легенди, встановлювати різні типи маркерів і т.д. Крім того, Matplotlib може інтегруватись з іншими бібліотеками, такими як NumPy та Pandas, що робить його потужним інструментом для аналізу та візуалізації даних [15].

TensorFlow - це відкрита платформа для розробки інтелектуальних алгоритмів та моделей штучного інтелекту. Вона розроблена компанією Google та забезпечує зручні інструменти для створення, тренування та розгортання моделей машинного навчання.

Бібліотека TensorFlow дозволяє використовувати різноманітні типи штучних нейронних мереж, включаючи згорткові, рекурентні та повнозв'язні

мережі. Вона також підтримує автоматичну диференціацію, що спрощує процес оптимізації моделей та підвищує швидкість їх тренування.

TensorFlow має багато інструментів для візуалізації та моніторингу процесу тренування моделей, що допомагає відстежувати прогрес та знаходити помилки. Крім того, TensorFlow має широку підтримку для різноманітних апаратних платформ, включаючи CPU, GPU та TPU [16].

Оскільки бібліотека TensorFlow надзвичайно велика тут буде описано лише ті її можливості які будуть використав у реалізації (рис 2.1)

```
def createModel(X_train, DROPOUT=0.2):
    WINDOW_SIZE = SEQ_LEN

    model = keras.Sequential()

    model.add(Bidirectional(LSTM(WINDOW_SIZE, return_sequences=True),
                            input_shape=(WINDOW_SIZE, X_train.shape[2])))
    model.add(Dropout(rate=DROPOUT))

    model.add(Bidirectional(LSTM(WINDOW_SIZE * 2, return_sequences=True)))
    model.add(Dropout(rate=DROPOUT))

    model.add(Bidirectional(LSTM(WINDOW_SIZE, return_sequences=False)))

    model.add(Dense(units=1))

    model.add(Activation('linear'))
    return model
```

Рисунок 2.1 – Функція що створює модель нейронної мережі

Цей код (рис 2.1) є функцією побудови нейронної мережі з декількома шарами LSTM та функцією активації 'linear'. Функція отримує X_train - тренувальний набір даних та DROPOUT - параметр для функції Dropout.

Кроки функції:

1. Створення об'єкту моделі Sequential() - це побудова нейронної мережі в Keras;
2. Додавання шару Bidirectional (LSTM()) - це шар LSTM з додатковими нейронами, які сприймають інформацію від обох напрямків послідовності даних;
3. Додавання шару Dropout (rate=DROPOUT) - це шар, який випадковим чином відключає деякі нейрони з певною імовірністю DROPOUT, щоб запобігти перенавчанню моделі;
4. Повторення кроків 2 та 3 для декількох шарів LSTM з різними кількістю нейронів;
5. Додавання порожнього шару Dense (units=1) - це шар з одним вихідним нейроном, який використовується для передбачення вихідного значення;

6. Додавання функції активації 'linear' - це функція активації, яка використовується для повернення вихідних значень в їхній оригінальний масштаб.

За кількість нейронів відповідає константа `WINDOWS_SIZE` в яку може бути передане різне значення проте в подальшому у програмі `WINDOWS_SIZE` буде дорівнювати 7.

Ця функція допомагає створити потужну нейронну мережу для прогнозування тенденцій цін криптовалют.

`Bidirectional` - це шар в нейромережі, який дозволяє проходити інформацію через нейронну мережу в обидва напрямки - вперед і назад.

Шар `Bidirectional` приймає на вхід послідовність даних, розбиває її на частини та обчислює значення на кожному кроці часу. При цьому, дані проходять через два окремих LSTM шари - один вперед (`forward`) і один назад (`backward`).

Шар `Bidirectional` корисний у випадках, коли наступний елемент послідовності залежить не тільки від попередніх значень, але й від наступних. Наприклад, у текстовому аналізі, коли потрібно зрозуміти зміст речення, розуміння контексту може залежати як від наступних, так і від попередніх слів у реченні.

Завдяки можливості обчислювати значення в обидва напрямки, `Bidirectional` шари дозволяють враховувати більше інформації та поліпшувати точність передбачень.

Далі потрібно зкомпілювати модель нейромережі в TensorFlow для задачі прогнозування з функцією втрат "`mean_squared_error`" та оптимізатором "`adam`" (рис 2.2).

Функція втрат "`mean_squared_error`" вимірює середньоквадратичну помилку між прогнозованими та правильними значеннями. Ця функція використовується, коли ми хочемо навчити модель передбачати неперервні числові значення.

Оптимізатор "adam" використовує адаптивні швидкості навчання для кожного параметру моделі. Він підлаштовує швидкість навчання для кожного параметру залежно від ступеня їхнього оновлення. Оптимізатор "adam" зазвичай є хорошим вибором для багатьох задач навчання моделей нейромереж.

Далі потрібно навчити нейромережу за допомогою методу fit() бібліотеки TensorFlow (рис 2.3).

Аргументи функції fit():

- X_train: навчальні дані.
- Y_train: мітки для навчальних даних.
- epochs: кількість епох навчання, тобто кількість проходів даних через нейромережу.
- batch_size: розмір пакета (batch), тобто кількість зразків даних, які будуть передаватися моделі на кожній ітерації під час навчання.
- shuffle: чи перемішувати навчальні дані перед кожною епохою.
- validation_split: частка даних, які будуть використовуватися для перевірки точності навчання на кожній епосі [17].

```
model.compile(
    loss='mean_squared_error',
    optimizer='adam'
)
```

Рисунок 2.2 – Компілювання моделі

```
history = model.fit(
    X_train,
    Y_train,
    epochs=30,
    batch_size=BATCH_SIZE,
    shuffle=False,
    validation_split=0.1
)
```

Рисунок 2.3 – Навчання моделі

2.3. Використані показники та індикатори криптовалюти

Більшість серверів на яких зберігається історія про криптовалюту надають доступ до таких показників як: максимальна та мінімальна ціна за період часу, ціна відкриття та закриття, об'єм та середня ціна.

З цих показників слід виділити об'єм - кількість криптовалюти, що була куплена та продана за певний період часу. Цей показник дозволяє визначити

активність торгів на ринку та популярність криптовалюти. Та ціну закриття яку нам потрібно передбачити.

Індикаторів є доволі багато, зазвичай вони базуються на історії показників. В роботі будуть розглянуті наступні індикатори: RSI, EMA, MACD, ATR, Bollinger Bands, MFI, OBV, ADX

Індекс сили спаду / зростання (RSI) - це технічний індикатор, який вимірює швидкість і масштаб змін цін активу і визначає перевернення цінових тенденцій. RSI може допомогти інвесторам та трейдерам визначити, чи актив перепроданий або перекуплений і чи настав час купувати або продавати.

RSI обчислюється на основі серії цінових даних і розраховується за наступною формулою:

$$RSI = 100 - \left(\frac{100}{1 + RS} \right)$$

RS – це відношення середнього приросту ціни до середнього падіння за останні N періодів/свічок.

RSI зазвичай вимірюється в діапазоні від 0 до 100, де значення понад 70 вказують на перекупленість активу, а значення менше 30 вказують на його перепроданість. Інвестори можуть використовувати ці рівні, щоб визначити момент входу або виходу з позиції [18].

EMA (Exponential Moving Average) - це індикатор, який використовується для визначення середньої ціни активу протягом визначеного періоду. Цей індикатор дуже схожий на просту рухома середю (SMA), однак він забезпечує більший ваговий коефіцієнт для останніх даних, тому що він використовує експоненційну функцію зменшення ваги.

Формула EMA розраховується як:

$$EMA_{\text{сьогодні}} = \left(\text{Ціна}_{\text{сьогодні}} * \frac{2}{\text{Тривалість}_{\text{інтервалу}} + 1} \right) + (EMA_{\text{вчора}} * \left(1 - \frac{2}{\text{Тривалість}_{\text{інтервалу}} + 1} \right))$$

де: $Ціна_{сьогодні}$ - ціна активу в поточний день, $Тривалість_{інтервалу}$ - кількість періодів, на яких ви розраховуєте ЕМА, $ЕМА_{вчора}$ - ЕМА, розраховане для попереднього дня.

ЕМА може бути використаний для визначення тренду ринку. Якщо ціна активу перебуває вище свого ЕМА, то ринок нахилений до зростання, і навпаки, якщо ціна активу перебуває нижче свого ЕМА, то ринок нахилений до падіння [19].

Індикатор MACD (Moving Average Convergence Divergence) використовується для визначення поточного напрямку тренду та сигналів на купівлю або продаж.

MACD складається з трьох складових: лінії MACD, сигнальної лінії та історограми.

Лінія MACD обчислюється як різниця між експоненційно зваженим середнім (ЕМА) з довшим періодом (зазвичай 26 днів) та ЕМА з коротшим періодом (зазвичай 12 днів):

$$MACD_{Line} = 12_{EMA}^{day} - 26_{EMA}^{day}$$

Сигнальна лінія обчислюється як ЕМА лінії MACD з ще коротшим періодом (зазвичай 9 днів), а історограма відображає різницю між лінією MACD та сигнальною лінією

Графік MACD зазвичай відображається як дві лінії (MACD Line і Signal Line) та історограма. Сигнал на купівлю може виникнути, коли лінія MACD перетинає сигнальну лінію знизу вгору. Сигнал на продаж може виникнути, коли лінія MACD перетинає сигнальну лінію зверху донизу. Історограма може показати зміну моментуму руху ціни.

Індикатор MACD може бути корисним для трейдерів для визначення напрямку тренду та здійснення торгівельних операцій на основі сигналів купівлі або продажу [20].

Індикатор Average True Range (ATR) використовується для вимірювання волатильності активу, включаючи криптовалюти.

ATR відображає середнє значення абсолютної різниці між максимальним і мінімальним значеннями ціни за певний період. Чим вище значення ATR, тим більша волатильність ціни активу.

Формула розрахунку ATR полягає у взятті середнього значення із трьох індикаторів TR (True Range) за певний період:

$$ATR = \frac{(TR_1 + TR_2 + TR_3 + \dots + TR_n)}{n}$$

де TR - True Range, тобто максимальне значення з трьох наступних значень:

- різниця між максимальною та мінімальною ціною поточного періоду;
- абсолютна різниця між максимальною ціною поточного періоду та закривальною ціною попереднього періоду;
- абсолютна різниця між мінімальною ціною поточного періоду та закривальною ціною попереднього періоду.

Період, на який розраховується ATR, може бути налаштований, але найчастіше використовують 14-денний період. ATR можна використовувати окремо як індикатор волатильності, або як основу для побудови інших технічних індикаторів [21].

Індикатор Bollinger Bands - це технічний індикатор, що дозволяє вимірювати волатильність цін активів та визначати цінові коридори, що містять більшу частину цін на активи.

Цей індикатор складається з трьох складових: середня ковзна ціна (SMA) та два канали, що визначаються на основі стандартного відхилення цін від середньої.

Для того, щоб розрахувати Bollinger Bands, потрібно:

1. Обрати період для SMA (зазвичай використовують 20 днів).
2. Розрахувати SMA на основі цін активу за вибраний період.
3. Розрахувати стандартне відхилення цін активу за той же період, що був використаний для SMA.
4. Розрахувати два канали, які відображають кількість стандартних відхилень цін від середньої: верхній канал (SMA + (стандартне

відхилення * кількість стандартних відхилень)) та нижній канал (SMA - (стандартне відхилення * кількість стандартних відхилень)).

Зазвичай, для розрахунку Bollinger Bands використовують значення 2 стандартних відхилень. Якщо ціна активу виходить за коридор Bollinger Bands, це може свідчити про початок нового тренду. Якщо ціна активу перетинає середню лінію, це може бути сигналом для входу в позицію відповідно до напрямку руху ціни [22].

Індекс грошового потоку (Money Flow Index, MFI) - це технічний індикатор, який використовується для вимірювання грошового потоку у актив і визначення потенційної ринкової тенденції.

MFI визначається на основі двох факторів: грошового потоку (Money Flow, MF) та обсягів (Volume) за певний період. Оскільки ці показники залежать від ціни, то індикатор MFI також пов'язаний з ціновою динамікою ринку.

Основна ідея індикатора MFI полягає в тому, що при зростанні ціни та збільшенні обсягів, грошовий потік також збільшується, що свідчить про ріст ціни на ринку. Навпаки, при падінні ціни та зменшенні обсягів грошовий потік зменшується, що може свідчити падіння ціни.

Формула індикатора MFI складається з кількох кроків:

1. Typical Price (TP) - середнє значення цін на актив за даний період:

$$TP = \frac{High + Low + Close}{3}$$

2. Money Flow (MF) - вимірює грошовий потік від купівлі або продажу активу:

$$MF = TP * Volume$$

3. Money Ratio (MR) - відношення PMF до NMF:

$$MR = \frac{PMF}{NMF}$$

4. Money Flow Index (MFI) - індикатор, який відображає силу грошових потоків та потенційне зміщення ціни активу:

$$MFI = 100 - \frac{100}{1 + MR}$$

Індикатор MFI може бути корисним для визначення зміни напрямку руху цін [23].

OBV (On-Balance Volume) - це індикатор, який використовується для вимірювання позицій покупців та продавців, щоб визначити напрямок тренду та підтвердити його. Цей індикатор базується на тому, що обсяг торгів вказує на те, в якому напрямку рухатиметься ціна.

При зростанні ціни обсяг торгів зазвичай збільшується, тоді як при падінні - зменшується. OBV обчислюється шляхом додавання або віднімання обсягу до попереднього значення OBV в залежності від того, чи було зростання або падіння ціни.

Якщо ціна зростає, то поточний обсяг додається до попереднього значення OBV, що вказує на позиції покупців. Якщо ціна падає, то поточний обсяг віднімається від попереднього значення OBV, що вказує на позиції продавців.

OBV можна використовувати для підтвердження напрямку тренду або для виявлення змін у поведінці ринку. Якщо OBV зростає разом з ціною, це підтверджує, що рух є сильним і продовжується. Якщо ціна падає, а OBV залишається стабільним або зростає, це може свідчити про можливий перехід тренду або реверсію [24].

Індикатор ADX (Average Directional Index) - це технічний індикатор, що використовується для вимірювання сили тенденції ринку. ADX складається з двох інших індикаторів, плюс самого індикатора ADX. Перші два індикатори - Directional Movement Indicators (DMI) - використовуються для визначення напрямку тенденції. DMI складається з двох ліній +DI (Positive Directional Index) та -DI (Negative Directional Index), які показують, які сили домінують на ринку - биків або ведмедів.

Тепер про ADX. ADX використовується для вимірювання сили цієї тенденції. Індикатор складається з однієї лінії, яка коливається від 0 до 100. Зазвичай ADX розглядають як індикатор, що показує силу тенденції, якщо він перевищує рівень 25. Значення ADX більше 40 вказують на дуже сильну тенденцію [25].

РОЗДІЛ 3 РЕАЛІЗАЦІЯ ПРОГРАМИ ДЛЯ ПЕРЕДБАЧЕННЯ ТЕНДЕНЦІЙ ЦІН КРИПТОВАЛЮТИ

3.1. Програма та алгоритми

Перш за все програма завантажує дані про певну криптовалюту за вказаний період часу та вказаним інтервалом, в подальшому програма буде працювати з біткоїном, також вона буде скачувати усі дані які надає сервер з інтервалом в 1 день. Після скачування вона отримає параметри біткоїну починаючи з 2015 року по 2023 рік з інтервалом в 1 день (рис 3.1), а саме дату, ціну відкриття та закриття, найбільшу та найменшу ціну у інтервалі, середню ціну та об'єм.

Далі обчислюються усі індикатори які мають бути в тренувальних даних та видаляються не потрібні дані. Наприклад обчислюється індикатор RSI та видаляється дата оскільки вона не потрібна для навчання (рис 3.2).

	Date	Open	High	Low	Close	Volume	Price
0	2015-01-25 00:00:00+00:00	247.352085	255.074807	243.889999	253.718003	33502700	249.482002
1	2015-01-26 00:00:00+00:00	254.078995	309.384003	254.078995	273.472992	106794000	281.731499
2	2015-01-27 00:00:00+00:00	273.166992	275.480011	250.653000	263.475006	44390000	263.066505
3	2015-01-28 00:00:00+00:00	263.351813	266.535004	227.046005	233.914993	44352200	266.790504
4	2015-01-29 00:00:00+00:00	233.340007	238.705994	220.712000	233.513000	32213400	229.709000

	Open	High	Low	Close	Volume	Price	RSI_14	RSI_14_A_60	RSI_14_B_40
14	227.692993	229.430004	221.070996	221.412003	17145200	225.257000	30.442268	0	1
15	223.389000	223.577005	217.018997	220.110001	27791300	220.498001	37.678557	0	1
16	220.281998	221.007007	215.332001	219.839005	21115100	218.565004	37.530191	0	1
17	219.731995	223.406006	218.074005	219.184998	17201900	220.748005	37.149999	0	1
18	219.207993	222.199005	217.613998	221.764008	15206200	219.908502	39.742327	0	1

Рисунок 3.1 – Завантажені дані

Рисунок 3.2 – Завантажені дані з
обрахованим RSI та видаленою датою

Після завантаження усіх необхідних даних для навчання йде процес їхньої підготовки. А саме дані нормалізуються (рис 3.3), процес нормалізації програма виконує за допомогою мінмаксного масштабування а саме функції MinMaxScaler(). Це необхідно тому що, нероймережа краще вчиться коли дані для навчання знаходяться в діапазоні від 0 до 1. Це пов'язано з тим, що багато функцій активації, таких як сигмоїда і гіперболічний тангенс, мають значення від 0 до 1 або від -1 до 1. Це дозволяє підвищити швидкість навчання мережі і покращити її точність. Також слід зазначити що деякі індикатори не будуть нормалізовані оскільки вони мають значення або 0 або 1.

	Open	High	Low	Close	Volume	Price	RSI_14	RSI_14_A_60	RSI_14_B_40
14	0.000262	0.000111	0.000325	0.000192	0.000019	0.000183	0.349868	0	1
15	0.000198	0.000032	0.000264	0.000143	0.000049	0.000112	0.328960	0	1
16	0.000152	0.000000	0.000238	0.000139	0.000038	0.000084	0.327202	0	1
17	0.000144	0.000023	0.000280	0.000129	0.000019	0.000116	0.322696	0	1
18	0.000136	0.000006	0.000273	0.000167	0.000013	0.000104	0.353418	0	1
...
2994	0.413262	0.406747	0.416945	0.411474	0.030919	0.412530	0.572651	0	0
2995	0.411503	0.407451	0.418295	0.411799	0.026677	0.413553	0.574513	0	0
2996	0.411976	0.412891	0.417466	0.417519	0.034662	0.415918	0.607772	1	0
2997	0.417673	0.438955	0.422917	0.437115	0.054912	0.427811	0.697893	1	0
2998	0.446160	0.439565	0.448753	0.442217	0.049117	0.444915	0.717231	1	0

[2985 rows x 9 columns]

Рисунок 3.3 – Нормалізовані дані

Наступний крок це поділ даних на тестові (рис 3.4) та навчальні (рис 3.5). Для цього просто беруться n останніх записів та записуються в інший масив. В подальшому буде вибрано 30 останніх днів як тестові дані. Це потрібно для того щоб оцінити на скільки добре нейромережа справиться з передбаченням 30 днів щоб оцінити вірогідність її передбачення на 31-ий день.

Open	High	Low	Close	Volume	Price	RSI_14	RSI_14_A_60	RSI_14_B_40	
0.02080	0.348817	0.328103	0.340017	0.142163	0.000475	1	0	0	
0.02079	0.356279	0.348458	0.360845	0.155008	0.173889	0.633001	1	0	
0.02078	0.364773	0.348972	0.370088	0.161073	0.134500	0.572708	0.995729	1	0
0.02077	0.368828	0.344143	0.363020	0.168813	0.096466	0.342771	0.638170	1	0
0.02076	0.368051	0.400025	0.378051	0.400022	0.142458	0.390184	0.739778	1	0
0.02075	0.400487	0.401121	0.399451	0.397222	0.101757	0.401054	0.695649	1	0
0.02074	0.397308	0.411545	0.408353	0.411349	0.107308	0.400380	0.738011	1	0
0.02073	0.413381	0.412016	0.406617	0.400111	0.127457	0.414526	0.755080	1	0
0.02072	0.409244	0.415151	0.411309	0.415181	0.103438	0.412134	0.720880	1	0
0.02071	0.410488	0.411638	0.401121	0.402291	0.095067	0.409069	0.631171	1	0
0.02070	0.400137	0.410704	0.407718	0.417531	0.060892	0.412250	0.695060	1	0
0.02069	0.417306	0.418709	0.405341	0.405052	0.073997	0.408079	0.628011	1	0
0.02068	0.400019	0.401008	0.407313	0.405071	0.038301	0.400701	0.628118	1	0
0.02067	0.400101	0.407718	0.411022	0.412688	0.039314	0.410458	0.652821	1	0
0.02066	0.413205	0.407071	0.399005	0.399080	0.031706	0.401354	0.583136	0	0
0.02065	0.399080	0.397225	0.400019	0.401709	0.050441	0.399191	0.589080	0	0
0.02064	0.401708	0.414125	0.408071	0.417788	0.039080	0.412134	0.644814	1	0
0.02063	0.417306	0.418709	0.405341	0.405052	0.073997	0.408079	0.628011	1	0
0.02062	0.411362	0.410653	0.411367	0.410678	0.054111	0.410405	0.646600	1	0
0.02061	0.419371	0.418882	0.424547	0.418007	0.039011	0.421888	0.634221	1	0
0.02060	0.419370	0.419370	0.419370	0.419370	0.039011	0.419370	0.634221	1	0
0.02059	0.415202	0.412007	0.409229	0.409468	0.050503	0.411308	0.572815	0	0
0.02058	0.409041	0.414148	0.412342	0.410000	0.031011	0.408800	0.593800	0	0
0.02057	0.415201	0.415088	0.417406	0.415211	0.048358	0.417501	0.600800	0	0
0.02056	0.415205	0.407722	0.414310	0.413230	0.039300	0.412038	0.585957	0	0
0.02055	0.411202	0.400147	0.410405	0.411474	0.039319	0.412530	0.572703	0	0
0.02054	0.411361	0.409421	0.418205	0.411709	0.040477	0.413553	0.574513	0	0
0.02053	0.411370	0.412011	0.417466	0.417519	0.034662	0.415918	0.607772	1	0
0.02052	0.417673	0.438955	0.422917	0.437115	0.054912	0.427811	0.697893	1	0
0.02051	0.446160	0.439565	0.448753	0.442217	0.049117	0.444915	0.717231	1	0

[2955 rows x 9 columns]

Рисунок 3.4 – Тестові дані

Рисунок 3.5 – Навчальні дані

Далі йде найскладніший та найважливіший етап підготовки, дані поділяються на два масиви X та Y у масиві X будуть створюватися “історичні елементи” в кожному такому елементі буде зберігатися інформація про n інтервалів. Наприклад якщо $n = 3$ тоді “історичні елементи” будуть мати вигляд: $[[n_0, n_1, n_2], [n_1, n_2, n_3], [n_2, n_3, n_4] \dots]$ (рис 3.6). Кожен з елементів $n_0, n_1, n_2 \dots$ містить у собі рядок з рис 3.5. У масиві Y записуються значення які потрібно передбачити у нашому випадку це лише одне значення а саме ціна закриття. Елементи у масиві Y утворюються наступним чином якщо у масиві X ми маємо такий масив $[n_0, n_1, n_2]$ йому у відповідність у масиві Y буде такий масив $[ціна_закриття_n_4]$, тобто ціна закриття наступного дня після останнього дня у “історичному елементі” масиву X (рис 3.6). На рисунку 3.7 зображена індексація масиву X а на рисунку 3.7 зображена індексація масиву Y для $n = 7$. Цей процес відбувається окремо для навчальних та тестових даних.

Ефективність використання “історичних елементів буде досліджено пізніше.

```

[[[0.00026173 0.0001129 0.00032501 ... 0.34986772 0. 1. ]
 [0.00019782 0.0003165 0.0002637 ... 0.32896028 0. 1. ]
 [0.00015168 0. 0.0002382 ... 0.32720201 0. 1. ]
 ...
 [0.00013573 0.00000572 0.00027269 ... 0.35341774 0. 1. ]
 [0.00017673 0.00026911 0.00032781 ... 0.48945087 0. 0. ]
 [0.00037808 0.00055421 0.00054336 ... 0.63246875 1. 0. ]

[[[0.00019782 0.0003165 0.0002637 ... 0.32896028 0. 1. ]
 [0.00015168 0. 0.0002382 ... 0.32720201 0. 1. ]
 [0.00014351 0.0002332 0.00027964 ... 0.3226964 0. 1. ]
 ...
 [0.00017673 0.00026911 0.00032781 ... 0.48945087 0. 0. ]
 [0.00037808 0.00055421 0.00054336 ... 0.63246875 1. 0. ]
 [0.00070447 0.00063884 0.00042484 ... 0.47126897 0. 0. ]

[[[0.00015168 0. 0.0002382 ... 0.32720201 0. 1. ]
 [0.00014351 0.0002332 0.00027964 ... 0.3226964 0. 1. ]
 [0.00013573 0.00000572 0.00027269 ... 0.35341774 0. 1. ]
 ...
 [0.00037808 0.00055421 0.00054336 ... 0.63246875 1. 0. ]
 [0.00070447 0.00063884 0.00042484 ... 0.47126897 0. 0. ]
 [0.00036764 0.00025834 0.00044506 ... 0.4653792 0. 0. ]

...
]]]

```

Рисунок 3.6 – Масив X та Y, відповідно, для навчальних даних

```

[[ [ 0 1 2 ... 4 5 6 ]
 [ 1 2 3 ... 5 6 7 ]
 [ 2 3 4 ... 6 7 8 ]
 ...
 [2945 2946 2947 ... 2949 2950 2951]
 [2946 2947 2948 ... 2950 2951 2952]
 [2947 2948 2949 ... 2951 2952 2953]]
[[ [ 7 ]
 [ 8 ]
 [ 9 ]
 ...
 [2952]
 [2953]
 [2954]]]

```

Рисунок 3.7 – Індексація масиву X та Y, відповідно, для навчальних даних

З підготовкою даних завершено далі йде процес підготовки самої нейромережі. За створення та навчання якої відповідає бібліотека tensorflow. Достатньо лише створити модель та у функцію навчання передати наші масиви X та Y для тренувальних даних. Далі залишається викликати функцію predict() яка і запустить нейромережу, в цю функцію потрібно передати масив X для тестових значень і вона поверне нам масив схожий на масив Y проте з передбаченням на наступний день який нам і потрібен. Увесь цей процес зайняв приблизно 72.74 секунди. Далі потрібно денормалізувати дані, для зручності виведення, та додати їх до графіка (рис 3.8), на графіку зображено реальні ціни закриття періоду (в нашому випадку 1 день) криптовалюти (графік намальований зеленим кольором) та передбачених нейромережею (графік намальований червоним кольором). Хоч ціни на графіку не співпадають проте нас цікавить не ціна а ріст чи падіння ціни, з цим нейромережа впоралась не погано далші будуть продовжуватись спроби покращити цей результат змінюючи вхідні дані.




Рисунок 3.8 – Перше передбачення

3.2. Показники та індикатори

Отже ми отримали наше перше передбачення (рис 3.8) для нього ми використали такі показники як: ціна відкриття та закриття, мінімальна та максимальна ціна, об'єм та середня вартість. Це основний набір показників який в подальшому не буде мінятися, змінюватись будуть індикатори. Давайте детальніше розглянемо передбачення зроблене лише по показниках (рис 3.8). Ми бачимо що нейромережа погано реагує на дрібні зміни вартості проте не погано передбачає загальну тенденцію руху наприклад коли вона росте (рис 3.9) або коли падає (рис. 3.9). Проте на мою думку цей результат можна покращити.




Рисунок 3.9 – Ріст та падіння ціни відповідно

Один із способів покращити результати передбачення нейромережі це додавання нових навчальних даних, а саме індикаторів. Як було вказано раніше є 4 основні види індикаторів.

Спершу розглянемо індикатор RSI. Якщо додати його до навчальних даних, отримаємо наступну таблицю (рис. 3.10). Вона міститиме три нові стовпчики, а саме RSI_14, який відображає значення RSI за останні 14 днів, а також RSI_14_A_70 і RSI_14_B_30. Останні два стовпці показують критичні

точки для параметру RSI_14. Зокрема, якщо значення RSI_14 перевищує 70, то значення RSI_14_A_70 буде 1, в іншому випадку воно буде 0. Аналогічно, якщо значення RSI_14 менше 30, то значення RSI_14_B_30 буде 1, інакше - 0 (рис. 3.10).

Якщо спробувати передбачити ціну на тому ж проміжку часу, що й на рисунку 3.8, ми не помітимо значних змін, за винятком останніх днів. В цих днях параметр RSI вплинув на передбачення і дозволив нейромережі більш точно передбачити різке падіння ціни (рис 3.11). Час виконання склав 74.69 секунди.

RSI_14	RSI_14_A_70	RSI_14_B_30
16.447344	0	1
32.015818	0	0
30.628742	0	0
33.512867	0	0
31.480957	0	0
...
43.547701	0	0
43.497180	0	0
41.600970	0	0
37.405458	0	0
28.921326	0	1




Рисунок 3.10 – Навчальні дані із індикатором RSI

Рисунок 3.11 – Передбачення з використанням індикатора RSI

Для кращого відображення роботи RSI було вирішено зробити передбачення на більшому проміжку часу, наприклад, на 100 днів. Також слід зауважити, що не завжди можна візуально спостерігати поліпшення або погіршення точності передбачень на графіку. З цією метою буде введено поняття "Точність передбачення", яке відобразатиме відсоток правильних передбачень нейромережі. Іншими словами, це буде відсоток днів, коли нейромережа вірно передбачила зростання або падіння ціни закриття періоду криптовалюти.

Порівнюючи графіки (рис 3.12, рис 3.13), ми бачимо, що RSI не має значного впливу на здатність нейромережі передбачати загальну тенденцію. Однак, він покращує здатність передбачати невеликі зміни в ціні, що добре видно на рисунку 3.14. Час виконання склав 69.93 секунди.

Також варто відзначити, що точність передбачення на даних без використання індикатора RSI становить 51.61%, а з використанням - 54.84%. Таким чином, ми можемо зробити висновок, що RSI однозначно покращує роботу нейромережі.




Рисунок 3.12 – Передбачення без використання індикаторів на 100 днів

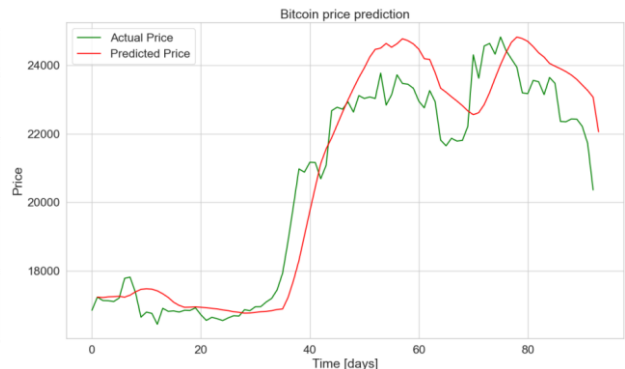


Рисунок 3.13 – Передбачення з використанням RSI на 100 днів



Рисунок 3.14 – Мала зміна ціни яку передбачила нейромережа завдяки індикатору RSI

Також, серед найефективніших індикаторів ціни варто відзначити індикатор MACD. Якщо ми додамо його до навчальних даних, отримаємо три нові стовпчики: MACD, що відображає значення самого індикатора MACD, а також MACDh і MACDs, які представляють повільну і швидку серії цього індикатора. При порівнянні графіків передбачень з використанням індикатора MACD (рис 3.15) та без нього (рис 3.12), ми бачимо, що він майже не впливає на передбачення нейромережі. Однак, якщо ми порівняємо точність передбачення - 51.61% без індикатора та 55.91% з використанням індикатора MACD, ми бачимо, що він навіть кращий за передбачення з використанням RSI. Проте, все ж, RSI показав себе краще, оскільки разом з ним нейромережа краще передбачає невеликі зміни в ціні. Час виконання становить 62.64 секунди.




Рисунок 3.15 – Передбачення з використанням MACD на 100 днів

Далі розглянемо індикатори волатильності, зокрема індикатор ATR. Як вже було зазначено, цей індикатор можна налаштувати на будь-який період, але зараз він буде використовуватися на 14-денному періоді. Таким чином, після додавання індикатора ATR до навчальних даних, вони будуть мати вигляд, як показано на рисунку 3.16.

Після навчання та передбачення порівнюємо графік передбачень на 100 днів з використанням індикатора ATR (рис 3.17) та без нього (рис 3.12). Візуально графіки майже не змінилися, проте при розгляді точності передбачення, яка складає 53.76% для навчальних даних з використанням індикатора ATR, можемо зробити висновок, що цей індикатор покращує передбачення нейромережі. Час виконання становить 66.18 секунди.

	Open	High	Low	Close	Volume	Price	ATR
33	374.645996	374.950012	368.045013	369.949805	45933400	371.497513	13.733528
34	378.174011	391.608002	369.993011	389.593994	69285504	380.800507	14.349177
35	388.898010	391.093994	385.571991	386.549011	43825000	388.332993	13.467736
36	386.589989	386.631012	372.386993	376.522003	49249300	379.590003	13.711808
37	376.514008	380.871002	374.983015	376.619995	37876300	377.887009	13.120726
...
2620	22354.144531	22613.685547	22307.142578	22435.513672	13317001733	22460.414062	705.066931
2621	22436.816486	22504.292969	22331.314493	22429.757812	17353192895	22457.003711	672.774902
2622	22428.322256	22527.407969	22011.263719	22219.765813	22765452204	22269.339844	661.587055
2623	22216.441486	22268.896484	21708.050781	21718.080074	22536575684	21888.473633	654.391987
2624	21720.880078	21802.716797	20210.386641	20363.021484	30364664171	21006.511719	721.393285

Рисунок 3.16 – Навчальні дані із індикатором ATR




Рисунок 3.17 – Передбачення з використанням ATR на 100 днів

Наступним індикатором є Bollinger Bands, який використовується для відстеження зміни тренду. Після додавання цього індикатора до навчальних даних, отримуємо п'ять нових стовпців, як показано на рисунку 3.18:

- BBL: Нижня лінія Болінджера (Lower Bollinger Band)
- BBM: Середня лінія Болінджера (Middle Bollinger Band)
- BBU: Верхня лінія Болінджера (Upper Bollinger Band)
- BBB: Ширина ліній Болінджера (Bollinger Band Width)
- BBP: Відсоткове відношення ціни до ліній Болінджера (Bollinger Band %B)

Графік передбачень з використанням цього індикатора (рис 3.19) майже не відрізняється від графіка без індикаторів (рис 3.12). Однак, є певне покращення у точності передбачення, яка складає 53.84%. Якщо врахувати похибку, то індикатори ATR та Bollinger Bands мають приблизно однакову ефективність. Час виконання склав 103.78 секунди.

Close	...	BBM	BBU	BBB	BBP
369.949005	...	385.400902	412.673027	14.152601	0.216709
389.593994	...	386.664052	412.200591	13.208644	0.557368
386.549011	...	386.614702	412.148124	13.208718	0.498714
376.522003	...	386.325851	412.176759	13.382955	0.310377
376.619995	...	385.798451	411.987298	13.576439	0.324764
...
22435.513672	...	23598.349023	25188.352726	13.475550	0.134329
22429.757812	...	23608.796680	25164.839920	13.181894	0.121142
22219.769531	...	23504.393066	25137.125921	13.893002	0.106603
21718.080078	...	23409.123340	25216.015154	15.437501	0.032057
20363.021484	...	23198.994336	25361.516050	18.643237	-0.155710

Рисунок 3.18 – Навчальні дані із індикатором Bollinger Bands




Рисунок 3.19 – Передбачення з використанням Bollinger Bands на 100 днів

Один із найефективніших індикаторів обсягів - індикатор MFI (Money Flow Index), дозволяє виявити момент зміни тренду. Перевіримо, чи цей індикатор дійсно покращить передбачення нейромережі. Додамо його до навчальних даних (рис 3.20) і проаналізуємо графік. Після аналізу графіка (рис 3.21), ми бачимо, що нейромережа, навчена з використанням індикатора MFI, добре передбачила різкий ріст (рис 3.22) та має високу точність передбачення - 58.06%. Робимо висновок, що індикатор MFI допомагає нейромережі передбачати зміну тренду, що також добре видно на рисунку 3.23. Час виконання становить 66.5 секунди.

	Open	High	Low	Close	Volume	Price	MFI
33	374.645996	374.950012	368.045013	369.949005	45933400	371.497513	37.630684
34	370.174011	391.608002	369.993011	389.593994	69285504	380.800507	37.291794
35	388.898010	391.093994	385.571991	386.549011	43825000	388.332993	45.713543
36	385.588989	386.631012	372.386993	376.522003	49249300	379.589003	46.220953
37	376.514008	380.871002	374.903015	376.619995	37076300	377.887009	39.564395
...
2620	22354.144531	22613.685547	22307.142578	22435.513672	13317001733	22460.414062	33.351938
2621	22436.816406	22584.292969	22331.314453	22429.757812	17353192895	22457.803711	24.971101
2622	22428.322266	22527.417969	22011.261719	22219.769531	22765452204	22269.339844	25.910823
2623	22216.441406	22268.896484	21708.050781	21718.080078	22536575684	21988.473633	26.814049
2624	21720.080078	21802.716797	20210.306641	20363.021484	30364664171	21006.511719	27.228182

Рисунок 3.20 – Навчальні дані із індикатором MFI




Рисунок 3.21 – Передбачення з використанням MFI на 100 днів




Рисунок 3.22 – Різкий ріст передбачений за допомогою індикатора MFI




Рисунок 3.23 – Поворот тенденції передбачений за допомогою індикатора MFI

Інший ефективний індикатор обсягів - індикатор OBV (On-Balance Volume), використовується для підтвердження напрямку тренду або його зміни. Додамо індикатор OBV до навчальних даних (рис 3.24) і проаналізуємо графік передбачення (рисунок 3.25). Після аналізу графіка, ми бачимо, що нейромережа так само добре передбачила зміну тренду, як і з використанням MFI. Однак, точність передбачення знизилася до 53.57%, що гірше, ніж при навчанні з використанням MFI. Час виконання становить 68.42 секунди.

	Open	High	Low	Close	Volume	Price	OBV
33	374.645996	374.950012	368.045013	369.949005	45933400	371.497513	-4.416103e+08
34	370.174011	391.608002	369.993011	389.593994	69285504	380.800507	-3.717240e+08
35	388.898010	391.093994	385.571991	386.549011	43825000	388.332993	-4.135400e+08
36	385.588989	386.631012	372.386993	376.522003	49249300	379.589003	-4.647991e+08
37	376.514008	380.871002	374.903015	376.619995	37076300	377.887009	-4.277220e+08
...
2620	22354.144531	22613.685547	22307.142578	22435.513672	13317001733	22460.414062	1.128743e+12
2621	22436.816406	22584.292969	22331.314453	22429.757812	17353192895	22457.803711	1.111390e+12
2622	22428.322266	22527.417969	22011.261719	22219.769531	22765452204	22269.339844	1.088624e+12
2623	22216.441406	22268.896484	21708.050781	21718.080078	22536575684	21988.473633	1.066080e+12
2624	21720.080078	21802.716797	20210.306641	20363.021484	30364664171	21006.511719	1.035723e+12

Рисунок 3.24 – Навчальні дані із індикатором OBV



Рисунок 3.25 – Передбачення з використанням OBV на 100 днів

Іншим індикатором, який використовується для визначення тренду на ринку, є ЕМА (Exponential Moving Average). Цей індикатор також використовується під час обрахунків інших індикаторів. Однак, тут ми перевіряємо, чи покращить він роботу нейромережі. Після додавання індикатора ЕМА до навчальних даних (рисунок 3.26) і аналізу графіка (рисунок 3.27), бачимо, що нейромережа справилась не краще, ніж коли вчилась на інших індикаторах. Однак, точність передбачення становить 56.99%. Час виконання склав 70.35 секунди.

	Open	High	Low	Close	Volume	Price	EMA
33	374.645996	374.950012	368.045013	369.949005	45933400	371.497513	379.359727
34	370.174011	391.608002	369.993011	389.593994	69285504	380.800507	381.220503
35	388.898010	391.093994	385.571991	386.549011	43825000	388.332993	382.189322
36	386.588989	386.631012	372.386993	376.522003	49249300	379.509003	381.158901
37	376.514008	380.871002	374.903015	376.619995	37076300	377.887009	380.333645
...
2620	22354.144531	22613.685547	22307.142578	22435.513672	13317001733	22460.414062	23028.670273
2621	22436.816406	22584.292969	22331.314453	22429.757812	17353192895	22457.003711	22919.777099
2622	22420.322266	22527.417969	22011.261719	22219.769531	22765452204	22269.339844	22792.502995
2623	22216.441406	22268.896484	21708.050781	21718.080078	22536575684	21988.473633	22597.153374
2624	21720.080078	21802.716797	20210.308641	20363.021484	30364664171	21806.511719	22190.947576

Рисунок 3.26 – Навчальні дані із індикатором ЕМА




Рисунок 3.27 – Передбачення з використанням ЕМА на 100 днів

Індикатор ADX (Average Directional Index) використовується для вимірювання сили тенденції на ринку. Після додавання цього індикатора до навчальних даних (рисунок 3.28) з'являються три нових стовпці, а саме "DMP" (Directional Movement Positive), що означає "Позитивний напрямок руху", і "DMN" (Directional Movement Negative), що означає "Негативний напрямок руху". Ці стовпці використовуються для розрахунку індикатора Directional Movement Index (DMI) і вказують на зміну ціни в певному напрямку протягом певного періоду.

Після здійснення передбачень і аналізу графіка (рисунок 3.29), бачимо, що нейромережа недостатньо швидко реагує на різку зміну тренду і показує себе гірше, ніж при навчанні на індикаторі ЕМА. Точність передбачення з використанням ADX становить 54.33%. Час виконання склав 76.70 секунди.

Volume	Price	ADX	DMP	DMN
45933400	371.497513	40.281197	13.318920	38.483660
69285504	380.800507	38.816813	20.775212	33.971325
43825000	388.332993	37.509940	20.127246	32.911780
49249300	379.509003	37.209858	18.522430	37.668155
37076300	377.887009	36.940255	17.879196	36.360041
...
817001733	22460.414062	23.916034	23.628562	23.277232
853192895	22457.803711	22.261246	22.993928	22.652035
765452204	22269.339844	21.151762	21.712546	24.845166
536575684	21988.473633	20.590495	20.383352	26.633826
864664171	21006.511719	21.756610	17.169467	37.264291




Рисунок 3.28 – Навчальні дані із індикатором ADX

Рисунок 3.29 – Передбачення з використанням ADX на 100 днів

Розглянувши результати дослідження кожного індикатора окремо, ми розуміємо, що технічний аналіз ринку зазвичай базується на комбінації декількох індикаторів, а не на одному. У нашому випадку, ми виявили, що неймережа краще вчиться з використанням індикатора RSI. Спробуємо поєднати його з індикаторами ATR та Bollinger Band.

Спочатку поєднаємо RSI та ATR (рис 3.30). За результатами графіка передбачень, бачимо, що усі зміни тренду передбачаються зі значною затримкою, а точність передбачення також низька і становить 48.73%. Час виконання склав 64.13 секунди.




Рисунок 3.30 – Передбачення з використанням RSI та ATR на 100 днів

Спробуємо об'єднати індикатор RSI з індикатором Bollinger Bands (рис 3.31). Після аналізу графіка передбачень бачимо, що поєднання цих двох індикаторів дало чудові результати. Неймережа здатна передбачати як малі

зміни в ціні, так і тренди руху, що підтверджується високою точністю передбачення в розмірі 58.06%. Час виконання склав 130.1 секунди.




Рисунок 3.31 – Передбачення з використанням RSI та Bollinger Bands на 100 днів

Продовжуємо додавати до комбінації індикатор RSI та Bollinger Bands ще один індикатор - OBV. Після аналізу графіка (рис 3.32) бачимо, що додавання індикатора OBV погіршило результат. Це підтверджується також низькою точністю передбачення, яка становить 49%. Час виконання склав 135.63 секунди..




Рисунок 3.32 – Передбачення з використанням RSI, Bollinger Bands та OBV на 100 днів

В результаті досліджень було виявлено що поєднання більш ніж двох індикаторів може приводити до суперечностей та погіршувати результат передбачення. Це може бути пов'язано зі складністю врахування багатьох різних сигналів та їх взаємодії.

Також цікаво, що зв'язка RSI та Bollinger Bands виявилась найкращою серед розглянутих індикаторів. Це може свідчити про їх доповнювальність та здатність спільно виявляти тенденції та зміни ринку.

3.3. Історичні елементи

Раніше було визначено сутність історичного елемента та його створення. Узагалі, історичний елемент - це набір даних з n інтервалів, що утворюють масив. У цьому випадку досліджується, як історичний елемент впливає на передбачення нейромережі. Усі налаштування однакові: не використовуються індикатори, лише стандартний набір показників, і тести проводяться на проміжку 100 днів. Почнемо з $n = 1$, що означає, що навчальні дані матимуть такий вигляд, де показники даного інтервалу відповідають ціні закриття наступного інтервалу. Аналізуючи графік (рис. 3.33), помічаємо, що нейромережа намагається передбачити кожен змінювання ціни, але точність передбачень дуже низька - 43.43%. Час виконання становить 71.5 секунди.




Рисунок 3.33 – Передбачення при $n = 1$ на 100 днів

Тепер передбачимо ціну, встановивши значення $n = 3$. Це означає, що навчальні дані будуть складатися з масиву, де ціна закриття 3-го дня відповідатиме даним 0-го, 1-го і 2-го днів. Після аналізу графіка (рис. 3.34) ми помічаємо, що графік став більш плавним, а точність передбачень зросла до 55.67%. Час виконання склав 75.38 секунди




Рисунок 3.34 – Передбачення при $n = 3$ на 100 днів

При встановленні $n = 7$ і аналізі графіка (рис. 3.35) ми спостерігаємо, що графік став ще більш плавним, і тепер для людини стало легше визначити тенденцію руху ціни криптовалюти. Час виконання склав 76.73 секунди.




Рисунок 3.35 – Передбачення при $n = 7$ на 100 днів

Тож, історичні елементи мають значний вплив на плавність графіка, і чим більше значення n , тим більш плавним буде графік передбачень. Користувач може змінювати значення n в залежності від обраної торговельної стратегії. Наприклад, якщо користувач планує частіше продавати або купувати, йому варто вибрати менше значення n . У разі, якщо користувач націлений на тривалу гру або довготермінові інвестиції, йому слід встановити більше значення n .

3.4. Епохи

Епоха в нейромережі - це один прохід вперед та назад через всі навчальні приклади у навчальному наборі даних. У процесі кожної епохи, модель виконує передбачення на кожному навчальному прикладі, обчислює втрати (помилки) та корегує свої внутрішні ваги, щоб зменшити ці втрати.

Кількість епох визначає, скільки разів навчальний набір даних буде пройдений через нейромережу. Чим більше епох, тим більше навчання отримує модель, але занадто велика кількість епох може привести до перенавчання моделі, тобто вона буде дуже точно передбачати навчальні дані, але не зможе правильно передбачити нові дані, які вона не бачила раніше.

Кількість епох залежить від конкретної задачі, розміру навчального набору даних та складності нейромережі. Зазвичай, навчання нейромережі займає декілька десятків або сотень епох, але може бути і менше, якщо задача є простішою.

Тож у цьому розділі буде досліджено як різна кількість епох впливає на навчання нейромережі. Тести будуть проводитись на 100 денному проміжку, без використання індикаторів лише з показниками та n історичного елемента буде дорівнювати 3, змінюватись буде лише кількість епох.

Почнемо з навчання за допомогою 10 епох та подивимось на результат на графіку (рис. 3.36). Потім спробуємо навчити нейромережу з використанням 30 епох (рис. 3.37) і порівняємо результати. Ми бачимо, що при використанні 30 епох графік стає ще більш плавним і краще передбачає тенденції. Це підтверджується також точністю передбачень, яка становить 53.61% для 30 епох та 47.42% для 10 епох. Час виконання для 10 епох склав 41.42 секунди, а для 30 епох - 72.09 секунди.




Рисунок 3.36 – Передбачення при використаних 10-ти епох




Рисунок 3.37 – Передбачення при використаних 30-ти епох

Після використання 60 епох (рис. 3.38) графік став трохи більш плавним, але точність передбачення знизилася до 50.52%. Час виконання склав 132.72 секунди. В останньому тесті використовуємо 100 епох (рис. 3.39).




Рисунок 3.38 – Передбачення при використаних 60-ти епох




Рисунок 3.39 – Передбачення при використаних 100-ти епох

Графік з 100 епох майже не відрізняється від графіка з 60 епох, і точність передбачення також майже однакова - 51.92%. Час виконання склав 183.99 секунд. Загалом, для цієї задачі доцільно використовувати від 50 до 100 епох. Якщо взяти менше, можна не отримати очікуваних результатів, а після 100 епох точність не змінюється, хоча є ризик перенавчання моделі. В такому випадку модель добре передбачатиме події, на яких вона навчалася, але погано справлятиметься з новими випадками. Для передбачення тенденції ціни криптовалюти це критично, оскільки на ринку рідко зустрічаються дуже схожі ситуації.

ВИСНОВОК

У даній дипломній роботі було розглянуто застосування нейронних мереж для прогнозування тенденцій цін криптовалют. Було написано програму за допомогою якої можна обрати криптовалюту та період часу за який можна взяти тестові дані, обрати показники та індикатори по яких нейромережа буде навчатись та обрати кількість епох та розмірність історичного елемента для навчання нейромережі а також побачити результати прогнозування.

Для реалізації нейромережі було використано тип нейромережі LSTM, який є добре підходящим для аналізу часових рядів. Для покращення роботи нейромережі було використано такі індикатори, як RSI, Bollinger Bands, Money Flow Index та інші. Також було проведено обробку даних та їх підготовку для навчання нейромережі.

Результати експериментів показали, що нейромережа може бути успішно використана для прогнозування тенденцій цін криптовалют. Однак, варто зазначити, що навіть найкраща модель нейронної мережі не здатна передбачити ціновий рух криптовалют з абсолютною точністю, оскільки ціни криптовалют залежать від багатьох факторів, включаючи геополітичні події, новини з ринку та технічний аналіз. Тому, використання нейронних мереж для прогнозування цін криптовалют повинно бути додатковим інструментом для аналізу ринку, а не єдиним методом прийняття інвестиційних рішень.

Програму, яка використовує нейронні мережі для прогнозування тенденцій цін криптовалют, можна застосовувати в різних сферах, де аналіз цінових рухів криптовалют є важливим:

- **Трейдинг:** Програма може бути використана трейдерами для отримання додаткової інформації та аналізу ринку криптовалют перед прийняттям рішень щодо купівлі, продажу або управління позиціями.
- **Інвестування:** Інвестори можуть використовувати програму для аналізу та оцінки потенційних інвестиційних можливостей в криптовалюти на основі прогнозів тенденцій цін.

- Дослідження ринку: Аналітики та дослідники ринку можуть використовувати програму для проведення досліджень та аналізу цінових рухів криптовалют з метою виявлення трендів, кореляцій та інших важливих факторів.
- Фінансовий аналіз: Банки, фінансові установи та фінансові аналітики можуть використовувати програму для аналізу криптовалютного ринку та виявлення можливих ризиків та можливостей.

Отже, використання нейронних мереж для прогнозування тенденцій цін криптовалют є перспективним напрямом дослідження. Також за допомогою написаної програми можна визначити який набір показників та індикаторів найбільше підходить для отримання хороших результатів прогнозування на теперішньому ринку критовалюти

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Кравченко В. Що таке нейронні мережі та як вони працюють? Класифікація штучних нейромереж [Електронний ресурс]. – 2022 – Режим доступу: <https://livingfo.com/shcho-take-nejronni-merezhi-ta-iaak-vony-pratsiuiut/>
2. Great learning team Types of Neural Networks and Definition of Neural Network [Electronic resource]. – 2022 – Available from: <https://www.mygreatlearning.com/blog/types-of-neural-networks/>
3. Coinbase What are fundamental analysis and technical analysis? [Electronic resource]. – 2023 – Available from: <https://www.coinbase.com/learn/crypto-basics/what-are-technical-analysis-and-fundamental-analysis>
4. James Royal, Brian Baker, CFA, Brian Beers 12 most popular types of cryptocurrency [Electronic resource]. – 2023 – Available from: <https://www.bankrate.com/investing/types-of-cryptocurrency/>
5. Matt Johnes Types of Technical Indicators [Electronic resource]. – 2019 – Available from: <https://tradesanta.com/blog/types-of-technical-indicators>
6. Aishwarya.27 Introduction to Recurrent Neural Network [Electronic resource]. – 2023 – Available from: <https://www.geeksforgeeks.org/introduction-to-recurrent-neural-network/>
7. Hemanth Pedomallu RNN vs GRU vs LSTM [Electronic resource]. – 2020 – Available from: <https://medium.com/analytics-vidhya/rnn-vs-gru-vs-lstm-863b0b7b1573>
8. IntelliPaat What is LSTM? Introduction to Long Short Term Memory [Electronic resource]. – 2023 – Available from: <https://intellipaate.com/blog/what-is-lstm/?US>
9. Python team What is Python? Executive Summary [Electronic resource]. – 2023 – Available from: <https://www.python.org/doc/essays/blurb/>
10. Ran Aroussi Download market data from Yahoo! Finance's API [Electronic resource]. – 2023 – Available from: <https://pypi.org/project/yfinance/>
11. Jason Brownlee How to Use StandardScaler and MinMaxScaler Transforms in Python [Electronic resource]. – 2020 – Available from: <https://machinelearningmastery.com/standardscaler-and-minmaxscaler-transforms-in-python/>
12. Pandas User Guide [Electronic resource]. – 2023 – Available from: https://pandas.pydata.org/docs/user_guide/index.html
13. Python Library Pandas TA: A Technical Analysis Library in Python 3 [Electronic resource]. – 2022 – Available from: <https://morioh.com/p/0aa3e75ff555>

14. NumPy Documentation [Electronic resource]. – 2022 – Available from: <https://numpy.org/doc/stable/>
15. John Hunter, Darren Dale, Eric Firing, Michael Droettboom Matplotlib [Electronic resource]. – 2023 – Available from: <https://matplotlib.org/stable/tutorials/index>
16. Introduction to TensorFlow [Electronic resource]. – 2023 – Available from: <https://www.tensorflow.org/learn>
17. TensorFlow Tutorials [Electronic resource]. – 2023 – Available from: <https://www.tensorflow.org/tutorials>
18. GoodCrypto Relative Strength Index (RSI) Indicator for Crypto Trading: An Ultimate Guide by Good Crypto [Electronic resource]. – 2023 – Available from: <https://goodcrypto.app/relative-strength-index-rsi-indicator-for-crypto-trading-an-ultimate-guide-by-good-crypto/>
19. GoodCrypto Moving Averages, SMA, EMA, WMA: A Complete Guide for Traders Explained by Good Crypto [Electronic resource]. – 2023 – Available from: <https://goodcrypto.app/moving-averages-sma-ema-wma-a-complete-guide-for-traders-explained-by-good-crypto/>
20. GoodCrypto The MACD indicator and the MACD trading strategies: A Detailed Guide by Good Crypto [Electronic resource]. – 2023 – Available from: <https://goodcrypto.app/the-macd-indicator-and-the-macd-trading-strategies-a-detailed-guide-by-good-crypto/>
21. Adam Hayes Average True Range (ATR) Formula, What It Means, and How to Use It [Electronic resource]. – 2022 – Available from: <https://www.investopedia.com/terms/a/atr.asp>
22. GoodCrypto Bollinger Bands: a Complete Guide for Traders exemplified by Good Crypto Charts [Electronic resource]. – 2023 – Available from: <https://goodcrypto.app/bollinger-bands-a-complete-guide-for-traders-exemplified-by-good-crypto-charts/>
23. Julia Gerstein What is the MFI indicator? [Electronic resource]. – 2020 – Available from: <https://tradesanta.com/blog/mfi-indicator>
24. Alexandria On-Balance Volume (OBV) [Electronic resource]. – 2023 – Available from: <https://coinmarketcap.com/alexandria/glossary/on-balance-volume-obv>
25. Dmytro Spilka What Is an Average Directional Index (ADX), and How Do You Use It in Crypto Trading? [Electronic resource]. – 2023 – Available from: <https://www.makeuseof.com/what-is-an-average-directional-index-adx/>