

Київський національний університет імені Тараса Шевченка

Економічний факультет

Кафедра економічної кібернетики

КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

«Прогнозування курсу криптовалют методами глибинного навчання»

студентки 4 курсу
спеціальності 051 «Економіка»
ОПП «Економічна кібернетика»
денної форми навчання
Будікової Софії Євгенівни

Науковий керівник:
кандидат економічних наук,
доцент
Шпирко Віктор Васильович
Засвідчую, що у цій дипломній
роботі немає запозичень із
праць інших авторів без
відповідних посилань
Студент _____

Роботу допущено до захисту перед ЕК
рішенням кафедри економічної кібернетики
від 05.06.2024р., протокол № 15

Завідувач кафедри:
доктор економічних наук, професор
Ляшенко Олена Ігорівна _____

РЕФЕРАТ

Кваліфікаційна робота бакалавра містить: 55 ст., 9 рис., 1 табл., 30 джерел

Ключові слова: курс, криптовалюта, прогнозування, волатильність, глибинне навчання, моделювання часових рядів, метрики оцінки якості.

Об'єкт дослідження: курси криптовалют, які демонструють високий рівень волатильності та складність у прогнозуванні.

Мета дослідження: вивчення та оцінка ефективності методів глибинного навчання у прогнозуванні курсу криптовалют.

Методи дослідження: аналіз літератури та попередніх досліджень з метою розуміння сутності та історії розвитку криптовалют, а також сучасних методів їхнього прогнозування; використання різних моделей часових рядів для прогнозування курсу криптовалют; проведення порівняльного аналізу для визначення найефективніших методів прогнозування.

Наукова новизна, теоретична значимість дослідження: в роботі проведений всебічний аналіз та порівняння ефективності різних моделей часових рядів, включаючи методи глибинного навчання, для прогнозування курсу криптовалют, детально досліджено як традиційні статистичні методи, такі як ARIMA, Facebook Prophet та експоненційне згладжування, так і сучасні методи глибинного навчання, зокрема LSTM. Дана робота сприяє розвитку теоретичних основ аналізу криптовалют, їхніх цінових динамік та факторів, що впливають на їхнє коливання. Результати дослідження можуть бути використані для подальшого розвитку теоретичних моделей прогнозування фінансових ринків, а також для розробки нових підходів до аналізу великих даних у фінансовій сфері.

Практична цінність: можливість застосування отриманих результатів для покращення точності прогнозування курсу криптовалют, що може бути корисним для інвесторів, фінансових аналітиків та трейдерів.

RESUME

Taras Shevchenko National University of Kyiv,

Faculty of Economics, Department of Economic Cybernetics

Key words: exchange rate, cryptocurrency, forecasting, volatility, deep learning, time series modeling, quality assessment metrics.

The graduation research of student

deals with cryptocurrency rates, which demonstrate a high level of volatility and are difficult to predict

The work is interesting for a comprehensive analysis and comparison of the effectiveness of various time series models, including deep learning methods, for forecasting cryptocurrency rates, and use of both traditional statistical methods, such as ARIMA, Facebook Prophet, and exponential smoothing, and modern deep learning methods, such as LSTM. This work contributes to the development of the theoretical framework for analyzing cryptocurrencies, their price dynamics, and the factors that influence their fluctuations. The results of the study can be used to further develop theoretical models for forecasting financial markets, as well as to develop new approaches to big data analysis in the financial sector.

Pages 55, tables 9, bibliog 30, tables 1.

ЗМІСТ

ВСТУП.....	5
РОЗДІЛ I. Криптовалюта, як об'єкт дослідження	7
1.1 Загальний огляд	7
1.2 Огляд методик та попередніх досліджень.....	13
РОЗДІЛ II. Огляд моделей та підготовка даних	19
2.1 Використання глибинного навчання для прогнозування курсу криптовалют	19
2.2 Збір та попередня обробка даних	32
РОЗДІЛ III. Тренування моделей та порівняння результатів	35
3.1 Тренування та оцінка моделей.....	35
3.2 Метрики оцінки якості передбачень	48
3.3 Порівняльний аналіз результатів моделей	48
ВИСНОВКИ	50
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	52

ВСТУП

Криптовалюта становить важливий аспект сучасного фінансового ландшафту, привертаючи увагу як інвесторів, так і науковців. Вона постійно еволюціонує, що робить її об'єктом численних досліджень та інвестицій. У контексті дослідження динаміки її вартості викликає особливий інтерес використання глибинного навчання, що відкриває нові перспективи для прогнозування курсів криптовалют. Огляд історії розвитку криптовалют і попередніх методів їхнього аналізу закладає фундамент для розуміння сучасного стану ринку та важливості точного прогнозування їхнього курсу. У цій дипломній роботі буде розглянуто застосування методів глибинного навчання для прогнозування курсу криптовалют, що може надати цінні інсайти для інвесторів та сприяти розвитку наукових досліджень у цій галузі.

Актуальність теми дослідження

Зростання популярності криптовалют на фінансових ринках створює нові виклики для інвесторів та аналітиків. Висока волатильність криптовалют робить їхню вартість важко передбачуваною, що вимагає застосування сучасних методів аналізу даних. Глибинне навчання, зокрема рекурентні нейронні мережі (RNN) та мережі довгої короткочасної пам'яті (LSTM), демонструють високу ефективність у прогнозуванні часових рядів, що робить їхню перспективними інструментами для прогнозування курсів криптовалют. Дане дослідження є актуальним, оскільки воно спрямоване на покращення методів аналізу та прогнозування, що може підвищити точність передбачень і відповідно зменшити ризики інвестицій.

Метою та завданням даного дослідження є вивчення та оцінка ефективності методів глибинного навчання у прогнозуванні курсу криптовалют. Зокрема, дослідження спрямоване на аналіз і порівняння результатів моделі LSTM, з традиційними методами прогнозування, а також на розробку рекомендацій щодо найкращих підходів у залежності від конкретних умов ринку.

Об'єктом дослідження є курси криптовалют, які демонструють високий рівень волатильності та складність у прогнозуванні.

Предметом дослідження є методи традиційного статистичного аналізу та методи глибокого навчання, зокрема мережі довгої короткочасної пам'яті (LSTM), що застосовуються для прогнозування курсів криптовалют.

РОЗДІЛ I. КРИПТОВАЛЮТА, ЯК ОБ'ЄКТ ДОСЛІДЖЕННЯ

1.1 Загальний огляд

Криптовалюта становить важливий аспект сучасного фінансового ландшафту, привертаючи увагу як інвесторів, так і науковців. У контексті дослідження динаміки її вартості викликає особливий інтерес використання глибинного навчання, що відкриває нові перспективи для прогнозування курсів криптовалют. Огляд історії розвитку криптовалют і попередніх методів їхнього аналізу закладає фундамент для розуміння сучасного стану ринку та важливості точного прогнозування їхнього курсу.

Один із підходів до прогнозування ціни Bitcoin включає застосування моделі з поверхневим двонаправленим LSTM (Bi-LSTM), яка базується на обробці даних за допомогою запропонованого методу інженерії ознак. Такий підхід демонструє, що шляхом використання методу обробки даних можливо досягти вищої ефективності прогнозування порівняно з іншими популярними моделями. Це підкреслює значення розробки спеціалізованих методів для підвищення акуратності прогнозів у світі криптовалют. [1]

Ще одне дослідження пропонує мультимодальний підхід з використанням ансамблю AdaBoost-LSTM, який включає в себе аналіз різноманітних джерел інформації - від соціальних медіа та об'ємів пошуку до інформації з блокчейна та торгових даних. Цей підхід демонструє значну перевагу використання мультимодальності для прогнозування змін в обмінному курсі криптовалют, надаючи суттєве покращення ефективності порівняно з існуючими методами. Такі знахідки акцентують на важливості комплексного огляду щодо джерел інформації для точного прогнозування. [2]

В іншому дослідженні порівнюються три алгоритми: LSTM, машина опорних векторів (SVM) і поліноміальна регресія для прогнозування ціни криптовалют. Пріоритет дається машині опорних векторів через її здатність досягати найменших значень середньоквадратичної помилки, що свідчить про значну перспективність цього методу у контексті фінансового прогнозування. [3]

Загалом, аналіз сучасних методів прогнозування курсу криптовалют, зокрема з використанням глибинного навчання, відкриває нові горизонти для розробки більш точних і надійних моделей. Інтеграція різних підходів та адаптація специфічних методів обробки і аналізу даних має потенціал значно покращити якість прогнозів, що становить важливий крок на шляху до більш ефективного і обґрунтованого інвестування в криптовалюту.

1.1.1 Сутність та історія розвитку криптовалют

Криптовалюта, як новий вид цифрових активів, вже стала не лише об'єктом фінансових спекуляцій, але й важливим елементом світової економіки. Вперше концепція електронних грошей, що не контролюється центральним органом, була введена в 1998 році Вей Дай, однак справжній прорив стався з появою Bitcoin у 2009 році, створеним загадковою особою (або групою осіб) під псевдонімом Сатоші Накамото. Bitcoin продемонстрував можливість здійснення безпечних фінансових операцій без участі посередників і став першою криптовалютою, що отримала широке визнання.

З того часу відбулась динамічна еволюція ринку криптовалют, що включає появу тисяч інших криптовалют, заснованих на блокчейні або інших технологіях, які пропонують варіації оригінального механізму, оптимізації щодо швидкості транзакцій, конфіденційності, масштабованості та інших аспектах. Ці нововведення постійно трансформують методи взаємодії в фінансовому світі та способи зберігання цінностей.

Головним чином, історія розвитку криптовалют відзначена не лише бурхливим зростанням кількості проєктів, але й значними коливаннями їхніх котирувань, що зробило їх об'єктом інтенсивного аналізу, спекуляцій та інвестиційних стратегій. Ці коливання курсу криптовалют, породжені змінами в регуляції, технічними інноваціями, загальною економічною ситуацією, спорадичними подіями та психологією учасників ринку, підкреслюють потребу в розвитку дедалі точніших методів прогнозування їхньої динаміки.

У зв'язку з цим, аналіз історії та сутності криптовалют є не лише академічним інтересом, але й практичною необхідністю для розуміння механізмів, що лежать в основі їхньої цінності та ціноутворення, що, в свою чергу, є критично важливим для розробки ефективних моделей прогнозування. Отже, дослідження історії криптовалют та вивчення їхньої природи становить підґрунтя для подальших аналітичних та прогностичних зусиль на шляху до створення точних та надійних моделей для прогнозування курсу криптовалют.

1.1.2 Сучасний стан ринку криптовалют

Розділ, присвячений сучасному стану ринку криптовалют, розпочинається з аналізу його динаміки останніх років, що підкреслює непередбачувану волатильність та стрімкий розвиток цієї сфери. Важливо відмітити, що за цей період спостерігалось як значне зростання капіталізації ринку криптовалют, так і моменти його глибоких спадів, що привертало увагу інвесторів, аналітиків та науковців. Особливий наголос робиться на появі нових криптовалют та технологій блокчейн, які не тільки збільшили кількість активів на ринку, але й внесли значний вклад у його диверсифікацію.

Аналізуючи структуру ринку, відзначається лідерство деяких криптовалют, таких як Bitcoin, Ethereum, що займають значну частку ринкової капіталізації. Разом з тим, акцентується на тому, що швидкий розвиток менш відомих альткоїнів також вносить суттєві зміни у баланс сил на ринку. Важливим аспектом є те, що динаміка ринку активно впливає на розробку фінансових інструментів, пов'язаних з криптовалютами, що забезпечують більшу ліквідність та доступність для ширшого кола інвесторів.

Аналізуючи регуляторне середовище, яке безпосередньо впливає на ринок криптовалют, незважаючи на стрімкий розвиток, ринок криптовалют продовжує залишатися предметом для дебатів з точки зору правового регулювання в різних юрисдикціях. Огляд останніх тенденцій в регулюванні криптовалют показує, що влада різних країн намагається знайти баланс між інноваційним розвитком ринку та захистом інвесторів.

Розглянувши вплив глобальних економічних та політичних подій на ринок криптовалют, бачимо, що криптовалютний ринок не існує в ізоляції та є чутливим до глобальних економічних трендів, таких як інфляційні процеси, зміни в політиці центральних банків, геополітичні конфлікти тощо. Цей аспект розглядається як ключовий для розуміння поведінки ринку та ефективного прогнозування його курсів.

Підсумовуючи, можна сказати, що сучасний стан ринку криптовалют характеризується великою волатильністю, швидкими змінами у регуляторному середовищі та незмінним впливом глобальної економічної обстановки. Усе це створює як можливості, так і виклики для учасників ринку, а також для тих, хто займається аналізом та прогнозуванням його динаміки.

1.1.3 Основні фактори, що впливають на коливання курсу криптовалют

В останні роки криптовалюта стала значущим елементом світової фінансової системи, що зумовило збільшення інтересу до вивчення факторів, які впливають на її курс. Відомо, що криптовалютні ринки характеризуються високою волатильністю цін, що робить важливим знання про основні фактори, які можуть спричиняти ці коливання. До таких факторів належать різноманітні економічні, політичні, технологічні та соціальні елементи, які визначають динаміку цін на ринку криптовалют.

Значний вплив на коливання курсу криптовалют мають новини та події, пов'язані з криптовалютою. Це можуть бути законодавчі зміни у різних країнах, хакерські атаки на криптобіржі, аносування нових технологічних рішень або партнерств в галузі. Фундаментальний аналіз, який включає вивчення макроекономічних показників, таких як виробництво і використання криптовалюти, може також виявити важливі тренди.

На курс криптовалют суттєво впливають психологічні фактори. Очікування інвесторів, страх і жадібність грають ключову роль у формуванні цінових трендів. Технічний аналіз, що включає вивчення графіків цін і торговельних об'ємів, використовується трейдерами для прогнозування короткострокових змін.

Крім того, ступінь прийняття криптовалют суспільством і бізнесом має значний вплив на її курс. Чим більше компаній та користувачів приймають криптовалюту як засіб платежу, тим вищою стає її вартість. Зростання числа мережевих учасників та збільшення кількості транзакцій в мережі також сприятливо впливає на курс.

Зважаючи на це, можна зробити висновок, що вплив на ціну криптовалют має багатофакторний характер, де значущу роль відіграють як економічні показники, так і психологічні тенденції серед інвесторів. Тому, розуміння цих факторів є ключовим для точного прогнозування майбутнього курсу криптовалют, що в свою чергу підтверджує необхідність подальших досліджень у цій сфері.

1.1.4 Значення та перспективи прогнозування курсу криптовалют

У розділі, присвяченому значенню та перспективам прогнозування курсу криптовалют, розглянуто важливість точного передбачення майбутньої поведінки цін на криптовалютному ринку. Особлива увага приділена оцінці потенціалу, який відкривається для інвесторів, трейдерів та фінансових аналітиків завдяки вдосконаленню технік прогнозування. Прогнозування криптовалют вбачається не лише як спосіб зниження ризиків, але й як засіб для генерації прибутку, оскільки точні прогнози дозволяють зробити обґрунтовані інвестиційні рішення.

З поширенням технологій глибинного навчання та аналітичних моделей спостерігається значне підвищення інтересу та ефективності у сфері прогнозування фінансових ринків, особливо у контексті криптовалют. Еволюція даних методів дозволила виявити нові закономірності у поведінці криптовалютних ринків і глибше розуміння факторів, що впливають на коливання курсів. Така динаміка підтверджує перспективність подальших досліджень і розвитку аналітичних інструментів в даній галузі.

Проте, слід визнати, що прогнозування криптовалют є складним завданням через високу волатильність, непередбачуваність ринкових трендів і вплив неочікуваних зовнішніх факторів. В цьому контексті роль глибинного навчання і використання алгоритмів, здатних адаптуватися до цих умов, набуває особливої значущості. Основною перевагою цих методів є можливість врахування величезної кількості

даних з різноманітних джерел і їхньої крос-валідації для вибудовування точного прогнозу.

Підсумовуючи, актуальність і значення прогнозування курсу криптовалют високо оцінюється у фінансовому світі, враховуючи потенціал цієї сфери для досягнення зисків і зменшення інвестиційних ризиків. Перспективи використання глибинного навчання в цьому напрямі обнадійливі, але ще потребують ретельної розробки та тестування моделей для досягнення оптимальної точності і надійності прогнозів.

1.1.5 Проблеми та виклики у прогнозуванні курсу криптовалют

У процесі дослідження ринку криптовалют особливе місце приділяється прогнозуванню їх курсу, що представляє значний інтерес для інвесторів, трейдерів та фінансових аналітиків. Однак, активне використання методів глибинного навчання для прогнозування курсу криптовалют суттєво ускладнюється рядом специфічних проблем та викликів, що є властивими саме цьому ринку.

Волатильність є однією з ключових характеристик ринку криптовалют. Її присутність значно ускладнює будь-які спроби прогнозування, оскільки незначні події або навіть інформаційні повідомлення можуть спровокувати значні коливання курсів. Ця непередбачуваність зумовлює високий ризик для використання стандартних моделей глибинного навчання без адаптації їх до особливостей криптовалютного ринку.

Іншою важливою проблемою є відсутність довгострокових історичних даних. Більшість криптовалют є відносно новими активами, тому обмеження доступних даних зменшує ефективність навчання моделей, спираючись на історичні тенденції.

Також, ринок криптовалют характеризується високою фрагментацією та нестабільністю регулювань у різних країнах, що веде до появи арбітражних моментів та спекулятивних операцій, що додатково ускладнює прогнозування.

Наявність шуму в даних та їх неконсистентність також є значною перешкодою. Дані із різних джерел можуть відрізнятися за якістю та актуальністю, а іноді і зовсім містити помилкову інформацію, що впливає на точність моделей прогнозування.

Окремою проблемою є висока залежність курсу криптовалют від аспектів, пов'язаних з соціальними медіа та новинними потоками. Аналіз тональності новин та визначення їх впливу на коливання курсів вимагають від глибинних моделей навчання не лише визначення закономірностей у числових даних, але й підхід до обробки і розуміння природної мови.

З огляду на викладене, маємо, що прогнозування курсу криптовалют методами глибинного навчання стоїть перед рядом важливих викликів, кожен з яких має бути ґрунтовно досліджений та за можливості подоланий для підвищення ефективності прогнозувань. Розробка адаптивних моделей, здатних враховувати специфіку ринку криптовалют, є основним напрямом подолання цих складнощів, стало предметом подальших досліджень у цій галузі.

1.2 Огляд методик та попередніх досліджень

У цьому розділі проведено детальний огляд сучасних методик та результатів попередніх досліджень у сфері прогнозування курсу криптовалют. Перша частина розділу присвячена аналізу методів прогнозування фінансових даних, розглядаються основні принципи та виклики, з якими зіштовхуються фахівці у цій області. Особливу увагу приділено вибору метрик та критеріїв для оцінки ефективності моделей, а також обговорюються висновки щодо релевантності різних методів для прогнозування курсів криптовалют.

Далі увага зосереджена на застосуванні глибинного навчання в контексті прогнозування курсів. Розглядаються основні архітектури та принципи роботи рекурентних нейронних мереж (RNN) та мереж довгої короткочасної пам'яті (LSTM), доведено їх ефективність у вирішенні подібного роду задач. Важливе місце займають попередні дослідження, де проводиться аналіз успіхів та недоліки використання RNN та LSTM для прогнозування курсу криптовалют.

Традиційні статистичні методи також детально розглянуті у цьому розділі. Метод ARIMA, модель Facebook Prophet та методи експоненційного згладжування оцінюються з точки зору їх придатності та ефективності при прогнозуванні курсів

криптовалют. Надається порівняльний аналіз цих традиційних методів, виділяючи їх сильні та слабкі сторони.

В останній частині розділу висвітлюється порівняння між глибинним навчанням та статистичними методами. Надаються підказки щодо вибору найефективнішого підходу в залежності від конкретних умов та задач, що стоять перед дослідником. Також розглядається можливість синтезу різних методів для розробки гібридних моделей, які могли б запропонувати кращі результати у прогнозуванні курсу криптовалют.

Підсумовуючи, цей розділ узагальнює основні підходи та методики, які використовуються в сучасних дослідженнях для прогнозування курсів криптовалют. Зроблено порівняння між традиційними та інноваційними методами, що дає можливість вибрати найбільш оптимальний підхід для покращення точності прогнозів. Рекомендації щодо синтезу моделей відкривають перспективу для подальших досліджень в цій динамічно розвиваючій сфері.

1.2.1 Аналіз методів прогнозування фінансових даних

Аналіз ефективності методів прогнозування фінансових даних на ринку криптовалют є фундаментальним для розробки ефективних стратегій інвестування та управління ризиками. У цьому контексті, існуючі методики мають різну призму аналізу та передбачення, базуючись на історичних даних, математичних моделях, а також новітніх підходах машинного та глибинного навчання.

У одному з джерел аналізуються основні безпекові та приватні питання Bitcoin та технології блокчейн, які лежать в основі цього процесу. Порушується тема ризику подвійних витрат, оцінюється ймовірність успіху таких атак і вивчається можливість отримання прибутку атакуючими. Особлива увага приділяється аналізу безпеки мережі Bitcoin peer-to-peer та зберіганню криптовалюти, порівнюються різні типи гаманців Bitcoin з точки зору безпеки. Цей аналіз важливий не лише для розуміння загальних ризиків, але й для розробки стратегій прогнозування, оскільки безпека та приватність безпосередньо впливають на поведінку ринку. [4]

Інше дослідження зосереджується на аналізі мережі Bitcoin та Bitcoin Cash, зокрема на їх глобальній структурі та визначенні малого світу поведінки. Результати свідчать, що принцип "найбільш підхожий збагачується", у поєднанні зі зростаючою кількістю з'єднань, може бути механізмом, що призводить ці мережі до їх поточної структури. Ці знахідки важливі для розуміння поведінкових аспектів ринку та можуть бути інтегровані в моделі прогнозування курсу криптовалют. [5]

Останнє розглянуте дослідження занурюється в аналіз мережі транзакцій Bitcoin, подаючи огляд недавніх результатів щодо її структурних властивостей. Система, що зростає з часом, стає все більш розрідженою, з чіткою структурою ядра та периферії. Така топологія мережі, разом з високим ступенем нерівномірного розподілу Bitcoin, вказує на зростаючу централізацію системи, що є ключовим фактором для моделей прогнозування. [6]

Як висновок, аналіз методів прогнозування фінансових даних на ринку криптовалют показує, що цей процес вимагає глибокого розуміння як технічних аспектів криптовалют, так і впливу зовнішніх та внутрішніх факторів на ринок. Джерела, що аналізуються в даному розділі, подають цінну інформацію для розробки ефективних методик прогнозування, зокрема, з урахуванням безпекових вимог, структури мережі та поведінкових аспектів ринку.

1.2.2 Основні принципи та виклики фінансового прогнозування

У сфері фінансового прогнозування з часом виникає багато викликів, серед яких основними є потреба у високій точності прогнозів та здатність моделей адаптуватися до швидко змінюваних умов ринку. Особливо актуальним це стає в контексті прогнозування курсу криптовалют, де волатильність вища, ніж у традиційних фінансових ринках. Сучасні методи фінансового прогнозування покликані вирішити цю проблему, забезпечуючи достовірність результатів і скорочення часу на обчислення.

Одне із джерел згадує про виклики, пов'язані із виконанням прогнозування на основі байєсівських методів. Підхід, що базується на проективному прогностичному виведенні, демонструє здатність до ефективного вибору моделі, що мінімізує ризики

перенавчання та покращує прогностичні характеристики порівняно з іншими методами. Важливою особливістю розглянутого підходу є його здатність застосовуватися у широкому спектрі сфер, що робить його перспективним для включення в арсенал засобів прогнозування тенденцій на ринку криптовалют. [7]

Друге дослідження наголошує на значенні швидкого та точного оцінювання моделей генерації зображень на основі текстових описів. Розвиток таких моделей вимагає врахування ефективності оцінювання їхньої роботи, що суттєво впливає на можливості удосконалення та оптимізації. І хоча цей аспект не є безпосередньо пов'язаним із фінансовим прогнозуванням, принципи, закладені в методологію оцінки та вибору підмножини даних для ефективного аналізу, застосовуватимуться і для поліпшення моделей прогнозування курсів криптовалют. [8]

Обидва згадані підходи демонструють напрямки розвитку в області точного та ефективного прогнозування, що є ключовим для успішного вирішення завдань в сфері криптовалют. Основні принципи та виклики, що супроводжують сучасне фінансове прогнозування, вказують на необхідність інтеграції байєсівських методів та інших інноваційних підходів для забезпечення високої точності та оперативності прогнозів. Це, в свою чергу, вимагає подальших досліджень та розробок у даній області.

1.2.3 Вибір метрик та критеріїв ефективності моделей

У розділі, присвяченому вибору метрик та критеріїв ефективності моделей, розглядаються основні підходи та інструменти для оцінки якості прогностичних моделей у сфері фінансових ринків. Визначення ефективності моделі є ключовим аспектом дослідження, оскільки дає змогу не лише оцінити потенційну точність прогнозів, але й порівняти різні методології між собою.

Так, у одному з джерел розглядаються підходи до прогнозування фінансових ринків за допомогою аналізу часових рядів та обробки природних мов, зокрема, на основі аналізу тональності повідомлень у Twitter. Показано, що такий підхід дає змогу значно підвищити точність прогнозів, використовуючи моделі глибинного навчання, такі як LSTM. Це продемонстровано на прикладі акцій компаній, таких як Tesla та

Apple, і підкреслює важливість врахування публічних настроїв у фінансовому прогнозуванні. [9]

Далі у іншому дослідженні розглядається методика використання перетворення Хілберта-Хуанга та машинного навчання для аналізу фінансових часових рядів. Емпіричне порівняння різних моделей показало переваги використання інтегрованих характеристик ННТ для підвищення точності прогнозування. [10]

У третьому джерелі аналізуються потенціал та пастки використання машинного навчання для фінансового прогнозування та планування. Підкреслюється, що застосування машинного навчання вимагає особливої уваги, щоб уникнути помилок у плануванні та розподілі ресурсів. [11]

Згідно з останнім вивченим джерелом, робиться порівняльний аналіз між традиційною моделлю ARIMA та моделями на основі глибинного навчання, зокрема LSTM та BiLSTM. Значний інтерес представляє вивчення можливостей BiLSTM моделей, що, завдяки подвійному проходженню через вхідні дані, показують вищу точність прогнозування. [12]

Таким чином, важливість адекватного вибору метрик та критеріїв для оцінювання ефективності моделей прогнозування не може бути недооцінена. Вивчені джерела підкреслюють значення інтеграції як статистичних, так і інноваційних підходів глибинного навчання для підвищення точності і надійності прогнозів на фінансових ринках. Особливо це стосується використання методів обробки природних мов та аналітики великих даних, що відкриває нові можливості для удосконалення фінансового прогнозування.

Вивчаючи основні методи прогнозування фінансових даних, зокрема застосування статистичних і технік глибинного навчання, виявлено їх високу релевантність для ринку криптовалют. Багатовимірність даних, що характеризують динаміку курсів криптовалют, вимагає використання складних аналітичних засобів. Методи глибинного навчання, зокрема нейронні мережі, що мають здатність до самонавчання на основі великих обсягів даних, показали свою спроможність чітко аналізувати та прогнозувати коливання курсів криптовалют. Ці методи демонструють

здатність адаптуватися до швидкозмінних умов ринку та ефективно обробляти неструктуровану інформацію.

Застосування глибинного навчання, особливо таких його елементів, як рекурентні нейронні мережі (RNN) та мережі з довгою короткочасною пам'яттю (LSTM), в контексті прогнозування курсів криптовалют, виявилось особливо перспективним. Вони враховують не тільки кількісні показники ринку але і сентимент аналіз, що дає змогу створювати прогнози із вищою точністю. В той же час, слід пам'ятати, що успіх прогнозування значною мірою залежить від правильного вибору параметрів моделі та її навчання, а також своєчасного внесення корективів у відповідь на зміни ринкових умов. Тому, підсумовуючи, обрані методи глибинного навчання, на зразок RNN та LSTM, вважаються дуже обнадійливими для прогнозування курсу криптовалют, проте їх ефективність тісно пов'язана з якістю та обсягом доступних даних, а також глибиною аналізу змін на ринку.

РОЗДІЛ II. ОГЛЯД МОДЕЛЕЙ ТА ПІДГОТОВКА ДАНИХ

2.1 Використання глибинного навчання для прогнозування курсу криптовалют

У сучасному світі криптовалюти займають значне місце в фінансовій системі, при цьому прогнозування їх курсу є складною задачею через високу волатильність та непередбачуваність. Одним із перспективних напрямків у цій галузі є використання глибинного навчання, зокрема рекурентних нейронних мереж (RNN) та їх модифікацій, як-от мережі з довгою короткочасною пам'яттю (LSTM). Цей підхід дає змогу аналізувати та прогнозувати часові ряди курсів криптовалют, враховуючи їх історичну динаміку.

У одному з джерел розглядається застосування чотирьох алгоритмів машинного навчання - Support Vector Machines (SVM), Artificial Neural Network (ANN), Naive Bayes (NB) і Random Forest (RF), а також логістичної регресії в якості базової моделі для прогнозування курсу Bitcoin. Для оцінки ефективності моделей використовувалися статистичні метрики, як-от: F статистика, точність, середня абсолютна помилка (MAE) та коренева середньоквадратична помилка (RMSE). Емпіричні результати демонструють перевагу алгоритму Random Forest для неперервних даних, тоді як ANN показав найкращі результати для дискретних даних. [13]

Інше дослідження описує прогнозування ціни Ethereum з використанням нейронної мережі на основі архітектури трансформера. Тут припускається, що ціни на криптовалюти є взаємопов'язаними з іншими криптовалютами та настроєм у спільноті. Незважаючи на менші обсяги даних та менш складну архітектуру, модель на основі трансформера показала кращі результати в порівнянні з ANN і MLP за деякими параметрами. [14]

Третє дослідження фокусується на використанні Support Vector Machines для розробки торгових стратегій та прогнозування курсу криптовалют. Пропонуються класифікатори на основі різних технічних індикаторів для прогнозування короткострокових рухів цін. Виявлено, що SVM забезпечує найбільшу дохідність

торгових стратегій, що панує над ринковими показниками для Bitcoin, Ethereum та Litecoin. [15]

Четверте джерело пропонує підхід на основі глибокого навчання з використанням моделі Bidirectional-LSTM для прогнозування денного курсу закриття Bitcoin. З застосуванням запропонованих інженерії ознак, цей підхід показав кращі результати порівняно з іншими популярними моделями прогнозування цін. [16]

Підсумовуючи, застосування глибинного навчання для прогнозування курсу криптовалют відкриває нові можливості для точнішого та ефективнішого аналізу фінансових часових рядів. Рекурентні нейронні мережі та інші алгоритми глибинного навчання демонструють високу ефективність у вирішенні цього завдання, що свідчить про їх перевагу та релевантність для сучасного ринку криптовалют.

2.1.1 Архітектура та принцип роботи рекурентних нейронних мереж (RNN)

У сучасному світі швидкого розвитку технологій та поширення криптовалют, прогнозування їх курсу займає важливу нішу в дослідницькій та практичній діяльності. Для ефективного вирішення цього завдання активно застосовуються методи глибинного навчання, серед яких рекурентні нейронні мережі (RNN) відіграють ключову роль. Основною особливістю й перевагою RNN є їх здатність обробляти послідовні дані, зокрема, часові ряди, що робить їх ідеальним вибором для аналізу фінансових даних, зокрема, курсів криптовалют. Принцип роботи таких мереж ґрунтується на використанні внутрішньої пам'яті для зберігання інформації про попередні дані в послідовності, дозволяючи розглянути залежності між часовими точками і, як наслідок, підвищити точність прогнозування.

Важливість рекурентних мереж в контексті прогнозування курсу криптовалют полягає також у їх адаптивності до постійно змінної динаміки ринку та здатності до самонавчання на основі нових даних. Ця особливість робить RNN незамінними інструментами у визначенні тенденцій ринку криптовалют. Окрім того, було зазначено, що архітектура і спосіб тренування рекурентних мереж значно впливають на їх продуктивність і точність прогнозування. Таким чином, глибше розуміння цих параметрів може відкрити шлях до розробки більш ефективних моделей для

прогнозування курсу криптовалют, забезпечуючи інвесторам та аналітикам важливий інструмент для прийняття рішень.

2.1.2 Мережі довгої короткочасної пам'яті (LSTM)

Сучасний світ фінансових технологій важко уявити без криптовалют та методів їх прогнозування. Однією з перспективних технологій у цій сфері є використання мереж довгої короткочасної пам'яті (LSTM), які є розвиненою формою рекурентних нейронних мереж (RNN). Особливість LSTM полягає в їх здатності зберігати інформацію протягом тривалого часу, що робить їх ідеально придатними для аналізу та прогнозування часових рядів, таких як курси криптовалют.

У одному з досліджень описується унікальний підхід до подолання проблеми катастрофічного забування в мережах LSTM, що є критичним для неперервного навчання на послідовних даних. Представлено два нових та легко імплементованих способи відокремлення пам'яті LSTM, або для кожного завдання, або для кожної цільової мітки, що робить зайвим застосування складних методів, таких як регуляризація чи гіпермережі. [17]

У іншому джерелі розглядається новаторська архітектура адаптивного керування, що інтегрує адаптивний нейронний контролер та мережу LSTM. Ця архітектура покращує часову складність системи завдяки здатності LSTM аналізувати залежності в послідовностях вхідних даних, забезпечуючи швидке реагування на несподівані зміни в динаміці об'єкта керування. [18]

У тьюторіалі про розуміння LSTM наголошується на значенні та історії розвитку довгих короткочасних пам'яті мереж. Особлива увага приділяється питанню ефективності роботи LSTM, що становить базове розуміння для глибшого дослідження та використання цієї технології. [19]

Оглядове дослідження RNN та LSTM надає широкий огляд архітектур, принципів роботи та їх застосувань. У цьому контексті демонструється, як проблеми, такі як зникнення або вибух градієнта, можуть бути подолані за рахунок використання LSTM, що робить їх привабливими для прогнозування часових рядів. [20]

У підсумку, мережі LSTM мають велике значення для прогнозування курсу криптовалют завдяки їх здатності точно аналізувати та прогнозувати залежності в часових рядах. Вдосконалення в методах навчання та архітектурах мереж дозволяють ефективно застосовувати LSTM в сфері фінансових технологій, перевищуючи в потенціалі традиційні методи прогнозування. Це відкриває нові перспективи для розробки точних і надійних систем прогнозування курсів криптовалют.

2.1.3 Попередні дослідження та успіхи застосування RNN та LSTM у прогнозуванні курсу криптовалют

У останні роки з'явився значний інтерес до прогнозування курсу криптовалют з використанням методів глибокого навчання. Серед них особливу увагу привертають рекурентні нейронні мережі (RNN) та мережі довгої короткочасної пам'яті (LSTM) завдяки їх здатності ефективно працювати з послідовними даними, що є ключовим у фінансовому прогнозуванні. У певних дослідженнях, які зосереджені на прогнозуванні курсу криптовалют, технології RNN та LSTM показали високу ефективність, зокрема завдяки здатності моделювати складні взаємозалежності в часових рядах даних. Це дозволило з великою точністю прогнозувати зміни вартості криптовалют і тим самим відкривати нові можливості для інвесторів на цьому швидкозростаючому ринку.

Практичне використання технологій RNN та LSTM у прогнозуванні курсу криптовалют висвітлено у численних дослідженнях, які демонструють позитивний вплив застосування цих методів на якість прогнозів. Однак, слід зазначити, що успішне застосування цих моделей вимагає великих обсягів даних та ретельного підбору гіперпараметрів, що може виявитись досить складним завданням в умовах високої волатильності ринку криптовалют. Незважаючи на ці виклики, дослідження підтверджують, що RNN та LSTM здатні забезпечити вищу точність прогнозування порівняно з традиційними методами та статистичними моделями, вказуючи на їхній значний потенціал у сфері фінансового аналізу та прогнозування. Таким чином, результати попередніх досліджень є міцною основою для подальшого вивчення та

вдосконалення методів глибинного навчання в контексті прогнозування курсу криптовалют.

2.1.4 Застосування традиційних статистичних методів

У сучасну еру цифрової економіки прогнозування курсу криптовалют набуває особливої актуальності, оскільки здатність точно передбачити флуктуації ціни може значно підвищити ефективність інвестиційних та торгових стратегій. Традиційні статистичні методи відіграють ключову роль у цьому процесі завдяки своїй спроможності виявляти закономірності в історичних даних, що дає змогу зробити обґрунтований прогноз майбутніх вартостей.

Серед таких методів особливе місце займає модель ARIMA, що використовується для аналізу та прогнозування часових рядів. Цей метод дає змогу моделювати та прогнозувати курс криптовалют на основі історичної динаміки, враховуючи тренди та циклічні коливання. Модель Facebook Prophet вирізняється своєю здатністю до гнучкого прогнозування з урахуванням сезонності та виразних трендів у даних. Інший важливий метод, експоненційне згладжування, використовується для визначення будь-яких закономірностей в даних, що сприяє підвищенню точності прогнозів.

Порівняння цих методів демонструє, що кожен з них має свої переваги в певних умовах та типах даних. Приміром, ARIMA є бездоганним вибором для моделювання лінійних трендів, тоді як Facebook Prophet ефективніший для даних з виразною сезонністю та святковими періодами, а експоненційне згладжування оптимально використовувати для даних, що характеризуються високим рівнем шуму. Це вказує на необхідність вибору методу аналізу, який відповідає специфіці даних та цілям прогнозування.

Підсумовуючи, традиційні статистичні методи залишаються важливим інструментом в арсеналі прогнозування курсу криптовалют. Вибір між методами залежить від характеристик даних та специфічних цілей аналітика. Ефективне застосування цих методів може значно покращити здатність передбачати майбутні

коливання курсу криптовалют, забезпечуючи таким чином більш обґрунтоване прийняття інвестиційних рішень.

Далі розглянемо детальніше кожен з вищевказаних статистичних методів прогнозування часових рядів:

Метод ARIMA

ARIMA, що розшифровується як Авторегресивна Інтегрована Ковзаюча Середня (AutoRegressive Integrated Moving Average), є однією з найпопулярніших моделей у сфері економічного прогнозування. Метод особливо ефективний у випадках, коли спостережувані дані виявляють певну ступінь стаціонарності або коли можливе їхнє перетворення в стаціонарний часовий ряд.

Модель ARIMA спирається на комбінацію трьох основних компонентів: авторегресії (AR), інтеграції (I), що допомагає досягти стаціонарності даних, та ковзних середніх (MA). Вводячи даний метод у контекст прогнозування курсу криптовалют, важливо оцінити стаціонарність існуючого часового ряду, оскільки криптовалютні ринки часто демонструють високу волатильність та непередбачуваність. Для цього можуть бути застосовані додаткові статистичні тести, такі як тест Дікі-Фуллера.

Використання ARIMA у прогнозуванні курсу криптовалют має свої особливості, пов'язані з високою непостійністю та непередбачуваністю ринку. Ці виклики вимагають ретельного підбору параметрів моделі (порядків AR, I, та MA компонентів) та можуть потребувати інтеграції з іншими методами аналізу для покращення точності прогнозу. Окрім того, є потреба постійного оновлення моделі з урахуванням нових даних, щоб адаптуватися до швидко змінюваних умов ринку.

На завершення, можна сказати, що, незважаючи на свою традиційність, метод ARIMA зберігає своє значення для аналізу часових рядів у фінансах, зокрема у прогнозуванні курсу криптовалют. Завдяки своїй гнучкості та адаптивності, ARIMA здатна надавати цінні прогнози, що можуть бути використані для розробки інвестиційних стратегій або ризик-менеджменту на криптовалютних ринках. Разом із

цим, важливо розуміти обмеження і складнощі, пов'язані з застосуванням цього методу, та розглядати його як частину комплексного інструментарію прогнозування.

Модель Facebook Prophet

Досить перспективним у аспекті проблематика прогнозування курсу криптовалют є застосування моделі Facebook Prophet, яка є однією з найбільш інноваційних розробок у сфері аналізу часових рядів. Ця модель вирізняється серед традиційних статистичних методів своєю гнучкістю та здатністю до адаптації під специфіку даних, що робить її дуже ефективним інструментом для прогнозування курсу криптовалют.

Facebook Prophet була розроблена як відкритий інструмент спеціалістами компанії Facebook для вирішення практичних завдань прогнозування. Основною її особливістю є здатність автоматично виділяти та враховувати тренди, сезонні коливання та свята, які можуть впливати на динаміку курсу криптовалют. Завдяки цим властивостям, модель здатна забезпечувати високу точність прогнозів.

Принцип роботи моделі базується на декомпозиції часових рядів на компоненти, включаючи тренд, сезонність і святкові дні. Ця декомпозиція дає змогу детально аналізувати кожен з факторів впливу на коливання курсу та прогнозувати його з максимальною точністю. Для покращення якості прогнозів, модель також дає змогу користувачам вносити власні корективи у прогнозовані тренди.

Застосування моделі Facebook Prophet в контексті криптовалют вже продемонструвало свою ефективність. Аналіз ринкових даних з її допомогою відкриває нові можливості для інвесторів та фінансових аналітиків, дозволяючи їм краще орієнтуватися у динаміці цін і відповідно адаптувати свої інвестиційні стратегії. Таким чином, наразі модель Facebook Prophet є однією з найбільш перспективних технологій для прогнозування курсу криптовалют на основі аналізу часових рядів.

Підсумовуючи, модель Facebook Prophet представляє собою важливий інструмент для аналізу та прогнозування курсу криптовалют. Її ефективність та гнучкість робить її незамінним компонентом для аналітичних досліджень у сфері

фінансових ринків. Більше того, успішний досвід застосування цієї моделі підтверджує її значущість і перспективність для розвитку методів прогнозування у фінансовій сфері.

Метод експоненційного згладжування

Цей метод базується на припущенні, що майбутні значення часового ряду залежать переважно від його останніх спостережень, з врахуванням згладжування старіших даних.

Експоненційне згладжування використовується для мінімізації впливу випадкових коливань, через що стає можливим точніше визначати довгострокові тенденції у даних. Цей метод передбачає використання коефіцієнта згладжування α , значення якого варіюється від 0 до 1. Він допомагає збалансувати вагу між останніми значеннями та історичними даними, дозволяючи аналітикам більш точно адаптуватися до змін у динаміці ринку.

Однією з переваг методу експоненційного згладжування є його простота та легкість імплементації у порівнянні з більш складними моделями глибинного навчання. Проте, цей метод має і обмеження, зокрема, у випадках складних часових рядів з нестабільними або нерівномірними трендами, де потрібний більш глибокий аналіз і наявність автоматичної корекції моделі.

Практичне застосування методу експоненційного згладжування до прогнозування курсу криптовалют демонструє його користь у допомозі аналітикам виявити короткострокові тренди на ринку. Однак, через високу волатильність та непередбачуваність ринку криптовалют, цей метод краще використовувати у комбінації з іншими підходами та інструментами аналізу для розробки більш інформативних і точних прогнозів.

У підсумку, метод експоненційного згладжування представляє важливий інструмент у наборі аналітика для прогнозування курсу криптовалют, особливо коли потрібно швидко реагувати на зміни ринкової динаміки. Його ефективність найкраще проявляється у короткостроковому аналізі або як доповнення до більш комплексних моделей, що дає змогу формувати більш надійні та точні прогнози.

2.1.5 Порівняння та синтез ефективності традиційних методів та методів глибинного навчання для прогнозування курсу криптовалют

У даному розділі проводиться глибинне дослідження ефективності традиційних методів прогнозування курсу криптовалют порівняно з сучасними підходами. Вважається, що ринок криптовалют характеризується високою волатильністю та непередбачуваністю, що ставить під сумнів ефективність застосування традиційних статистичних методів. Водночас, зі зростанням доступності великих даних та розвитком технологій штучного інтелекту, глибинне навчання займає все більш вагомую роль у прогнозуванні фінансових ринків, зокрема криптовалют.

На прикладі кількох досліджень аналізується, як традиційні методи, такі як ARIMA, порівнюються зі складнішими моделями на основі глибинного навчання. В одному з досліджень була проаналізована здатність моделі ARIMA передбачати курс Bitcoin, порівняно з моделями, заснованими на нейронних мережах з довготривалою пам'яттю (LSTM), які демонструють кращі результати з точки зору помилки середньоквадратичного відхилення (Root-mean-square error, RMSE). [21]

З іншого боку, розглядаються дослідження, що підкреслюють значення методів глибинного навчання, наприклад, використання моделей GRU (Gated Recurrent Unit) з рекурентними механізмами відкидання для прогнозування курсу Bitcoin. Такі моделі, як показано у дослідженнях, забезпечують вищу точність прогнозування порівняно з попередньо використовуваними методами завдяки кращій обробці часових залежностей у даних. [22]

Підсумовуючи, можна відзначити, що сучасні методи глибинного навчання мають значну перевагу над традиційними статистичними методами у контексті прогнозування курсу криптовалют. Результати аналізу різних досліджень вказують на те, що моделі, засновані на LSTM та GRU, забезпечують значно кращі показники точності та надійності прогнозів. Використання цих сучасних підходів дає змогу ефективно враховувати високу волатильність криптовалютного ринку і може сприяти розробці більш точних моделей прогнозування курсів.

Застосування глибинного навчання, зокрема рекурентних нейронних мереж та мереж довгої короткочасної пам'яті, продемонструвало високу ефективність у задачах прогнозування курсу криптовалют, завдяки здатності цих моделей знаходити складні закономірності в часових рядах даних. Статистичні методи, такі як ARIMA і метод експоненційного згладжування, традиційно використовувались для аналізу фінансових ринків і мають свої переваги, зокрема щодо їх простоти та прозорості моделювання. Модель Facebook Prophet, яка була спеціально розроблена для підвищення точності прогнозів за умови мінімальної взаємодії з користувачем, також стала значущим доповненням до арсеналу інструментів прогнозування.

Порівняльний аналіз показує, що хоча глибинне навчання може виявити більш складні нелінійні залежності у даних та здійснити більш точні прогнози у багатьох випадках, статистичні методи продовжують залишатися цінними за умови, коли потрібна більш проста і швидка реалізація або коли обсяг даних є обмеженим. Таким чином, вибір методу прогнозування залежить від конкретної ситуації, обсягу наявних даних, вимог до точності прогнозу та обчислювальних ресурсів.

З огляду на особливості кожного методу, розробка гібридних моделей, які поєднують в собі переваги глибинного навчання та статистичних методів, видається перспективним напрямком дослідження. Синтез різних методів може допомогти у досягненні вищої точності прогнозів та більшої гнучкості моделі у пристосуванні до змінних умов ринку. Такий підхід відкриває нові можливості для створення ефективних інструментів прогнозування курсу криптовалют, що є надзвичайно важливим у контексті їхньої високої волатильності та непередбачуваності.

З огляду на значний прогрес у сфері машинного навчання та аналітики даних, з'являється новий інтерес до дослідження ефективності різних підходів у фінансовому прогнозуванні. В одному з досліджень аргументується, що моделі, побудовані на основі глибинного навчання, зокрема рекурентні нейронні мережі та мережі з довгою короткочасною пам'яттю (LSTM), демонструють вражаючі результати у прогнозуванні часових рядів фінансових даних завдяки своїй здатності вловлювати

складні нелінійні залежності між даними. Це становить особливий інтерес, виходячи з великої волатильності та непередбачуваності ринку криптовалют.

Натомість, статистичні методи, такі як ARIMA та експоненційне згладжування, традиційно використовувалися для прогнозування фінансових часових рядів завдяки їх ефективності в моделюванні лінійних залежностей. Хоча ці методи можуть бути не такими ефективними за умови складних патернів, як методи глибинного навчання, вони залишаються цінними завдяки своїй простоті в імплементації та розумінні. У певних дослідженнях підкреслюється, що комбінація статистичних методів та глибинного навчання може призвести до покращення точності прогнозів, запропонувавши гібридний підхід до аналізу фінансових даних. Такий синтетичний підхід дає змогу використати переваги обох методологій, забезпечуючи більш точне та надійне прогнозування.

2.1.6 Рекомендації щодо найкращого підходу в залежності від обставин та синтез різних методів прогнозування та розробка гібридних моделей

На основі проведеного аналізу методик прогнозування курсу криптовалют, значну увагу було приділено визначенню оптимальних підходів за різних обставин. Розглянувши можливості як статистичних методів, так і методів глибинного навчання, далі надаються рекомендації щодо їх застосування в контексті специфічних потреб прогнозування курсу криптовалют. Враховуючи широку варіативність криптовалютного ринку, а також нестабільність його динаміки, визначення найкращого методу виявляється ключовим для підвищення точності прогнозів.

Для короткострокового прогнозування, де важливу роль відіграє здатність оперативно реагувати на ринкові зміни, рекомендується застосовувати моделі глибинного навчання, особливо архітектури RNN та LSTM. Ці моделі ефективно враховують послідовність даних і здатні вловлювати складні залежності у динаміці курсів криптовалют. Для довгострокового прогнозування, де важливіше отримати загальну тенденцію, без деталізації коливань у короткі терміни, ефективно застосовувати статистичні методи, наприклад ARIMA або метод експоненційного згладжування.

Значну увагу слід також приділити обмеженню доступних даних. У випадку наявності великого масиву історичних даних з високою частотністю оновлення, методи глибинного навчання покажуть кращі результати через можливість "навчити" модель вловлювати складні патерни. У ситуації, коли об'єм даних є обмеженим, а їх якість – під питанням, може бути доцільним застосування більш простих статистичних методів, що не вимагають масивної вибірки для високоякісного навчання.

Гнучкий підхід, що поєднує можливості як статистичних, так і методів глибинного навчання, рекомендується для сценаріїв з високим рівнем невизначеності ринкових умов. Розроблення гібридних моделей, що враховують переваги кожної з методик, може дозволити досягти більшої точності прогнозів, а також підвищити їхню надійність у різних ринкових ситуаціях.

Отже, вибір методу прогнозування курсу криптовалют вимагає комплексного підходу до аналізу доступних даних, цілей прогнозування, а також специфіки ринку. Правильна оцінка обставин та адаптація методології дозволить досягти оптимального балансу між точністю та швидкістю прогнозів, забезпечивши при цьому надійне рішення для учасників криптовалютного ринку.

У сучасних дослідженнях все частіше звертають увагу на необхідність синтезу різноманітних методів прогнозування для підвищення точності та надійності аналітичних моделей. Використання гібридних моделей дає змогу поєднувати переваги різних підходів та алгоритмів, зменшуючи при цьому вплив їх недоліків. Такий підхід є особливо актуальним у прогнозуванні курсу криптовалют, враховуючи високу волатильність та непередбачуваність цього ринку.

У одному з досліджень представлено розробку алгоритму MFABA, який є прикладом глибокого навчання, орієнтованого на аналіз значущості входів у нейронні мережі. Цей підхід дає змогу не тільки підвищити ефективність моделей прогнозування, але й зробити результати їх роботи більш зрозумілими для людей. Застосування таких алгоритмів може стати ключовим у синтезі ефективних моделей прогнозування курсу криптовалют. [23]

Інше дослідження вводить у застосування FinLangNet – інноваційну модель глибокого навчання, призначену для прогнозування кредитного ризику. Модель адаптує техніки обробки природної мови до аналізу фінансових даних, демонструючи високу ефективність. Гібридизація таких підходів із традиційними методами аналізу даних може значно підвищити точність прогнозів на ринку криптовалют. [24]

Комплексний аналіз різних моделей прогнозування океанської циркуляції демонструє, що гібридні моделі, які поєднують лінійну регресію із глибоким навчанням, мають високу точність та ефективність. Оскільки поведінка криптовалютного ринку схожа на динамічні системи, результати цього дослідження можна застосовувати для підвищення точності прогнозування курсу криптовалют. [25]

У роботі, присвяченій дослідженню глибоких нейронних мереж для прогнозування часових рядів, аналізується ефективність різних архітектур, зокрема LSTM та CNN. На основі отриманих висновків можна зробити висновок про можливість створення ефективних гібридних моделей для прогнозування курсу криптовалют, використовуючи наявні архітектури глибокого навчання. [26]

Використання глибоких нейронних мереж для аналізу виборів показує, як за допомогою методів статистичного навчання можна розробити моделі, які одночасно мають високу здатність передбачувати та інтерпретуватись. Цей підхід можна адаптувати для синтезу гібридних моделей прогнозування курсу криптовалют, які будуть поєднувати точність передбачення з можливістю аналізу впливу різних факторів. [27]

Таким чином, аналіз сучасних наукових досліджень вказує на значний потенціал гібридних моделей в прогнозуванні курсу криптовалют. Поєднання різноманітних алгоритмів і методів дає змогу створювати моделі, які ефективно враховують складність і непередбачуваність цього ринку, підвищуючи точність прогнозів.

2.2 Збір та попередня обробка даних

2.2.1. Опис датасету про курси криптовалют

Датасет про історичні ціни криптовалют містить інформацію про щоденні ціни для низки провідних криптовалют за ринковою капіталізацією. Дані охоплюють період з 28 квітня 2013 року і були отримані з відкритого джерела CoinMarketCap. Для кожної криптовалюти наявний окремий CSV-файл із записами, що включають дату, ціну відкриття, максимальну та мінімальну ціни дня, ціну закриття, обсяг торгів в доларах США та ринкову капіталізацію в доларах США на відповідну дату. Отже, цей датасет дає змогу відстежувати динаміку цін, ринкової капіталізації та обсягів торгів різними криптовалютами на щоденній основі протягом тривалого періоду. Приклад таблиці з даними наведено на Рисунку 2.1:

	SNo	Name	Symbol	Date	High	Low	Open	Close	Volume	Marketcap
0	1	Chainlink	LINK	2017-09-21 23:59:59	0.207892	0.155292	0.189132	0.169680	2.126270e+06	5.938800e+07
1	2	Chainlink	LINK	2017-09-22 23:59:59	0.181675	0.139869	0.169826	0.150503	1.423220e+06	5.267605e+07
2	3	Chainlink	LINK	2017-09-23 23:59:59	0.157440	0.126297	0.149562	0.131129	1.186670e+06	4.589515e+07
3	4	Chainlink	LINK	2017-09-24 23:59:59	0.190250	0.130275	0.131110	0.170278	1.025740e+06	5.959730e+07
4	5	Chainlink	LINK	2017-09-25 23:59:59	0.182637	0.158580	0.170636	0.182198	1.021370e+06	6.376930e+07
...
1380	1381	Chainlink	LINK	2021-07-02 23:59:59	18.520256	17.305501	18.220669	18.283561	6.865419e+08	7.990091e+09
1381	1382	Chainlink	LINK	2021-07-03 23:59:59	18.886003	17.898075	18.285458	18.538818	5.090763e+08	8.101641e+09
1382	1383	Chainlink	LINK	2021-07-04 23:59:59	19.894503	18.028957	18.548805	19.262838	6.802681e+08	8.418044e+09
1383	1384	Chainlink	LINK	2021-07-05 23:59:59	19.246891	17.814752	19.246891	18.371589	6.986191e+08	8.028560e+09
1384	1385	Chainlink	LINK	2021-07-06 23:59:59	20.240997	18.351877	18.351877	20.080466	1.156986e+09	8.775356e+09

1385 rows × 10 columns

Рис. 2.1. - Приклад таблиці з даними про курс валюти Chainlink

Джерело: розрахунки автора

Наявність цінових даних за низку років створює можливості для різноманітних видів аналізу. Зокрема, можна дослідити зміни історичних цін та ринкової капіталізації окремих криптовалют з часом, побудувати моделі для прогнозування майбутніх цін, визначити волатильні та відносно стабільні криптовалюти, вивчити кореляції в цінових коливаннях між різними активами, а також виявити сезонні тренди в цінових рухах.

Оскільки різні криптовалюти існують різну кількість часу, кожна таблиця має різну кількість записів. Графіки криптовалют представлені на Рисунку 2.2:

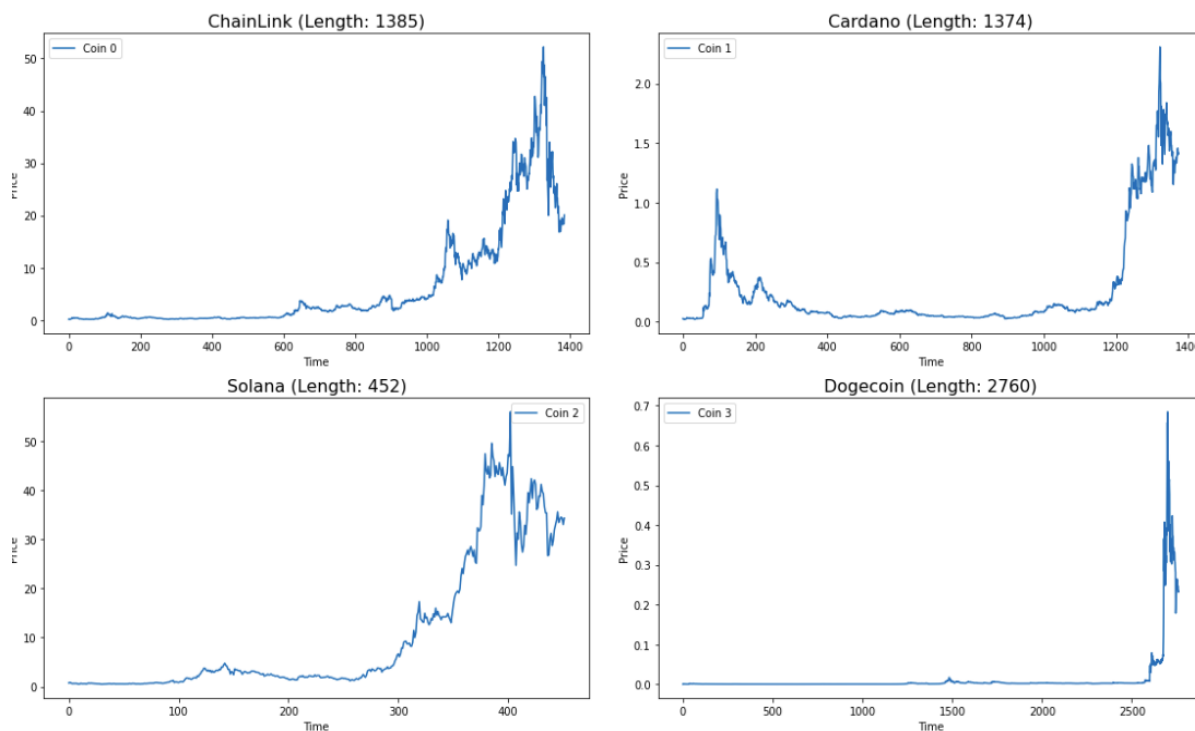


Рис. 2.2. - Графіки криптовалют з різною кількістю записів

Джерело: розрахунки автора

2.2.2. Очищення та нормалізація даних

Очищення та нормалізація даних є важливим кроком у підготовці даних до аналізу та моделювання. Оскільки вхідні дані часто містять відхилення, пропущені значення або шум, необхідно виконати певні процедури для забезпечення чистоти та узгодженості даних. У цьому розділі описано кроки з очищення та нормалізації даних про криптовалюти.

Першим кроком в обробці даних криптовалют є масштабування даних для уніфікації діапазону значень між різними криптовалютами. Для цієї задачі було проведено ітерування по кожній криптовалюті та застосовуючи зсув (мінімальне значення) і коефіцієнт масштабування (різниця між максимальним і мінімальним значеннями) до даних кожної криптовалюти. Після масштабування всі дані будуть знаходитись у діапазоні від 0 до 1.

Наступним кроком є створення вхідних і вихідних послідовностей для навчання, валідації та тестування моделі LSTM, оскільки вона завжди має однакову кількість даних на вхід. Для цього було створено послідовності, де вхідні послідовності

представляють історичні дані про криптовалюту за певний період (визначений параметром History), а вихідні послідовності містять наступне значення після історичних даних. Ця функція викликається окремо для створення наборів даних для навчання, валідації та тестування моделі.

Остаточна форма даних на вхід до LSTM є тривимірним масивом вхідних послідовностей та одновимірним масивом вихідних значень. Ці масиви будуть використані для навчання та оцінки моделі прогнозування цін на криптовалюту.

2.2.3. Розділення даних на тренувальну і тестову вибірки

Розділення даних на навчальну, валідаційну та тестову вибірки є критично важливим етапом у процесі машинного навчання. Навчальна вибірка використовується для навчання моделі, тоді як валідаційна вибірка застосовується для налаштування гіперпараметрів моделі та запобігання перенавчанню під час процесу навчання. Тестова вибірка, яка не бере участі в процесі навчання, використовується для остаточної оцінки продуктивності навченої моделі на нових, невідомих даних. Це забезпечує об'єктивну оцінку узагальненої здатності моделі.

Правильне розділення даних на ці три підмножини є критично важливим для забезпечення достовірної оцінки моделі та уникнення завищених або занижених оцінок її продуктивності. Загалом, більша частина даних виділяється для навчальної вибірки, а менші частини – для валідаційної та тестової вибірок. Співвідношення розподілу даних може варіюватися залежно від розміру наявного набору даних та специфіки завдання, але типово становить близько 60-80% для навчальної вибірки, 10-20% для валідаційної вибірки та 10-20% для тестової вибірки.

В нашому випадку було проведено розділення даних за якого до тренувальної вибірки відноситься 18 історичних курсів різних криптовалют, до валідаційної 4, а до тестової 1.

РОЗДІЛ III. ТРЕНУВАННЯ МОДЕЛЕЙ ТА ПОРІВНЯННЯ РЕЗУЛЬТАТІВ

3.1 Тренування та оцінка моделей

3.1.1 Тренування моделі ARIMA

У цьому розділі розглянемо процес тренування моделі ARIMA (AutoRegressive Integrated Moving Average) для прогнозування цін на криптовалюти. Модель ARIMA є широко використовуваною для аналізу часових рядів і має здатність захоплювати як автокореляцію, так і інтегровані тренди у даних. Давайте детальніше розглянемо кожен з етапів тренування моделі ARIMA, починаючи з вибору параметрів моделі та закінчуючи оцінкою результатів.

Першим кроком у тренуванні моделі ARIMA є вибір відповідних параметрів. Модель ARIMA має три основні параметри:

1. p : порядок авторегресійної частини (AR),
2. d : ступінь диференціювання (I),
3. q : порядок ковзаючого середнього (MA).

У даному прикладі було використано порядок моделі (3, 0, 1), що означає, що модель має 3 лаги авторегресії, без диференціювання, і один лаг ковзаючого середнього. Ці параметри були обрані на основі попереднього аналізу автокореляційної функції (ACF) та часткової автокореляційної функції (PACF) для забезпечення найкращого підходу до даних.

Після вибору параметрів та тренування моделі ARIMA на кожному з наборів даних криптовалют, було проведено оцінку результатів на тестових вибірках. Для оцінки продуктивності моделі було використано наступні метрики:

1. Root Mean Square Error (RMSE): показує середнє квадратичне відхилення між передбаченими та фактичними значеннями.
2. Mean Absolute Error (MAE): показує середню абсолютну різницю між передбаченими та фактичними значеннями.
3. Durbin-Watson Statistic (DW): використовується для виявлення автокореляції залишків.

4. Mean Absolute Percentage Error (MAPE): показує середній абсолютний відсотковий відхил між передбаченими та фактичними значеннями.

Результати оцінки на кожній з криптовалют були наступними:

1. Mean Root Mean Squared Error: 0.0477
2. Mean Absolute Error: 0.0319
3. Mean Durbin-Watson statistic: 2.3277
4. Mean Absolute Percentage Error: 6.8580

Ці метрики свідчать про загальну ефективність моделі ARIMA у прогнозуванні цін на криптовалюту. Значення RMSE та MAE є досить низькими, що вказує на високу точність прогнозів. Значення Durbin-Watson близьке до 2, що свідчить про відсутність автокореляції залишків, що є позитивним показником. Значення MAPE вказує на допустимий рівень відносної похибки.

Для візуалізації результатів було побудовано графіки, які порівнюють фактичні та передбачені значення цін на криптовалюту (Рис 3.1.):




Рис. 3.1. - Візуалізація передбачень моделі

Джерело: розрахунки автора

Графіки показують, що модель ARIMA досить добре слідує за трендами фактичних даних, хоча деякі відхилення все ж таки присутні.

На основі цих результатів можна зробити висновок, що модель ARIMA є ефективним інструментом для прогнозування цін на криптовалюти, хоча подальше вдосконалення моделі може покращити точність прогнозів.

3.1.2 Тренування моделі експоненційного згладжування

У цьому розділі розглянемо процес тренування моделі експоненційного згладжування. Експоненційне згладжування є одним із найпопулярніших методів для аналізу та прогнозування часових рядів, оскільки він дає змогу враховувати як трендові, так і сезонні компоненти даних. Модель експоненційного згладжування, зокрема модель Holt-Winters, дає змогу захоплювати ці складові в часових рядах, що робить її особливо корисною для задач прогнозування фінансових показників.

Першим кроком у тренуванні моделі експоненційного згладжування є вибір відповідних параметрів. У моделі Holt-Winters можна вибрати тип тренду та тип сезонності (адитивний або мультиплікативний), а також період сезонності.

Для даного завдання, де було прогнозовано ціни на криптовалюти, адитивний тренд був обраний через його здатність обробляти стабільні зміни у рівнях цін. Використання адитивного тренду дає змогу моделі ефективно враховувати лінійні зміни в часі. Вибір адитивного сезонного компоненту допомагає моделі враховувати регулярні коливання, що повторюються з фіксованою частотою, що є актуальним для багатьох фінансових показників.

Після вибору параметрів моделі та її тренування на кожному з наборів даних криптовалют, було проведено оцінку результатів на тестових вибірках. Для оцінки продуктивності моделі було використано метрику Root Mean Square Error (RMSE), яка вимірює середнє квадратичне відхилення між передбаченими та фактичними значеннями. Значення RMSE дає змогу оцінити загальну точність прогнозів моделі.

Результати показали, що середнє значення RMSE для всіх криптовалют склало приблизно 0.1479. Це свідчить про те, що модель експоненційного згладжування ефективно прогнозує ціни на криптовалюти з досить високою точністю. Низьке значення RMSE вказує на те, що різниця між передбаченими та фактичними значеннями є незначною, що підтверджує ефективність моделі.

Для візуалізації результатів було побудовано графіки, які порівнюють фактичні та передбачені значення цін на криптовалюти (Рис. 3.2.):




Рис. 3.2. - Результати роботи ExpSmoothing

Джерело: розрахунки автора

Графіки візуалізації та метрики оцінки показують, що модель експоненційного згладжування може бути корисною для прогнозування цін на криптовалюти, але її точність може варіюватися залежно від конкретної криптовалюти. У випадку з ChainLink модель показала дещо гірші результати, з більш високими значеннями RMSE та MAPE. Натомість для Cardano результати були більш задовільними.

Це вказує на те, що для деяких криптовалют може бути доцільно розглянути додаткові методи налаштування моделі або комбінування різних методів прогнозування для досягнення більш точних результатів. Модель експоненційного згладжування все ще може бути корисною, особливо при інтеграції з іншими моделями або при застосуванні до даних з менш вираженими коливаннями.

3.1.3 Тренування моделі Facebook Prophet

У цьому розділі розглянемо процес тренування моделі Facebook Prophet для прогнозування цін на криптовалюти. Prophet є потужним інструментом для моделювання часових рядів, розробленим Facebook, який відрізняється простотою використання та здатністю обробляти складні сезонні дані. Розглянемо детальніше кожен з етапів тренування моделі Prophet, починаючи з налаштування моделі та закінчуючи оцінкою результатів і візуалізацією.

Модель Prophet надає гнучкі можливості для налаштування параметрів, що дозволяють враховувати різні компоненти часового ряду, такі як сезонність, тренди та святкові ефекти. У нашому дослідженні було використано стандартні налаштування моделі, які включають адитивний тренд. Це означає, що модель буде враховувати лінійні зміни у часі. Prophet автоматично виявляє та обробляє сезонні компоненти, що робить його ідеальним для даних з регулярними сезонними коливаннями.

Перед тренуванням моделі було здійснено попередню обробку даних, що включала:

1. **Перейменування колонок** - зміна назв колонок у DataFrame, щоб відповідати формату, який потребує Prophet (ds для дати і у для значення).

2. Масштабування даних - використання MinMaxScaler для нормалізації значень, щоб покращити продуктивність моделі.

Після цього створено модель Prophet та здійснено тренування на даних за допомогою стандартних налаштувань.

Після тренування моделі Prophet була проведена оцінка її продуктивності на тестових вибірках, використовуючи такі метрики, які було використано для моделі Arima, а саме:

1. Root Mean Square Error (RMSE) - показує середнє квадратичне відхилення передбачених значень від фактичних. Низьке значення RMSE вказує на високу точність моделі.
2. Mean Absolute Error (MAE) - вимірює середню абсолютну різницю між передбаченими та фактичними значеннями. Як і RMSE, низьке значення MAE вказує на хорошу продуктивність моделі.
3. Durbin-Watson Statistic (DW) - використовується для виявлення автокореляції у залишках моделі. Значення, близьке до 2, свідчить про відсутність автокореляції.
4. Mean Absolute Percentage Error (MAPE) - показує середній відсоток відхилення між передбаченими та фактичними значеннями. Низьке значення MAPE вказує на точні прогнози.

Для візуалізації результатів було побудовано графіки, що порівнюють фактичні та передбачені значення цін на криптовалюти (Рис. 3.3.):




Рис. 3.3. - Результати роботи моделі Prophet

Джерело: розрахунки автора

Модель Facebook Prophet показала високі результати у прогнозуванні цін на криптовалюти, зокрема ChainLink та Cardano. Низькі значення RMSE та MAE свідчать про високу точність прогнозів, а значення Durbin-Watson підтверджують відсутність автокореляції у залишках. Висока точність прогнозів робить модель Prophet корисною для аналізу та прогнозування фінансових показників.

Результати свідчать про те, що модель Prophet може бути успішно застосована для прогнозування цін на криптовалюти, забезпечуючи точні та надійні прогнози. Можливості моделі з автоматичного виявлення та обробки сезонних компонентів роблять її особливо цінною для аналізу часових рядів з комплексною структурою даних.

Середнє значення Root Mean Squared Error (RMSE) складає 0.0518, що свідчить про високу точність моделі у передбаченні цін на криптовалюти. Це значення показує, що різниця між прогнозами моделі та реальними даними є мінімальною.

Середнє значення Mean Absolute Error (MAE) дорівнює 0.0352, що підтверджує, що модель ефективно мінімізує абсолютні помилки між передбаченими та фактичними значеннями. Це вказує на високу продуктивність моделі у прогнозуванні.

Mean Durbin-Watson statistic має значення 1.1389. Це вказує на відсутність значної автокореляції у залишках моделі, що є позитивним показником для стабільності та надійності прогнозів.

Mean Absolute Percentage Error (MAPE) складає 6.997%. Це низьке значення свідчить про точні прогнози моделі в контексті відсоткових відхилень від фактичних даних, що є важливим для фінансового аналізу.

Загалом, модель Facebook Prophet демонструє високу точність та надійність у прогнозуванні цін на криптовалюти, що робить її ефективним інструментом для фінансового аналізу та прийняття обґрунтованих рішень у цій сфері.

На основі отриманих результатів можна рекомендувати модель Prophet для широкого спектру задач прогнозування у фінансовій сфері, а також для інших галузей, де є потреба у точних прогнозах на основі часових рядів. Додаткове налаштування параметрів та використання більшого обсягу даних можуть ще більше підвищити точність моделі.

3.1.4 Тренування моделі LSTM

У цьому розділі розглянемо архітектуру моделі LSTM (Long Short-Term Memory), яка була обрана для вирішення задачі прогнозування цін на криптовалюти. LSTM є різновидом рекурентних нейронних мереж, здатних ефективно вивчати та моделювати часові залежності у послідовних даних. Завдяки своїй унікальній структурі, що включає комірки пам'яті та логічні вентиля, LSTM можуть захоплювати довгострокові залежності в даних без проблеми зникнення або вибуху градієнтів під час навчання. Це робить їх особливо підходящими для задач з часовими рядами, таких як прогнозування цін на фінансові активи. Архітектура даної моделі LSTM була

ретельно розроблена для максимальної ефективності у вивченні складних залежностей у даних про криптовалюти. Архітектуру обраної моделі продемонстровано на Рисунку 3.4.:

```

Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
lstm (LSTM)                  (None, 60, 128)           66560
-----
lstm_1 (LSTM)                (None, 64)                 49408
-----
dense (Dense)                (None, 25)                 1625
-----
dense_1 (Dense)              (None, 1)                  26
-----
Total params: 117,619
Trainable params: 117,619
Non-trainable params: 0
-----

```

Рис. 3.4. - Архітектура моделі LSTM

Джерело: розрахунки автора

Мережа складається з двох послідовних шарів LSTM, що дає змогу моделі ефективно вивчати довгострокові залежності у часових рядах. Перший шар LSTM з параметром `return_sequences=True` повертає повну послідовність прихованих станів для кожного часового кроку, даючи змогу другому шару LSTM краще захоплювати контекстну інформацію. Перший шар LSTM має 128 прихованих нейронів, а другий - 64 це дає змогу моделі спочатку вивчити складні особливості даних у першому шарі з більшою кількістю нейронів, а потім узагальнити та згорнути ці особливості у другому шарі з меншою кількістю нейронів. Після двох шарів LSTM додано два щільних шари. Перший щільний шар з 25 нейронами виконує роль проміжного шару, що допомагає моделі краще узагальнити вивчені особливості. Другий щільний шар з одним нейроном є вихідним шаром, який генерує остаточний прогноз для наступного часового кроку. Для навчання моделі використовується оптимізатор Adam, який є ефективним варіантом стохастичного градієнтного спуску та добре працює для задач з часовими рядами. Для регресійної задачі прогнозування часових рядів

використовується функція втрат середньоквадратичної помилки (MSE), яка вимірює різницю між фактичними та передбаченими значеннями і є відповідною метрикою для таких задач.

Після визначення архітектури моделі LSTM, наступним важливим кроком є процес навчання або тренування моделі. Під час тренування модель ітеративно коригує свої внутрішні параметри (ваги) з метою мінімізації функції втрат на навчальних даних. Цей процес відбувається протягом заздалегідь визначеної кількості епох, при цьому навчальні дані проходять через модель кілька разів. Регулярний моніторинг значень функції втрат та метрик продуктивності, таких як середньоквадратична помилка, як на навчальній, так і на валідаційній вибірках, дає змогу відстежувати прогрес навчання та уникати перенавчання моделі. Належний процес тренування є критично важливим для забезпечення оптимальної продуктивності моделі LSTM у задачі прогнозування цін на криптовалюту. Процес тренування моделі наведено на Рисунку 3.5.:

```
Epoch 1/5
857/857 [=====] - 17s 10ms/step - loss: 0.0024 - mean_squared_error: 0.0024 - val_loss: 4.3611e-04 - val_mean_squared_error: 4.3611e-04
Epoch 2/5
857/857 [=====] - 7s 8ms/step - loss: 5.8506e-04 - mean_squared_error: 5.8506e-04 - val_loss: 3.6393e-04 - val_mean_squared_error: 3.6393e-04
Epoch 3/5
857/857 [=====] - 7s 8ms/step - loss: 5.6471e-04 - mean_squared_error: 5.6471e-04 - val_loss: 4.1830e-04 - val_mean_squared_error: 4.1830e-04
Epoch 4/5
857/857 [=====] - 7s 8ms/step - loss: 4.9624e-04 - mean_squared_error: 4.9624e-04 - val_loss: 3.3265e-04 - val_mean_squared_error: 3.3265e-04
Epoch 5/5
857/857 [=====] - 7s 8ms/step - loss: 4.8503e-04 - mean_squared_error: 4.8503e-04 - val_loss: 3.4547e-04 - val_mean_squared_error: 3.4547e-04
```

Рис. 3.5. - Процес тренування LSTM

Джерело: розрахунки автора

Процес тренування моделі LSTM відбувається протягом заданої кількості епох, в даному випадку - 5 епох. Під час кожної епохи вся навчальна вибірка проходить через модель, і ваги моделі оновлюються з метою мінімізації функції втрат.

На кожній епосі виводиться інформація про поточний прогрес навчання. Рядок "857/857 [=====]" вказує на те, що всі 857 батчів навчальних даних були опрацьовані за цю епоху. Наступне значення "- 17s 10ms/step"

показує, що ця епоха зайняла 17 секунд, а середній час обробки одного батчу даних склав 10 мілісекунд.

Далі наводяться значення функції втрат (loss) та метрики середньоквадратичної помилки (mean_squared_error) для навчальної вибірки після завершення поточної епохи. На першій епосі значення втрати становить 0.0024, що є досить низьким, але воно продовжує зменшуватися в наступних епохах.

Після навчальних метрик виводяться аналогічні метрики для валідаційної вибірки, позначені префіксом "val_". Ці метрики дозволяють відстежувати продуктивність моделі на даних, які не використовувались для навчання, і допомагають уникнути перенавчання.

Як видно з виведених результатів, значення функції втрат та середньоквадратичної помилки для навчальної та валідаційної вибірок послідовно зменшуються з кожною епохою, що свідчить про успішне навчання моделі. Після завершення 5 епох навчання модель готова до використання для прогнозування цін на криптовалюту на тестовій вибірці.

Крива тренування моделі зображена на Рисунку 3.6:




Рис. 3.6. - Крива тренування моделі

Джерело: розрахунки автора

Після завершення процесу тренування моделі LSTM, важливим етапом є оцінка її продуктивності на тестовій вибірці. Для цього було використано декілька метрик, які дозволяють об'єктивно оцінити якість прогнозування моделі. Основними метриками, що використовуються для оцінки моделі, є Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Durbin-Watson Statistic та Mean Absolute Percentage Error (MAPE), ті самі, які були використані для двох моделей вище.

Після оцінки продуктивності моделі на тестових даних, отримано наступні результати:

1. Root mean square error on test data: 0.2262
2. Mean absolute error on test data: 0.1543
3. Durbin-Watson statistic: 0.0062
4. Mean absolute percentage error on test data: inf

Як видно з отриманих результатів, модель показала досить низьке значення RMSE та MAE, що свідчить про високу точність прогнозування. Проте значення Durbin-Watson свідчить про можливу автокореляцію залишків, що може впливати на якість прогнозів. Значення MAPE виявилось нескінченним, що може свідчити про наявність аномальних значень у тестових даних.

Для кращого розуміння роботи моделі та її прогнозів було також візуалізовано результати. На Рисунку 3.7. зображено порівняння фактичних та передбачених значень цін на криптовалюту:

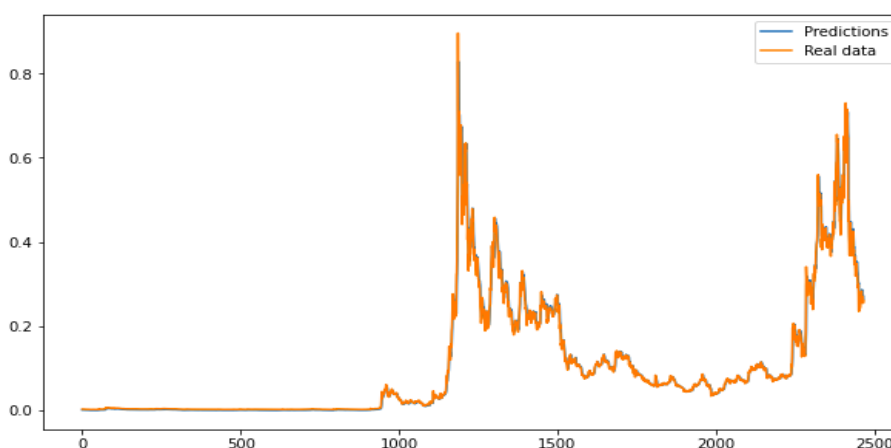


Рис. 3.7. - Порівняння фактичних та передбачених значень цін на криптовалюту

Джерело: розрахунки автора

Візуалізація показує, що модель LSTM досить добре слідує за трендами фактичних даних, що підтверджує її ефективність у задачі прогнозування. Однак, деякі відхилення все ж таки присутні, що може бути покращено за рахунок додаткового налаштування гіперпараметрів або використання додаткових даних для навчання.

В цілому, модель LSTM продемонструвала високий потенціал у задачі прогнозування цін на криптовалюти, проте для досягнення оптимальних результатів можливе подальше вдосконалення її архітектури та процесу тренування.

3.2 Метрики оцінки якості передбачень

Для оцінки якості передбачень моделей були використані такі самі метрики, які використовувались вище, а саме: середнє квадратичне відхилення (RMSE), середня абсолютна похибка (MAE), статистика Дарбіна-Ватсона (DW) та середня абсолютна відсоткова похибка (MAPE). Ці метрики дозволяють комплексно оцінити точність та надійність прогнозів кожної моделі.

Нижче наведена таблиця 3.1 порівняння результатів для моделей Prophet, експоненційного згладжування (Exp Smoothing), ARIMA та LSTM:

Таблиця 3.1. Порівняння метрик використаних моделей

Джерело: розрахунки автора

Модель	RMSE	MAE	DW	MAPE
Prophet	0.0518	0.0352	1.1389	6.997%
Exp Smoothing	0.1479	0.1027	0.1647	19.735%
ARIMA	0.0477	0.0319	2.3277	6.858%
LSTM	0.2262	0.1543	0.0062	∞

3.3 Порівняльний аналіз результатів моделей

Модель Facebook Prophet показала високу точність і надійність прогнозів. Значення RMSE (0.0518) та MAE (0.0352) свідчать про мінімальні відхилення між передбаченими та фактичними значеннями. Значення Durbin-Watson (1.1389) вказує на відсутність суттєвої автокореляції, а MAPE (6.997%) вказує на точні прогнози з точки зору відсоткових відхилень. Prophet добре справляється з захопленням сезонних і трендових компонентів, що робить її відмінним вибором для складних часових рядів. Недоліком може бути потреба в налаштуванні параметрів для специфічних даних.

Модель експоненційного згладжування (Exp Smoothing) має прийнятні результати, але її метрики свідчать про значні відхилення від фактичних значень: RMSE (0.1479) та MAE (0.1027). Значення Durbin-Watson (0.1647) вказує на

наявність автокореляції, а MAPE (19.735%) свідчить про значні відсоткові відхилення. Ця модель може бути корисною для простіших часових рядів, де не потрібна висока точність.

Модель ARIMA показала високу точність і надійність прогнозів. Значення RMSE (0.0477) та MAE (0.0319) є досить низькими, що вказує на високу точність. Значення Durbin-Watson (2.3277) свідчить про відсутність автокореляції, а MAPE (6.858%) вказує на точні прогнози. ARIMA підходить для багатьох задач прогнозування, але потребує ретельного вибору параметрів.

Модель LSTM показала найгірші результати серед усіх розглянутих моделей. Значення RMSE (0.2262) та MAE (0.1543) є найвищими, що свідчить про значні відхилення між передбаченими та фактичними значеннями. Значення Durbin-Watson (0.0062) вказує на високу автокореляцію, а MAPE має нескінченне значення, що вказує на суттєві проблеми з точністю прогнозів. Це свідчить про необхідність додаткової оптимізації або використання інших методів для покращення результатів.

Модель Facebook Prophet показала найкращі результати серед усіх розглянутих моделей, що робить її найбільш придатною для прогнозування цін на криптовалюту у даному дослідженні. ARIMA також продемонструвала високу точність, тоді як моделі експоненційного згладжування та LSTM потребують значного покращення для досягнення конкурентоспроможних результатів.

ВИСНОВКИ

Дана дипломна робота мала на меті дослідити ефективність методів глибинного навчання для прогнозування курсу криптовалют. У рамках дослідження було розглянуто кілька моделей, включаючи моделі Facebook Prophet, експоненційного згладжування (Exp Smoothing), ARIMA та LSTM, з метою порівняння їхньої точності та надійності у прогнозуванні часових рядів.

У ході роботи було виконано наступні завдання:

1. Проведено огляд теоретичних основ криптовалют та їх розвитку.
2. Аналізовано існуючі методи прогнозування фінансових даних, включаючи традиційні статистичні методи та методи глибинного навчання.
3. Описано архітектуру та принципи роботи моделей, що використовуються для прогнозування курсу криптовалют.
4. Здійснено збір та попередню обробку даних, включаючи очищення та нормалізацію даних.
5. Проведено тренування та оцінку моделей на основі реальних даних про курси криптовалют.
6. Виконано порівняльний аналіз результатів моделей за допомогою метрик оцінки якості передбачень, таких як RMSE, MAE, Durbin-Watson та MAPE.

Ця робота надала наступні корисні інсайти:

- Виявлено, що модель Facebook Prophet показала найкращі результати серед усіх розглянутих моделей, демонструючи високу точність і надійність у прогнозуванні курсу криптовалют.
- Модель ARIMA також продемонструвала високу точність, що робить її придатною для багатьох задач прогнозування.
- Моделі експоненційного згладжування та LSTM потребують значного покращення для досягнення конкурентоспроможних результатів.

Результати даної роботи можуть мати таке практичне застосування:

- Отримані моделі можуть бути використані для покращення точності прогнозів курсу криптовалют, що може допомогти інвесторам зменшити ризики та приймати більш обґрунтовані рішення.
- Результати дослідження можуть сприяти розвитку наукових досліджень у галузі фінансового прогнозування та глибинного навчання.
- Моделі та методи, розглянуті у цій роботі, можуть бути інтегровані у фінансові продукти та сервіси для автоматизованого прогнозування ринкових трендів.
- Дослідження може бути використано як навчальний матеріал для студентів та дослідників, які цікавляться прогнозуванням фінансових даних та застосуванням методів глибинного навчання.

Таким чином, ця дипломна робота зробила достатньо вагомий внесок у розуміння та застосування сучасних методів глибинного навчання для прогнозування курсу криптовалют, надаючи цінні інсайти та рекомендації для подальших досліджень та практичного використання.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Parth Daxesh Modi, Kamyar Arshi, Pertamina J. Kunz, Abdelhak M. Zoubir. A Data-driven Deep Learning Approach for Bitcoin Price Forecasting. ArXiv. URL: <https://arxiv.org/abs/2311.06280>
2. Zeyd Boukhers, Azeddine Bouabdallah, Matthias Lohr, Jan Jürjens. Ensemble and Multimodal Approach for Forecasting Cryptocurrency Price. ArXiv. URL: <https://arxiv.org/abs/2202.08967>
3. Novan Fauzi Al Giffary, Feri Sulianta. Prediction Of Cryptocurrency Prices Using LSTM, SVM And Polynomial Regression. ArXiv. URL: <https://arxiv.org/abs/2403.03410>
4. Ehab Zaghoul, Tongtong Li, Matt Mutka, Jian Ren. Bitcoin and Blockchain: Security and Privacy. ArXiv. URL: <https://arxiv.org/abs/1904.11435>
5. Marco Alberto Javarone, Craig Steven Wright. From Bitcoin to Bitcoin Cash: a network analysis. ArXiv. URL: <https://arxiv.org/abs/1804.02350>
6. Nicolò Vallarano, Claudio Tessone, Tiziano Squartini. Bitcoin Transaction Networks: an overview of recent results. ArXiv. URL: <https://arxiv.org/abs/2005.00114>
7. Yann McLatchie, Sölvi Rögnvaldsson, Frank Weber, Aki Vehtari. Robust and efficient projection predictive inference. ArXiv. URL: <https://arxiv.org/abs/2306.15581>
8. Lin Zhao, Tianchen Zhao, Zinan Lin, Xuefei Ning, Guohao Dai, Huazhong Yang, Yu Wang. FlashEval: Towards Fast and Accurate Evaluation of Text-to-image Diffusion Generative Models. ArXiv. URL: <https://arxiv.org/abs/2403.16379>
9. Ali Asgarov. Predicting Financial Market Trends using Time Series Analysis and Natural Language Processing. ArXiv. URL: <https://arxiv.org/abs/2309.00136>

10. Tim Leung, Theodore Zhao. Financial Time Series Analysis and Forecasting with HHT Feature Generation and Machine Learning. ArXiv. URL: <https://arxiv.org/abs/2105.10871>
11. Helmut Wasserbacher, Martin Spindler. Machine Learning for Financial Forecasting, Planning and Analysis: Recent Developments and Pitfalls. ArXiv. URL: <https://arxiv.org/abs/2107.04851>
12. Sima Siami-Namini, Neda Tavakoli, Akbar Siami Namin. A Comparative Analysis of Forecasting Financial Time Series Using ARIMA, LSTM, and BiLSTM. ArXiv. URL: <https://arxiv.org/abs/1911.09512>
13. Hakan Pabuccu, Serdar Ongan, Ayse Ongan. Forecasting the movements of Bitcoin prices: an application of machine learning algorithms. ArXiv. URL: <https://arxiv.org/abs/2303.04642>
14. Shubham Singh, Mayur Bhat. Transformer-based approach for Ethereum Price Prediction Using Crosscurrency correlation and Sentiment Analysis. ArXiv. URL: <https://arxiv.org/abs/2401.08077>
15. David Zhao, Alessandro Rinaldo, Christopher Brookins. Cryptocurrency Price Prediction and Trading Strategies Using Support Vector Machines. ArXiv. URL: <https://arxiv.org/abs/1911>
16. Parth Daxesh Modi, Kamyar Arshi, Pertami J. Kunz, Abdelhak M. Zoubir. A Data-driven Deep Learning Approach for Bitcoin Price Forecasting. ArXiv. URL: <https://arxiv.org/abs/2311.06280>
17. Ketaki Joshi, Raghavendra Pradyumna Pothukuchi, Andre Wibisono, Abhishek Bhattacharjee. Mitigating Catastrophic Forgetting in Long Short-Term Memory Networks. ArXiv. URL: <https://arxiv.org/abs/2305.17244>
18. Emirhan Inanc, Yigit Gurses, Abdullah Habboush, Yildiray Yildiz, Anuradha M. Annaswamy. Neural Network Adaptive Control with

- Long Short-Term Memory. ArXiv. URL: <https://arxiv.org/abs/2301.02316>
19. Ralf C. Staudemeyer, Eric Rothstein Morris. Understanding LSTM - a tutorial into Long Short-Term Memory Recurrent Neural Networks. ArXiv. URL: <https://arxiv.org/abs/1909.09586>
20. Benyamin Ghogh, Ali Ghodsi. Recurrent Neural Networks and Long Short-Term Memory Networks: Tutorial and Survey. ArXiv. URL: <https://arxiv.org/abs/2304.11461>
21. Aniruddha Dutta, Saket Kumar, Meheli Basu. A Gated Recurrent Unit Approach to Bitcoin Price Prediction. ArXiv. URL: <https://arxiv.org/abs/1912.11166>
22. S M Raju, Ali Mohammad Tarif. Real-Time Prediction of BITCOIN Price using Machine Learning Techniques and Public Sentiment Analysis. ArXiv. URL: <https://arxiv.org/abs/2006.14473>
23. Zhiyu Zhu, Huaming Chen, Jiayu Zhang, Xinyi Wang, Zhibo Jin, Minhui Xue, Dongxiao Zhu, Kim-Kwang Raymond Choo. MFABA: A More Faithful and Accelerated Boundary-based Attribution Method for Deep Neural Networks. ArXiv. URL: <https://arxiv.org/abs/2312.13630>
24. Yu Lei, Zixuan Wang, Chu Liu, Tongyao Wang, Dongyang Lee. FinLangNet: A Novel Deep Learning Framework for Credit Risk Prediction Using Linguistic Analogy in Financial Data. ArXiv. URL: <https://arxiv.org/abs/2404.13004>
25. Niraj Agarwal, Dmitri Kondrashov, Peter Dueben, Evgenii Ryzhov, Pavel Berloff. A comparison of data-driven approaches to build low-dimensional ocean models. ArXiv. URL: <https://arxiv.org/abs/2108.00818>

26. Pedro Lara-Benítez, Manuel Carranza-García, José C. Riquelme. An Experimental Review on Deep Learning Architectures for Time Series Forecasting. ArXiv. URL: <https://arxiv.org/abs/2103.12057>
27. Shenhao Wang, Qingyi Wang, Nate Bailey, Jinhua Zhao. Deep Neural Networks for Choice Analysis: A Statistical Learning Theory Perspective. ArXiv. URL: <https://arxiv.org/abs/1810.10465>
28. Tripathi S. Exponents in Python: A Comprehensive Guide for Beginners. Learn Data Science and AI Online | DataCamp. URL: <https://www.datacamp.com/tutorial/exponents-in-python>
29. Cryptocurrency Historical Prices. Kaggle: Your Machine Learning and Data Science Community. URL: <https://www.kaggle.com/datasets/sudalairajkumar/cryptocurrencypricehistory>
30. ARIMA Model - Complete Guide to Time Series Forecasting in Python | ML+. Machine Learning Plus. URL: <https://www.machinelearningplus.com/time-series/arima-model-time-series-forecasting-python/>

Київський національний університет імені Тараса Шевченка

Економічний факультет

Кафедра економічної кібернетики

ЗАВДАННЯ

на кваліфікаційну роботу бакалавра

студентки 4 курсу спеціальності 051 «Економіка», ОПП «Економічна
кібернетика»

Будікової Софії Євгенівни

1. Тема роботи: Прогнозування курсу криптовалют методами глибинного навчання.
2. Термін завершення роботи: 02.06.2024 року.
3. Попередній захист роботи: 03.06.2024 року.
4. Об'єкт дослідження: курси криптовалют, які демонструють високий рівень волатильності та складність у прогнозуванні.
5. Предмет дослідження: методи традиційного статистичного аналізу та методи глибинного навчання, зокрема мережі довгої короткочасної пам'яті (LSTM), що застосовуються для прогнозування курсів криптовалют.
6. Мета дослідження: вивчення та оцінка ефективності методів глибинного навчання у прогнозуванні курсу криптовалют.
7. Завдання дослідження:
 - 7.1 проаналізувати теоретичні основ криптовалют;
 - 7.2 дослідити традиційні статистичні методи та методи глибинного навчання;
 - 7.3 провести тренування різних моделей на основі зібраних даних, а також оцінити їхню точність та надійність за допомогою метрик оцінки якості;
 - 7.4 провести порівняльний аналіз результатів різних моделей для визначення їхньої ефективності.

Науковий керівник: кандидат економічних наук, доцент Шпирко Віктор
Васильович

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

Студент:

(підпис)

Затверджено на засіданні кафедри економічної кібернетики
протокол № 4 від 22.11.2023 р.

Календарний план виконання кваліфікаційної роботи бакалавра

№	Етапи роботи	Терміни виконання	Відмітка керівника про виконання
1	Вибір теми кваліфікаційної роботи бакалавра	14.11.2023-16.11.2023	
2	Розробка та затвердження завдання кваліфікаційної роботи бакалавра	17.11.2023-22.11.2023	
3	Вивчення наукових робіт за темою дипломної роботи	23.11.2023-05.01.2024	
4	Аналіз проведених досліджень та методів прогнозування	06.01.2024-03.02.2024	
5	Збір та попередня обробка даних, створення бази даних для дослідження	04.02.2024-05.03.2024	
6	Тренування та оцінка моделей	06.03.2024-03.05.2024	
7	Порівняння якості моделей за обраними метриками	04.05.2024-15.05.2024	
8	Порівняння результатів обраних моделей	16.05.2024-25.05.2024	
9	Написання висновків	26.05.2024-30.05.2024	
10	Коригування та оформлення остаточного варіанту роботи	31.05.2024-02.06.2024	

Науковий керівник: Шпирко Віктор Васильович

Студент: Будікова Софія Євгенівна