

Київський національний університет імені Тараса Шевченка

**Економічний факультет
Кафедра економічної кібернетики**

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

Прогнозування курсу криптовалют за допомогою методів Deep Learning

студентки 2 курсу магістратури
спеціальності 051 "Економіка"
ОНП "Економічна кібернетика"
денної форми навчання
Шайкової Олени Олегівни

Науковий керівник:
доктор економічних наук, професор
Ляшенко Олена Ігорівна

Засвідчую, що в цій роботі немає запозичень
із праць інших авторів без відповідних посилань
Студент _____

Роботу допущено до захисту перед ЕК
рішенням кафедри економічної кібернетики
від 11 травня 2023р., протокол №15

Завідувач кафедри:
доктор економічних наук, професор
Ляшенко Олена Ігорівна

КИЇВ – 2023

ЗМІСТ

ВСТУП	3
РОЗДІЛ 1. ТЕОРЕТИЧНІ ОСНОВИ БЛОКЧЕЙН-ТЕХНОЛОГІЙ ТА ЇХ ВИКОРИСТАННЯ ДЛЯ КРИПТОВАЛЮТ.....	6
1.1. Історія появи та розвитку криптовалют.....	6
1.2. Блокчейн-технології як децентралізована система зберігання даних	16
1.3. Огляд ринку криптовалют	27
РОЗДІЛ 2. ВИКОРИСТАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ ПРОГНОЗУВАННЯ В ЕКОНОМІЦІ.....	34
2.1. Машинне навчання та його ключові елементи	34
2.2. Глибинне навчання як сучасний метод аналізу даних.....	42
РОЗДІЛ 3. ПРАКТИЧНЕ ЗАСТОСУВАННЯ МЕТОДІВ DEEP LEARNING ПРИ ПРОГНОЗУВАННІ КУРСУ КРИПТОВАЛЮТ	49
ВИСНОВКИ.....	64
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	66
ДОДАТКИ	75

ВСТУП

Технологічний прогрес незмінно сприяє розвитку нашого суспільства. Щороку з'являються нові пристрої та програми, здатні виконувати неймовірну кількість функцій, які тривалий час виконувалися виключно мануально людьми.

У 2010-х роках технологічна революція розпочалася у фінансовій сфері. Якщо на початку XXI століття багато нововведень, у тому числі методи безконтактної оплати та цифровізація бізнесу, не мали значного впливу на функціонування фінансової сфери, а лише спрощували певні процеси, аналіз даних тощо, то технологія "блокчейн" розпочав значні структурні зміни в усій світовій економіці.

Поки що великі транснаціональні корпорації все ще розробляють стратегії введення блокчейну у свою операційну діяльність, багато ентузіастів та стартапів уже роблять свої розробки, що використовують цю технологію. Більшість з таких розробок відносяться до криптовалют, які і будуть розглянуті в даній роботі.

Поява нового фінансового інструменту неминуче спричинила дослідження механізмів формування його вартості. Так як кількість спекулянтів щодня зростає, все більше людей ставить питання управління ризиками при інвестиціях в криптовалюту. Ринок криптовалют, як і фондовий ринок, є дуже волатильним, адже ціна та курс криптовалют змінюються щосекунди, що зумовлює складність прогнозування вартості криптовалют та підвищує ризики для інвесторів.

Теми криптовалют торкнулося багато українських вчених, зокрема Яровий К. О., Мартиненко О. В., Шнурко А. М., Устенко С. В., Танклевська Н. С., Петренко В. С., Карнаушенко А. С., Мерінова С. В., Половенко Л. П. тощо. Основною тематикою наукових робіт вітчизняних вчених щодо криптовалют є правовий статус криптовалют, проблем визначення ролі криптовалют в економіці, їх сутності, державного регулювання криптовалютами тощо. Таким чином, на даний момент питання прогнозування вартості криптовалют є недостатньо дослідженим.

Новизна дипломної роботи полягає у тому, що вперше буде використано моделі на основі методів глибинного навчання, зокрема глибинних нейронних мереж, задля оптимізації роботи інвесторів на ринку криптовалют в умовах високої волатильності вартості криптовалют.

Об'єктом дипломної роботи є криптовалюти та їх вартість. Предметом дослідження є моделювання визначення вартості криптовалют у часовій перспективі за допомогою методів глибинного навчання для вирішення проблеми складності прогнозування вартості криптовалют під час операцій купівлі-продажу.

Метою даного дослідження є оптимізація прогнозування вартості криптовалют для інвестора, а також розробка програмного забезпечення, що буде базуватися на методах глибинного навчання, що дасть змогу оперативно реагувати на зміни вартості криптовалют та здійснювати підтримку прийняття рішень для інвестора.

У відповідності до поставленої мети було поставлено наступні завдання:

- дослідити історію появи та розвитку криптовалют;
- визначити основні характеристики криптовалют, їх місце в сучасній світовій економіці;
- проаналізувати наукові роботи, присвячені криптовалютам;
- дослідити технологію блокчейн, яка є фундаментом для функціонування криптовалют;
- зробити аналіз ринку криптовалют, його кількісні та якісні характеристики;
- визначити методи машинного навчання, які використовуються для аналізу даних;
- охарактеризувати глибинне навчання як ефективний засіб прогнозування показників у складних системах;
- проаналізувати доцільність використання методів глибинного навчання для вирішення поставленої проблеми;

- розробити програмний засіб для реагування на зміни вартості криптовалют.

Методи дослідження, що використовуються у даній дипломній роботі, у свій перелік включають аналіз та синтез інформації, індукцію, дедукцію, методи економіко-математичного моделювання, узагальнення, прогнозування тощо.

Під час здійснення дослідження було використано онлайн-ресурси та друковані джерела, зокрема, підручники, наукові видання, бібліографії, наукові сайти, електронні ресурси, сайти постачальників ПЗ тощо.

Апробація результатів дослідження була здійснена на конференції "Шевченківська весна 2023" в секції "Моделювання та інформаційні технології в економіці: напрями розвитку та адаптація під час війни".

У першому розділі було здійснено аналіз криптовалют, їх місця у економіці та суспільстві, розглянуто історію їх появи та становлення як окремого платіжного засобу; проведено дослідження блокчейн-технологій, їх значення для криптовалют, рівень залучення блокчейну у операційні процеси бізнесу сьогодні, а також перспективи їх використання у майбутньому; здійснено огляд ринку криптовалют та визначено основні тенденції, що спостерігаються як на світовому, так і на ринку України.

У другому розділі було здійснено аналіз методів машинного навчання, проаналізовано історію розвитку даних методів, їх місця у моделювання та аналізі даних сьогодні; детально розглянуто глибинне навчання та його основні структурні елементи; досліджено основні інструменти, що використовуються для імплементації методів глибинного навчання при аналізі даних.

У третьому розділі за допомогою методу нейронних мереж на мові програмування Python було розроблено кілька моделей прогнозування курсу криптовалют та визначено найбільш ефективну.

РОЗДІЛ 1. ТЕОРЕТИЧНІ ОСНОВИ БЛОКЧЕЙН-ТЕХНОЛОГІЙ ТА ЇХ ВИКОРИСТАННЯ ДЛЯ КРИПТОВАЛЮТ

1.1. Історія появи та розвитку криптовалют

Економіка XXI століття характеризується різноманітними глобалізаційними процесами, що сприяють зміцненню інтеграції в економічній сфері між різними країнами. Безперечно, це веде до становлення єдиного світового ринку, що являється системою національних ринків. Безумовно, можна відмітити, що саме інформація займає місце одного з найбільших пріоритетних ресурсів нашого часу.

Варто зазначити, що за допомогою комп'ютеризації та телекомунікацій, знаходяться нові шляхи вирішення економічних та соціальних проблем. Адже завдяки їм вони забезпечують появу нових можливостей для їх вирішення. До того ж вони сприятливо впливають на загальний світовий економічний розвиток, завдяки їм росте продуктивність праці.

Світова економіка перебуває у безперервному стані перетворень: відбуваються технологічні зрушення, змінюються механізми керування економічними процесами, вартість та цінність матеріальних благ тощо. Ці трансформації відбуваються під впливом появи нових чинників, що мають вагомий вплив на базисні засади діяльності ринкового механізму національної, або навіть світової економіки [1].

Нині таким чинником виступає глобальна цифровізація, яка вплинула на розвиток практично всіх сфер економіки. В результаті з'явилися нові ринки, нові форми комунікацій, нові підходи до організації та управління виробництвом товарів та надання послуг.

Активна цифровізація призвела до формування цифрового профілю людини, що характеризує всі сторони його життя, а також сприяла певним світоглядним змінам – поряд з матеріальними цінностями, з'явилися цифрові: починаючи від прав

на об'єкти інтелектуальної та закінчуючи персонажами в комп'ютерних онлайн-іграх.

Ці товари та послуги стали вироблятися, купуватися та продаватися на глобальному цифровому ринку, який з моменту появи не мав географічних кордонів. Особливістю цього ринку є те, що переважна більшість товарів та послуг споживаються та використовуються у цифровому просторі. Наслідком цього є прискорення комунікації та "доставки" цифрових продуктів між продавцями та покупцями. У той же час обслуговування угод купівлі-продажу здійснювалось з використанням фіатних грошей та банківської інфраструктури.

Зіткнення цифрового середовища та аналогових каналів передачі цінності призвело до зниження швидкості та підвищення вартості транзакцій, а також до появи ризику втрати цифрової власності та грошових коштів внаслідок шахрайських дій третіх осіб [2].

Пошук вирішення проблем збігся зі світовою фінансово-економічною кризою 2007-2009 років, а пізніше – дестабілізацією міжнародних економічних відносин через ускладнення необхідних вимог та умов торгівлі з боку провідних розвинених країн, що розвиваються, запровадження економічних санкцій та широкого застосування інструментів протекціонізму.

У цих умовах став формуватися запит учасників світової економіки на формування альтернативних інструментів заощадження накопичень, що не корелюють з динамікою традиційних фінансових ринків, нових еквівалентів грошей, що відповідають сучасним вимогам цифрової економіки та є менш залежними від дій країн-емітентів. Поява криптовалют стала спробою технологічної відповіді на проблеми та виклики.

Розуміння сутності та популярності цього феномена вимагає більш детального розгляду передумов появи криптовалюти та мотивів суб'єктів економіки (громадян, фірм, банків та країн), які почали її використовувати [3].

Людство постійно намагалося переосмислити роль грошей. Види та форми грошей завжди йшли у ногу зі змінами в економічній системі, відображаючи поточні запити щодо вартості, засобу обігу, платежу, накопичення. В економіці натурального господарства роль грошей виконували різні товари: домашні тварини, шкури, хутра, сіль та інше, у постіндустріальний період – готівкові форми, безготівкові форми з використанням пластикових карток, смартфонів. У цифровій економіці функції грошей залишаються незмінними, але при цьому вимоги до них зростають:

- перехід максимальною мірою до безготівкової (цифрової) форми зберігання та розрахунків;
- мінімальні витрати на здійснення розрахунків та зберігання коштів;
- максимальна уніфікація технологій передачі та зберігання вартості;
- можливість самостійного здійснення розрахунків незалежно від часу та місця знаходження відправника;
- відсутність посередника у розрахунках та платежах та неможливість впливу третьої сторони на їх здійснення;
- швидкість, зручність та високий ступінь надійності здійснення розрахунків та платежів.

У кризові періоди рівень довіри суб'єктів економіки до держави стабільно знижується. Такі негативні явища як висока інфляція, різке знецінення національної валюти, валютні війни, санкції пов'язуються з неспроможністю та неефективністю державної зовнішньої політики, реалізованих заходів економічної та грошово-кредитної політики [4].

Довіра до фіатних грошей лежить у площині сприйняття суспільством держави як гаранта підтримки стабільного та стійкого середовища, що формує стимули для розвитку. У разі економічної невизначеності гроші перестають ефективно виконувати свої функції: здатність зберігати вартість чи верхній поріг пропозиції

грошей перестає бути обмеженим. У такій ситуації основні суб'єкти економіки активно шукають нові способи збереження та передачі цінності.

Криптовалюти стали першою масовою апробацією технології блокчейн. Технологія дозволяє будувати децентралізовані взаємодії, забезпечуючи їх захищеність. Це дає можливість технологічно підвищити ефективність економічних відносин шляхом виключення посередника, який є гарантом виконання зобов'язань кожного учасника.

На додаток до цього тенденції стрімкого розвитку цифрових технологій, здешевлення вартості комп'ютерних технологій, підвищення обчислювальної потужності та глибоке проникнення мобільних пристроїв відкривають нові засоби організації економічних відносин. Використання криптовалют у грошових відносинах дозволяє підвищити захищеність та контрольованість випуску приватних грошей [5].

Роль держави як єдиного емітента грошових знаків та регулятора грошово-кредитного обігу за даної системи знижується на противагу зростанню контролю з боку кожного суб'єкта та суспільства в цілому.

Однією з характерних рис сучасної економіки є інтернаціоналізація людини. Це виражається, зокрема, в можливості бути громадянином однієї країни, проживати в іншій країні, вести бізнес або працювати в третій країні. Іншими словами, людина вже не обмежена національними кордонами держави і не асоціюється з якоюсь конкретною країною і може обирати комфортне середовище для проживання та роботи.

Іншою рисою сучасних економічних відносин стало посилення ролі транснаціональних компаній (ТНК) та великих приватних корпорацій. Завдяки економічній могутності такі структури впливають на функціонування окремих галузей економік та держав у цілому. Приватні компанії формують моделі

поведінки людей, включаючи їхні смаки та звички, незалежно від громадянства останніх (Apple, Nike, McDonald's та ін.).

Крім того, ТНК вже замінюють державу навіть у таких традиційних сферах як освіта, культура та охорона здоров'я, забезпечення безпеки. Логічним продовженням такого перерозподілу ролей між державою та приватними компаніями зі своїми екосистемами та платформами стало використання компаніями альтернативних грошей (бали, бонусні милі та ін.) для зберігання та передачі цінності натомість або на додаток до національних та міжнародних валют [6].

Зважаючи на зазначені передумови, використання криптовалют та технології блокчейн стало однією з відповідей на можливості та виклики розвитку світової економіки в т.ч. пов'язані з недосконалістю державного та ринкового регулювання:

- криптовалюта – продукт цифрової економіки;
- під час створення криптовалюти застосовуються алгоритми, засновані на об'єктивних математичних законах;
- контроль обігу криптовалют здійснюється самою системою, що робить її більш стійкою по відношенню до дій третіх осіб;
- криптовалюти дозволяють знижувати транзакційні витрати;
- криптовалюти – міжнародний товар, створений у сфері й обслуговування всіх учасників розрахунків.

Однією з ключових характеристик товару, що розглядається як еквівалент грошей, є його цінність. Цінність фіатних грошей формувалася історично з моменту їх появи, подальшої прив'язки до золотого стандарту та закінчуючи гарантіями країн-емітентів. Роль та статус держави багато в чому визначають довіру та цінність фіатних грошей на сучасному етапі. Цінність цифрових грошей не може бути виміряна стандартними підходами, які застосовуються до аналізу фіатних грошей [7].

Н. Поливка зазначає, що "електронні гроші є одиницями виміру звичайних грошей у цифровому вимірі". Криптовалюта в переважній більшості випадків не забезпечена будь-яким товаром і не гарантована державою. Таким чином, її цінність визначається одночасно виходячи з індивідуального сприйняття та від того, як вона оцінюється іншими членами суспільства, тобто рівнем довіри до неї [8].

Існуючи лише у вигляді програмного коду та маючи обмежені можливості прямого обміну на товари, криптовалюта використовується в ролі грошей. Її унікальність по відношенню до фіатних грошей полягає також у тому, що її обмеженість у обороті та регульованість фактично забезпечується без участі держави.

Комп'ютерна програма з математичним алгоритмом у своїй основі дозволяє організувати саморегульовану грошову систему. У порівнянні з традиційною грошовою системою, цифрові гроші складно "передрукувати" і тим самим викликати інфляцію, адміністративно обмежити/заборонити використання та проведення операцій з криптовалютами.

Таким чином, зовнішній вплив сильних гравців (держав) та їх валют на криптовалюти обмежений. У перспективі це може забезпечити стабільну вартість цифрових грошей у часі (ціна фіатних грошей з плином тривалого проміжку часу, як правило, знижується) [9].

Незважаючи на технічні обмеження та складнощі, пов'язані з майнінгом та обігом криптовалют (низька швидкість обробки транзакцій, ризик стабільності системи тощо), окремі держави вже експериментують із цифровими грошима, а також технологією блокчейн. Проте значення перспектив використання криптовалют для громадян, держави та бізнесу різняться.

З точки зору бізнесу криптовалюти – це насамперед інший формат взаємодії економічних агентів зі скороченням кількості посередників в особі банків, державних та квазідержавних інститутів. Насправді це означає мінімізацію

бюрократичних формальностей реалізації розрахунків, збільшення швидкості надання послуг, зниження вартості проведення транзакцій. Окрема цінність може становити незворотність транзакцій порівняно з можливістю скасування будь-якої банківської транзакції або заперечення та розірвання угод у судових інстанціях. Випуск криптовалют, цифрових знаків (токенів) розглядається також як зручний спосіб залучення приватних інвестицій для фінансування запуску та/або фінансового забезпечення поточних бізнес-проектів.

Фізичні особи підходять до розгляду криптовалют та блокчейн з різних аспектів:

- дешевий інструмент для великих розрахунків;
- отримання доходу за рахунок інвестицій у купівлю криптовалюти та майнінгу.

Зростаючий інтерес населення до криптовалюти був більшою мірою обумовлений можливістю вкладення коштів та отримання надприбутку за рахунок зростання котирувань криптовалюти (передусім, біткойну). При цьому багато експертів вважають, що вкладення в цифрові гроші – це "фінансова піраміда", і незабаром фінансова бульбашка має луснути або вже луснула.

Фактори динаміки вартості криптовалюти слабо прогнозовані, що відбивається на суттєвих стрибках курсу криптовалюти по відношенню до фіатних грошей. При тому, що актив не забезпечений реальною цінністю, потенційна прибутковість за рахунок операцій купівлі-продажу дуже висока, що робить вкладення в криптовалюту дуже ризикованими та одночасно привабливими для спекулятивного капіталу. Можна міркувати про "переоціненість" або "недооціненість" криптовалют, але при цьому необхідно розуміти, що ці терміни застосовні переважно до фіатних грошей [10].

Для держави це питання складніше, ніж для інших суб'єктів економіки. З одного боку є великий потенціал для розвитку фінансових технологій.

Використання криптовалют та технології блокчейн може спростити та прискорити міжбанківські та міждержавні розрахунки, випуск та обіг боргових паперів, процедуру ідентифікації, знизити вартість транзакцій, забезпечити захищеність та зручність здійснення операцій за рахунок використання криптографії. Потенціал застосування технології блокчейн істотний і з позиції надання державних послуг (наприклад, в угодах з підтвердженням майнових прав).

Інша сторона використання цифрових фінансів пов'язана з участю держави у грошово-кредитній системі. Виступаючи єдиним емітентом законних грошових знаків, держава також контролює кількість грошей в економіці, їх обіг та монетарні канали інфляції. Використання криптовалют, що додає елементів технічного прогресу у фінансовий сектор, одночасно знижує регулюючі та контролюючі можливості центральних банків.

На сьогодні масштаб використання криптовалют не дає підстав вважати, що більшість суб'єктів світової економіки відходять від використання фіатних грошей на користь криптовалют. Порівняно з іншими сегментами та агрегатами грошового ринку, капіталізація ринку криптовалют вкрай мала.

У діяльності, що пов'язана з криптовалютами, простежуються певні тенденції розвитку. Деякі компанії починають експериментально допускати оплату своїх товарів та послуг криптовалютами, окремі країни створюють правові рамки для використання криптовалют на своїй території. Говорячи про тренд загалом, можна констатувати, що країни все ще придивляються до цього феномену, визначаючи баланс між потенціалом розвитку цифрових технологій та ризиками послаблення державного контролю [11].

Зміни, що відбуваються у світовій економіці, справді змінюють її вигляд. Промислова міць і дешева робоча сила, сконцентровані на території окремо взятої країни, поступаються місцем "кремнієвим долинам", що знаходяться в різних географічних точках і виробляють цифрові товари та послуги для всього світу.

Темпи та глибина цих змін збільшуються, зумовлюючи перехід від постіндустріальної до цифрової епохи світового економічного розвитку.

Технологія блокчейн та один із продуктів її реалізації – криптовалюта – справді можуть стати стартовою точкою для трансформації світової економіки. За допомогою блокчейну можуть суттєво змінитись відносини "держава-бізнес", "бізнес-бізнес", "населення-держава". Іншими словами, основна трансформація буде пов'язана з можливістю делегування комп'ютерній програмі проведення та верифікацію операцій без участі третіх осіб – держави, банків, інших посередників – результатам якої довірятимуть всі або більшість суб'єктів економіки або ринку.

Криптовалюта – це наступний крок в еволюції процесів у цифровій економіці, незважаючи на те, що саме цифрові гроші стали каталізатором інтересу до технології блокчейн. Можливі ризики ослаблення регулятивних можливостей держави вимагають більш ретельної оцінки ефектів від використання криптовалют та зіставлення її результатів із потенційними масштабами реформування державної системи регулювання економіки.

У зв'язку з ростом популярності криптовалют у фінансовій сфері багато науковців провели дослідження на тему криптовалют, їх місця в цифровій економіці, приділили увагу проблематиці прогнозування вартості криптовалют, а також проблемам сприйняття криптовалют з боку інвесторів, домогосподарств, держави та податкових органів [12].

С. В. Мерінова та Л. П. Половенко розглянули функціональні ролі криптовалюти у цифровій економіці, дослідили тенденції та перспективи їх розвитку, визначили основні сильні сторони та недоліки криптовалют, а також дослідили правовий статус криптовалюти у різних країнах світу та проаналізували тенденції щодо поширення легалізації криптовалют як платіжного засобу [13].

Танклевська Н. С., Петренко В. С., Карнаушенко А. С. дослідили сутність поняття "криптовалюта", дослідили історичний шлях становлення криптовалюти як

повноцінного грошового засобу, проаналізували властивості, якими володіють фіатні гроші, та визначили, чи володіє такими особливостями криптовалюта, охарактеризували та здійснили порівняльний аналіз п'ятьох основних видів криптовалют [14].

Шинкаренко О. М., Рогова Н. В., Панівнік І. А. розглянули поняття криптовалюти, навели підходи міжнародного регулювання криптовалют, а також висвітлили основні ризики, які можуть виникнути при здійсненні операцій з криптовалютами [15].

Гонак І. М. обгрунтував визначення криптовалюти як грошей та платіжного засобу [16]. Яровий К. О., Мартиненко О. В., Шнурко А. М. дослідили державне регулювання криптовалют, оцінили можливість запровадження законів, що регулюватимуть обіг криптовалют в економіці України [17].

Загалом варто зазначити, що українські вчені у своїх працях більше уваги приділяють сутності, особливостям криптовалют, їх місця в економіці держави, правового статусу тощо. Питання проблеми прогнозування вартості та курсу криптовалют є недостатньо дослідженим.

1.2. Блокчейн-технології як децентралізована система зберігання даних

Основи криптовалют були розроблені в 1992 році неформальною групою людей, зацікавлених у збереженні анонімності, та тих, хто цікавиться криптографією. У 1993 році американський програміст Ерік Хьюз заявив про можливість забезпечення конфіденційності платіжних операцій шляхом багатоетапного шифрування.

Потім у 1994 році американський вчений та інженер з корпорації Intel Тімоті Мей описав основні характеристики такої системи, у тому числі безпеку транзакцій, що не відстежуються, через їх шифрування, а також транзакції, які проводяться без посередників [18]. Для реалізації цих ідей треба було створити новий механізм розрахунків, що не торкається банківського сектора.

Вай Дай, який описав концепцію криптовалюти b-money у 1998 році, запропонував реальний спосіб виконання умов договору між анонімними учасниками. Девід Чаум винайшов "сліпий підпис". І лише через 10 років, досі невідома людина (або група людей) під псевдонімом Сатоші Накамото вивів у публічний простір цифрову валюту Біткойн, опублікувавши статтю "Bitcoin: Peer-to-Peer Electronic Cash System" у списку розсилки про криптографію [19].

У статті описується децентралізоване рішення з використанням ідей пірингової системи, криптографії, математичних правил, таких, як доказ роботи (Proof-of-Work) та загальних правил проведення транзакцій між учасниками системи. Дане рішення отримало назву блокчейн біткойну. Ця подія і стала відправною точкою у розвитку даної технології [20-21].

Блокчейн – побудований за певними правилами неперервний послідовний ланцюжок блоків, що містять певну інформацію. Такий підхід є технологією надійного розподіленого зберігання записів про всі будь-коли виконані транзакції.

Блокчейн є ланцюжком блоків даних, обсяг якого постійно зростає в міру додавання нових блоків із записами останніх транзакцій. Це хронологічна база даних, тобто така база даних, у якої момент, коли було зроблено запис, нерозривно пов'язаний з самими даними, що робить його некомутативним [22].

Дані представлені послідовністю записів, які можна доповнювати. Записи разом із допоміжною інформацією зберігаються в блоках. Блоки зберігаються як однозв'язний список. Кожен учасник представлений вузлом, який зберігає весь актуальний масив даних та контактує з іншими вузлами. Вузли можуть додавати нові записи до кінця списку, а також повідомляють один одному про зміну списку [23].

Хешування – перетворення масиву вхідних даних довільної довжини в вихідний бітовий рядок встановленої довжини, що виконується певним

алгоритмом. Функція, що втілює алгоритм і виконує перетворення, називається "хеш-функцією" або "функцією згортки" [24].

Початкові дані називаються вхідним масивом, "ключом" або "повідомленням". Результат перетворення називається "хеш", "хеш-кодом", "хеш-сумою", "зведенням повідомлення".

Приклад хешування наведений на рис. 1.1. У даному прикладі назвою хеш-функції є SHA256, вхідним масивом є ціна, час та користувач, що здійснили транзакцію. У результаті отримується хеш-код, що є комбінацією символів: "189f07edd629caf6509168372d1f6975ec45cd877788b790a348c43ec4cfc466".

Набір символів у полі "Hash" є унікальним для заданого набору вхідних даних поля "Data". Він також може бути отриманий для іншого набору вхідних даних. Однак процес зворотного вилучення вхідних даних за допомогою наявного хеш-коду є завданням, що вимагає великих обчислювальних потужностей [25-26].

SHA256 Hash

Data:	price: 200usd, time: 01-01-2023 08:00:00, user: 24145
Hash:	189f07edd629caf6509168372d1f6975ec45cd877788b790a348c43ec4cfc466

Рис. 1.1. Компоненти хешування

Джерело: розроблено автором

У блоці використовується той самий процес хешування, проте вхідні дані розділені на чотири секції (рис. 1.2):

- "Block" – номер блоку в ланцюзі;
- "Nonce" – випадкове число, яке генерується для отримання такого хеша, який задовольняв би закладені розробниками умови;

- "Data" – набір даних;
- "Prev" – хеш попереднього блоку в ланцюзі.

The image shows a web interface for creating a block in a blockchain. It features a light green background. At the top, there is a 'Block:' label followed by a dropdown menu showing '# 1'. Below that is a 'Nonce:' label and a text input field containing the number '11316'. The 'Data:' label is followed by a large, empty text area. Underneath is a 'Prev:' label and a text input field filled with a long string of zeros. The 'Hash:' label is followed by a text input field containing a long alphanumeric string: '000015783b764259d382017d91a36d206d0600e2cbb3567748f46a33fe9297cf'. At the bottom of the form is a blue button with the text 'Mine'.

Рис. 1.2. Схема блока ланцюга

Джерело: розроблено автором

Послідовність таких блоків називається "ланцюгом блоків" або блокчейн. Базову модель розподілу даних у системі, побудованої на блокчейні, можна представити у вигляді наступної послідовності дій:

1. Нова транзакція надсилається всім вузлам мережі, мережа побудована за принципом пірингової мережі, транзакція потрапляє в пул необроблених даних на цих вузлах (рис. 1.3).
2. Певні вузли, що займаються майнінгом (діяльність зі створення нових блоків в блокчейні для забезпечення функціонування криптовалютних платформ) (на рис. 1.3 відзначені сірим кольором), додають транзакції, розташовані в пулі необроблених даних у блок (рис. 1.4).

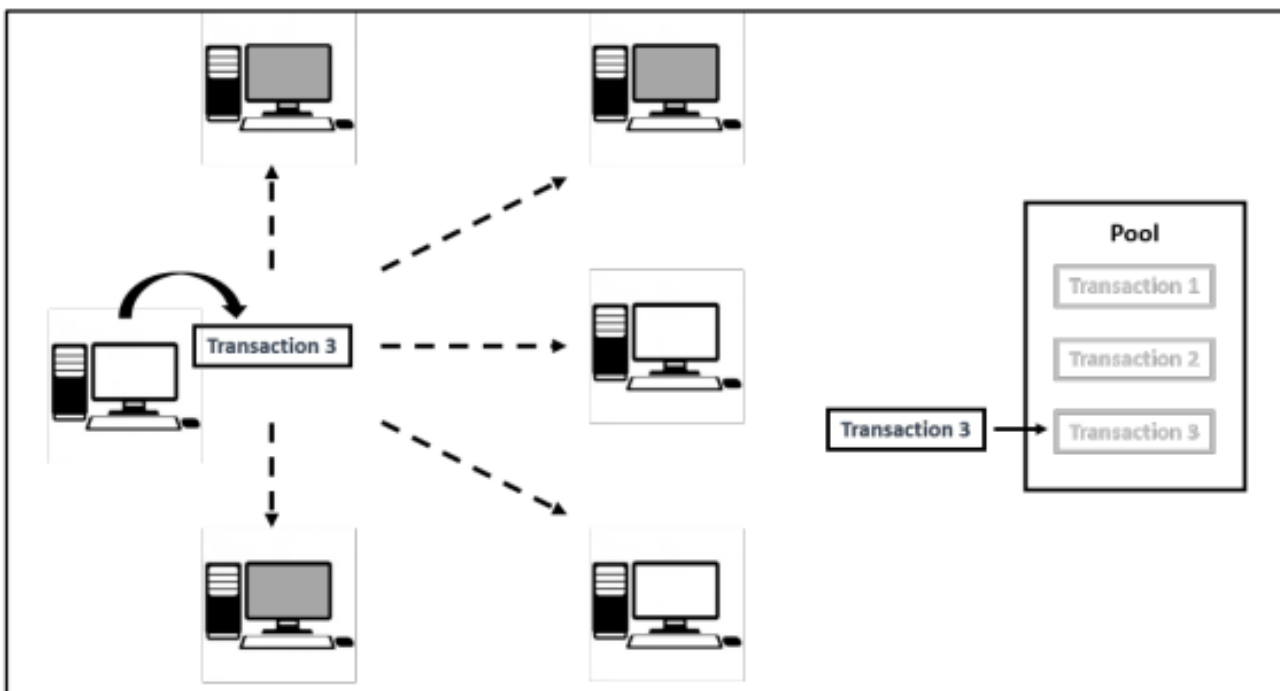


Рис. 1.3. Додавання транзакцій в пул необроблених транзакцій

Джерело: розроблено автором

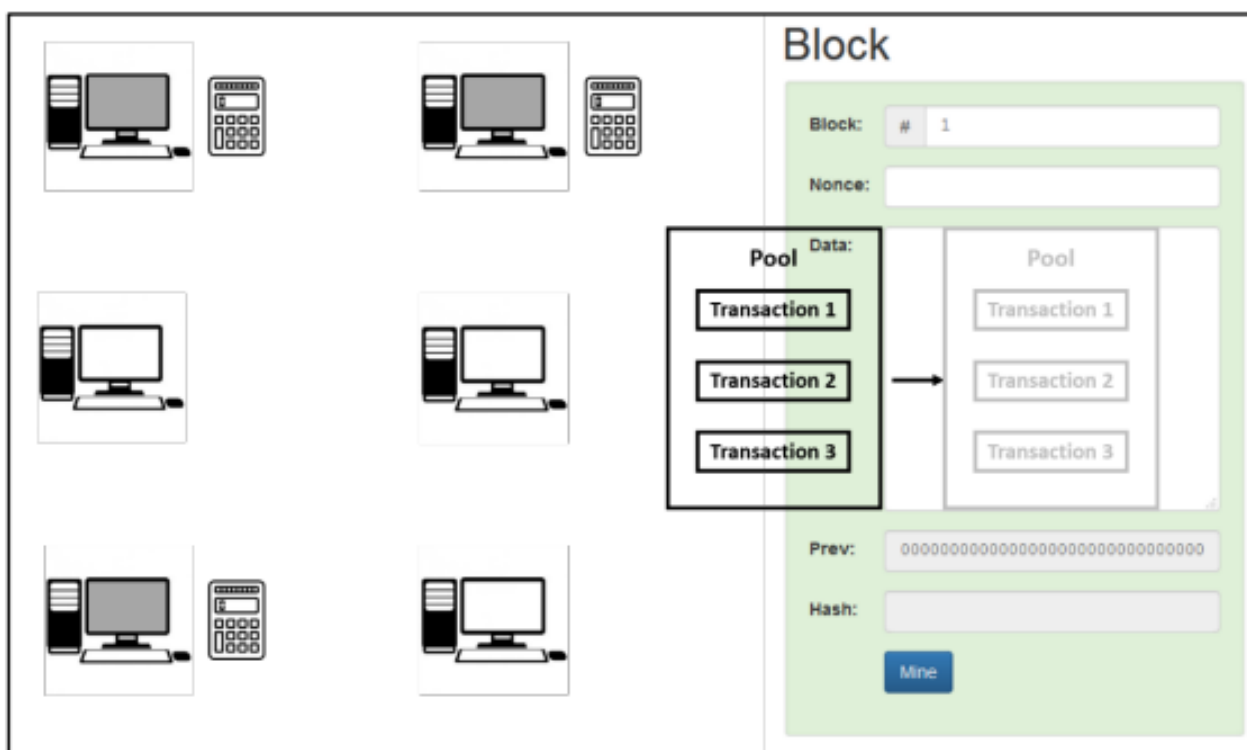


Рис. 1.4. Додавання пулу необроблених транзакцій в блок

Джерело: розроблено автором

3. Кожен майнер шукає таке значення поля "Nonce", при якому хеш блоку задовольняв би задані розробниками умови (у блокчейні біткойна умовою була наявність на початку хеш блоку певної кількості нулів), дана операція називається підтвердженням роботи (proof-of-work). Також на даний момент з'явився інший спосіб підтвердження права на здійснення операції з внесення блоку – метод підтвердження частки (Proof-of-stake).
4. Перший майнер, який отримав хеш блоку, що задовольняє умову, відправляє блок даних всім учасникам мережі, а сам майнер отримує винагороду за додавання блоку (рис. 1.5). Не критично, якщо блок отримують не всі вузли. Як тільки вузол, що пропустив один з блоків, отримає наступний за ним, він запросить інформацію, щоб заповнити пропуск.

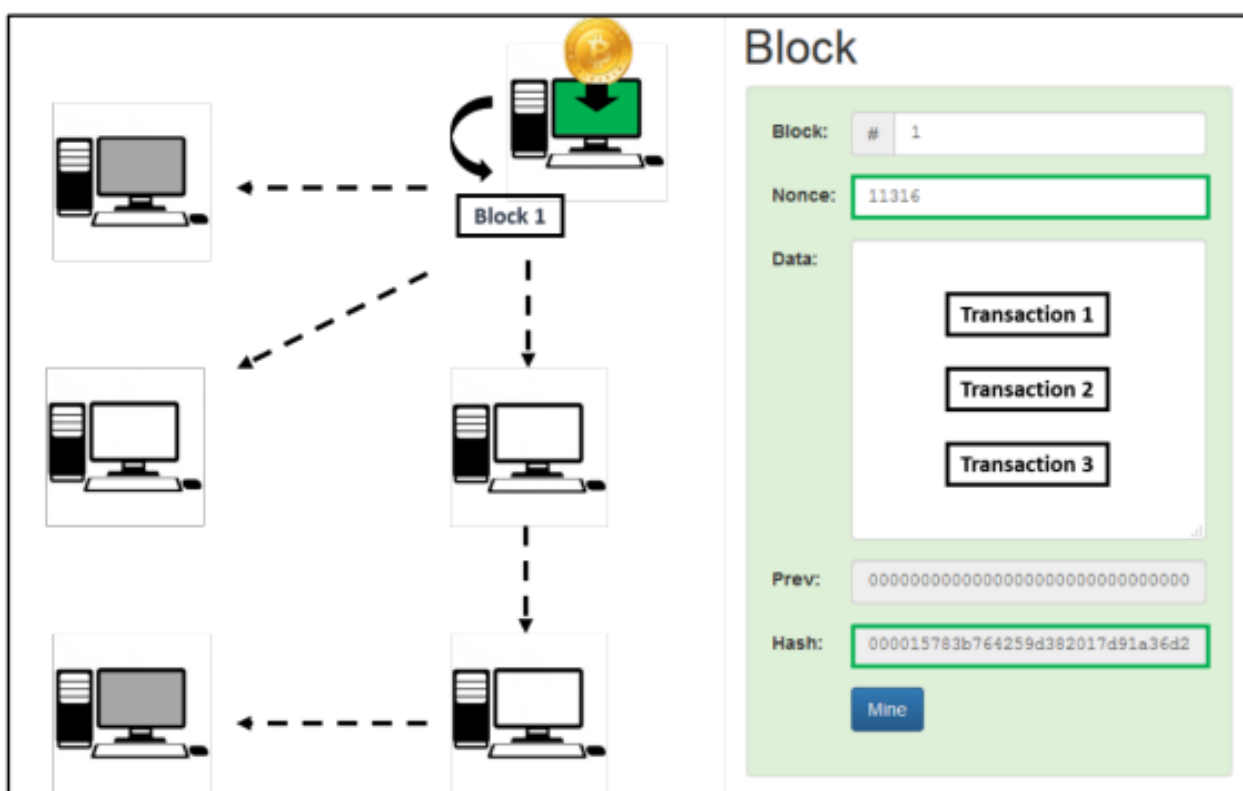


Рис. 1.5. Обчислення хешу та його відправка іншим вузлам

Джерело: розроблено автором

5. Вузли, які отримали даний блок проводять перевірку на коректність транзакцій та відсутність так званої подвійної витрати. Якщо блок не проходить перевірку, він відкидається.
6. Якщо досягається згода щодо коректності блоку, майнери додають його в ланцюжок і починають працювати над новим блоком даних, заснованим на хеші щойно доданого блоку (рис. 1.6).

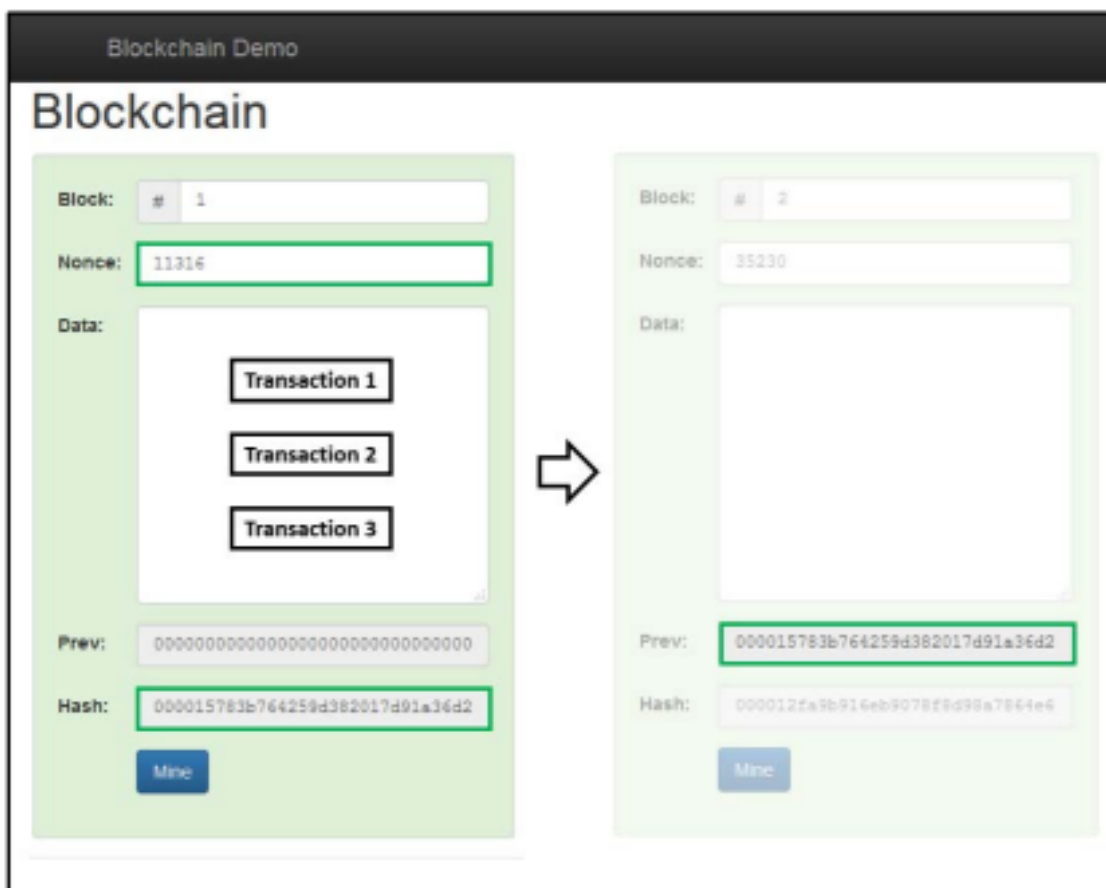


Рис. 1.6. Додавання блоку в блокчейн

Джерело: розроблено автором

Оскільки у формуванні хеша поточного блоку, крім інших вхідних даних, бере участь, у тому числі, і хеш попереднього блоку, будь-яка зміна будь-яких вхідних даних попереднього блоку призведе до зміни як попереднього хеша, так і хеша блоку, що йде за ним, який через це перестане відповідати заданій умові, а слідом за ним некоректним стане і весь наступний ланцюг.

Крім того, чим старіший блок у ланцюзі, тим складніше його змінити. Інформація про транзакції не передається у відкритому вигляді, інакше кожен зміг би створити транзакцію, "представившись" у системі іншою людиною, і таким чином відправити всі кошти самій собі. Дані про відправників та одержувачів перетворюються на зашифрований набір символів.

Кожен учасник мережі під час реєстрації у ній та встановлення необхідного програмного забезпечення на робочу станцію генерує випадковий набір чисел (приватний ключ), з допомогою якого формується інший, складніший набір символів (публічний ключ). Отримати приватний ключ із публічного неможливо, оскільки його довжина дуже велика і потребує величезних обчислювальних потужностей.

Приватний ключ належить лише користувачеві, який згенерував його. Він не бере участі в транзакціях, і його не можна розголошувати нікому. Він служить для здійснення підпису транзакції, проте у відкритому вигляді не передається [27].

Для того, щоб надіслати транзакцію, кожен користувач здійснює підпис цієї транзакції. У деталях транзакції під час відправки коштів він вводить свій публічний ключ для позначення свого гаманця як відправника, а в одержувачах – публічний ключ того гаманця, на який потрібно переказати кошти, та суму, яку бажає переказати (рис. 1.7).

На основі цих вхідних даних та приватного ключа формується підпис, а потім надсилається іншим учасникам для перевірки та внесення транзакції до блоку. Маючи підпис та всі вхідні дані, кожен користувач системи може перевірити, що транзакція, яку намагаються внести до блоку, підписана користувачем, який має доступ до реального приватного ключа.

Таким чином, блокчейн вже не має персональних даних про осіб, які передають кошти тій чи іншій особі, а має лише деякі ключі, що є гаманцями, за якими знаходяться ті чи інші особи та підписи до кожної транзакції (рис. 1.8).

Blockchain Demo: Public / Private Keys & Signing

Transaction

Sign **Verify**

Message

\$ 20.00 From: 04b510a7848f82f9649c79a- -> 04cc955bf8e359cc7ebbb66:

Private Key

3602980977560031527972367780215973463822503838405764608545064160491362493286

Sign

Message Signature

3045022100d5788af67e84867a6d9a9a7296344b64b7b9d353b3e002e99e2aeeba9cb17cb102200434137d6b18

Рис. 1.7. Підписання транзакції

Джерело: розроблено автором

Blockchain Demo: Public / Private Keys & Signing

Peer A

Block: # 3

Nonce: 78864

Coinbase: \$ 100.00 -> 04fe1be031bo7a54d900ff0

Tx:

\$ 10.00 From: 04222d7af34- -> 04d4080959e3'
Sig: 304402206866c204f14735649c4d61a955afedc1a9f0d1ef231

\$ 5.00 From: 041c377677bb- -> 04d4080959e3'
Sig: 3044022100b2a689ef250d79fbb600204f56e11436ef742a9c5

\$ 20.00 From: 04997ac426a5- -> 040b4c84f02b:
Sig: 3044022018296b3a4df98af5fc2f0b0e009730ffe963e4a62df

Prev: 00007dcbba72607746138920c2213f34d2138b5bf5fa80bcb26b4b9

Hash: 0000a9e2a5d6100c1fa23580671cc4f3bca3c58180d0f55e49f9e49a

Mine

Block: # 4

Nonce: 63022

Coinbase: \$ 100.00 -> 04fe1be031bo7a54d900ff0

Tx:

\$ 15.00 From: 04d4080959e3' -> 0451d4a9c44a:
Sig: 3045022100dfc2534ba49c1c3f947e4d29ac5f544420e9e03f

\$ 5.00 From: 04222d7af34- -> 041c377677bb:
Sig: 304402200b8d07fe4949a8eb958262d1fe579a5f0f96c2b4e1a

\$ 8.00 From: 04cc17dc1293- -> 04d4080959e3'
Sig: 30440220665c64c85982f75d78aa9957a6a805ed4999f8ad183

Prev: 0000a9e2a5d6100c1fa23580671cc4f3bca3c58180d0f55e49f9e49a

Hash: 0000e0e3d78d093313f15936f2b3d08f06b2bd095044342a1c896a3ee

Mine

Рис. 1.8. Схема ланцюга блоків з публічними ключами та підписами

Джерело: розроблено автором

Хеш у цій схемі – це перетворений за допомогою хеш-функції масив даних. У випадку криптовалют – це інформація про транзакцію, у більш складних системах – це інформація про смарт-контракти та актуальний стан програмного коду, внесеного до блокчейну.

В результаті перетворення ми отримуємо практично унікальний, крім випадків колізій хешування, літерно-числовий рядок, який характеризує початковий елемент, але не може бути перетворений в початкову інформацію. Поєднання використання відкритих та закритих ключів спільно з хешуванням дає технології блокчейну високий рівень безпеки зберігання даних [28].

Якщо один із майнерів намагається додати блок, що не відповідає даному правилу, такий блок автоматично відхиляється іншими учасниками мережі блокчейна. Щоб майнер зміг додати невалідний блок, необхідно змінити хеш усіх попередніх блоків, аж до так званого "генезису-блоку" – першого блоку в системі. Цей блок зазвичай задається розробниками системи. З цього виникає одна з істотних властивостей технології розподіленого реєстру – інформація, що потрапила в ланцюжок блоків, не може бути змінена постфактум [29].

З огляду на те, що в процесі майнінгу користувачі стали об'єднуватися в групи, звані пулами, з'явилася можливість переписати нещодавно доданий блок, однак це також є завданням, що важко здійснити, оскільки в такому випадку все одно доводиться боротися з обчислювальними потужностями всієї іншої мережі [30].

Необхідно зазначити, що додавання нових блоків майнерами відбувається за певними принципами. Дані принципи були введені в систему для підвищення безпеки блокчейну і водночас забезпечення децентралізації системи.

На даний момент існують два основні принципи, за якими в системі досягається консенсус щодо додавання нового блоку в блокчейн – це доказ виконаної роботи (Proof-of-work, або PoW) і доказ частки володіння (Proof-of-stake, або PoS).

У зв'язку з тим, що безпека блокчейну не покладається на єдиний центр, що засвідчує правильність виконання операції, такий, наприклад, як банк, з його інфраструктурою безпеки, то кожен з вузлів даної системи не знає апріорі, яка версія бази даних є дійсною [24].

Якщо відбудуватиметься атака на базу даних блокчейна, атакуючий майнер повинен вирішити те саме завдання, що й інша частина мережі, тобто решта усіх майнерів. Таким чином атака буде успішною, тільки якщо атакуючий майнер зможе залучити значні обчислювальні ресурси, які будуть перевищувати ресурси усіх інших майнерів у системі.

Функціонування протоколу біткойна таке, що безпека мережі підтримується наступними ресурсами:

- спеціалізоване обладнання для виконання обчислень;
- електрика, необхідна для роботи обладнання.

Це робить біткойн неефективним з точки зору споживання ресурсів. Для збільшення своєї частки винагороди, майнери в мережі біткойн змушені брати участь у гонці озброєнь, тобто використовувати все більше ресурсів для майнінгу. З одного боку, це робить вартість атаки на біткойн непомірно високою. З іншого ж, екологічна недружелюбність біткойна призвела до виникнення пропозицій побудувати подібні системи, які вимагають набагато менше ресурсів.

Вирішенням цієї проблеми став метод, заснований на алгоритмі підтвердження частки (PoS). Ідея підтвердження частки така: ймовірність створити новий блок і отримати відповідну винагороду є пропорційною до частки володіння користувача в системі. Щоб провести успішну атаку, зловмисник має придбати більшу частину валюти, а це буде непомірно дорого, якщо система буде досить популярною.

Розподілена природа баз даних робить зламування хакерами практично неможливим, оскільки для цього їм потрібно одночасно отримати доступ до копій бази даних на величезній кількості комп'ютерів у мережі. DoS-атаки також стають

безглуздими, оскільки немає єдиного центру, який був би схильний до відмови в обслуговуванні.

Таким чином, технологія розподіленого реєстру має наступні характеристики:

- децентралізація;
- відкритість внесених даних;
- математико-криптографічний захист інформації;
- неможливість змінити один раз внесені в систему дані.

У різних джерелах часто виділяють такі особливості:

- прозорість: доступ до всієї історії подій – грошових переказів, угод та інших записів – завжди відкритий всім учасникам системи;
- децентралізованість: історія транзакцій зберігається у кожного учасника на жорсткому диску, а не на якомусь головному сервері;
- анонімність: для роботи в блокчейні не потрібно розкривати особистість;
- рівноправність: у блокчейні немає адміністраторів або зберігачів інформації, а у всіх учасників однаковий статус та можливості;
- безпека: ніхто не підробить та не підмінить зафіксовану в блокчейні інформацію, можна бути впевненим, що вона достовірна.

1.3. Огляд ринку криптовалют

Ринок криптовалют – це ринок, де відбувається операції купівлі та продажу криптовалют. У 2020 році світовий ринок криптовалюти оцінювався в 1,49 мільярда доларів США, а до 2030 року, за прогнозами, досягне 4,94 мільярда доларів США, зростаючи на 12,8% у середньому з 2021 по 2030 рік.

Зростання потреби в операційній ефективності та прозорості фінансових платіжних систем, зростання попиту на грошові перекази в країнах, що розвиваються, підвищення безпеки даних і покращення ринкової капіталізації є основними факторами, які стимулюють зростання глобального ринку криптовалют.

Крім того, висока вартість впровадження та недостатня обізнаність про криптовалюту серед людей у країнах, що розвиваються, перешкоджають зростанню ринку криптовалют. Крім того, очікується, що збільшення попиту на криптовалюту серед банків і фінансових установ, а також невикористаний потенціал економік, що розвиваються, забезпечать вигідну можливість для розширення ринку протягом прогнозованого періоду.

Сегмент продажу обладнання займає основну частку ринку криптовалюти завдяки зростанню потреби в модернізації продуктивності програмного забезпечення та підвищення ефективності інструментів фінансових платежів. Однак очікується, що сегмент програмного забезпечення зростатиме найвищими темпами протягом наступних років на ринку криптовалют, оскільки це полегшує керування величезним обсягом даних, які генеруються для значущої інформації та прийняття більш обґрунтованих рішень.

У 2020 році на ринку криптовалют домінував Азіатсько-Тихоокеанський ринок, і очікується, що він збереже свої позиції протягом наступних років. Головним фактором такої популярності є збільшення кількості біткойн-обмінників по всій Азії, що приносить певну здорову конкуренцію та зрілість індустрії криптовалют [31].

Китайські банки наймають експертів з блокчейну, оскільки уряд наполягає на використанні технології, що лежить в основі біткойна, для підвищення прозорості та боротьби з шахрайством у фінансовому секторі. Ці фактори стимулюють зростання ринку криптовалют у регіоні.

За останні 5 років інтерес інвесторів до криптовалюти дуже стрімко зріс, оскільки біткойн (BTC) і ефіріум (ETH) досягли історичних максимумів, протоколи децентралізованого фінансування (DeFi) зросли до рекордних розмірів, ринкова капіталізація криптовалют перевищила 3 трильйони доларів США, ринок NFT-

токенів зростав з експоненціальним характером, а компанії венчурного капіталу інвестували в багато бізнесів, що пов'язані з криптовалюти.

Централізовані фінансові біржі (CeFi) спостерігали неймовірне зростання, оскільки їхні послуги пропонували привабливий рівень дохідності для інвесторів, порівняно з традиційними фінансовими ринками.

У 2022 році ринок криптовалют не просто зупинився у своєму зростанні – обсяг попиту на криптовалюти значно впав. Коли центральні банки змінили курс, почали знижувати ринкову ліквідність і підвищувати процентні ставки, спекулянти криптовалютою зупинили свою активність на ринку.

Завдяки збільшенню процентних ставок інвестори отримали можливість тримати інвестиції з меншим ризиком і отримувати високий дохід. Коли ціни на ризикові активи почали знижуватися, криптовалюти почали розпродаватися. До кінця другого кварталу 2022 року капіталізація криптовалютного ринку впала на понад 1 трильйон доларів. У третьому кварталі 2022 року дане падіння тільки прискорювалося.

Нові стартапи, куди було вкладено мільйони доларів, збанкрутували, коли трейдери покинули крипторинки. Стейблкоїн UST було офіційно відв'язано від долара США, через падіння якого інвестори втратили мільярди доларів. Внаслідок цього загальний ринок опинився під ще більшим тиском.

До кінця літа 2022 року крипторинки почали демонструвати ознаки стабілізації. Ринковий індекс CoinDesk (CMI) піднявся до літнього максимуму в 1092 доларів у вересні. Довіра поверталася на ринки завдяки великій біржі FTX, яка продовжувала інвестувати в криптокомпанії, що знижувало рівень недовіри інвесторів до криптовалют.

Довіра до криптовалют зберігалася до пізньої осені 2022 року, коли відбувся скандал щодо фінансових махінацій, що проводила біржа FTX, що призвело до ще одного значного падіння капіталізації ринку криптовалют.

Важливо зазначити, що жодна з криз, що пов'язана з криптовалютами, які відбулися у 2022 році, не була спричинена збоєм базової технології блокчейн. Насправді технічний розвиток даної технології триває, і останні роки стали важливим періодом в історії блокчейну.

У 2022 році Ethereum пройшов успішне оновлення, перейшовши від блокчейну з підтвердженням роботи (proof-of-work) до блокчейну з підтвердженням частки (proof-of-stake). Токеноміка Ethereum також значно змінилася, що принесе користь екосистемі Ethereum у перспективі.

Кризи на ринку криптовалют, які спостерігалися у 2022 році, змусили багатьох експертів закликати до запровадження подальшого регулювання криптовалюти. Шахрайство, крадіжки, а також безвідповідальне кредитування та торгівля за допомогою кредитних коштів створили складні умови для інвесторів, які були б неможливими за належного державного контролю та регулювання [32].

На рис. 1.9 наведено динаміку зміни вартості біткойну, починаючи з 2013 року до квітня 2023 року. Варто зазначити, що ринок криптовалют почав знову зростати, починаючи з кінця 2022 року.

Однак криза на ринку усіх криптовалют через падіння криптобіржі FTX у листопаді 2022 року продовжилася і у 2023 році.

8 березня криптобанк Silvergate Capital оголосив, що згортає свою діяльність і ліквідує свої активи. Рішення було прийнято після того, як загальні депозити банку впали з 11,9 мільярда доларів на кінець третього кварталу 2022 року лише до 3,8 мільярда доларів, що змусило Silvergate продати боргові цінні папери на 5,2 мільярда доларів із великими збитками.




Рис. 1.9. Динаміка зміни вартості біткойну

Джерело: [33]

Лише через два дні після того, як Silvergate оголосив про закриття, Федеральна корпорація страхування депозитів (FDIC) оголосила про арешт банку Silicon Valley. SVB мав приблизно 209 мільярдів доларів загальних активів і 175 мільярдів доларів депозитів станом на кінець 2022 року.

12 березня регулятори штату Нью-Йорк закрили криптобанк Signature Bank, який станом на кінець 2022 року мав понад 110 мільярдів доларів активів і 88 мільярдів доларів депозитів.

Налякані інвестори продали стейблкоїн USD Coin на суму понад 2 мільярди доларів після того, як материнська компанія USDC Circle Internet Financial заявила, що має 3,3 мільярда доларів у резервах у Silicon Valley Bank [33].

Таким чином, на ринку криптовалют у 2023 році панують дуже нестабільні настрої, інвестори продовжують продавати свої активи і все менше великих гравців на цьому ринку продовжують масові інвестиції у криптовалюту.

Інвестори повинні знати, що поточне макросередовище, відсутність регулювання та довіри до криптовалюти, а також нечіткі нормативні рамки продовжуватимуть чинити тиск на криптовалюту. Незважаючи на те, що ці проблеми значні, і їх буде непросто подолати, інновації та прогрес у блокчейні продовжують зростати, а список сфер застосування технології блокчейн продовжує розширюватися.

Проаналізуємо ринок криптовалют в Україні. Чинне законодавство України досі не містить законодавчо затвердженого визначення, що таке криптовалюта. Деякі аналітики вважають, що криптовалюти підпадають під закони про віртуальні активи.

Вагома частка представників фінансового сектору вважають, що криптовалюта є підвидом електронних грошей, а не віртуальним активом. Якщо приймати таку точку зору, то тоді Закон України "Про віртуальні активи" криптовалют не стосується [34].

Однак при аналізі Закону України "Про віртуальні активи" варто зазначити, що криптовалюти мають багато спільних ознак з тими характеристиками віртуальних активів, що перелічені у Законі. Це такі ознаки, як нематеріальність, можливість аргументованого визначення вартості, існування лише у цифровому форматі та у межах певного програмного забезпечення чи електронної системи.

Проте цим ознакам підпадають і інші нематеріальні активи, які ніяк не пов'язані з криптовалютами – ігрові скіни, цифрові токени, NFT тощо.

Основною відмінністю криптовалюти від віртуального активу є те, що криптовалюти широко застосовуються як платіжний засіб. Закон України "Про віртуальні активи" чітко заперечує можливість використання віртуального активу як засобу оплати. Таким чином, криптовалюти та віртуальні активи є схожими за своїми ознаками, однак не є тотожними [35].

Отже, можна зробити висновок, що обіг криптовалют на ринку України на даний момент не є регульованим у правовому плані. Оплата товарів та послуг криптовалютами є фактично нерегульованими та нелегальними на території України і це дуже стримує розвиток індустрії цифрових технологій в Україні.

Однак незважаючи на це, за даними Міністерства цифрового розвитку України, Україна входить до топ-5 країн світу за кількістю користувачів криптоактивів. Досвід використання та інвестування віртуальних активів має щонайменше 1 млн українців, свідчать розрахунки ресурсу Chainalysis. Обороти криптовалют в Україні – 1 млрд грн на добу згідно з даними Міністерства.

У 2021 році українські інвестори отримали прибуток від інвестицій у цифрові активи у розмірі майже \$2,8 млрд (13-те місце у загальному рейтингу), підрахувала аналітична компанія Chainalysis. Загальний прибуток власників криптовалют у світі склав \$162,7 млрд.

Варто зазначити, що у 2021 році на ринку криптовалют України відбувся бум – оборот ринку виріс у 5 разів. Однак уже в 2022 році оборот біткойну в Україні впав. На це вплинули два великих фактори – загальне падіння вартості біткойну відносно долару та війна в Україні, що похитнула фінансову стабільність у країні [36].

РОЗДІЛ 2. ВИКОРИСТАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ ПРОГНОЗУВАННЯ В ЕКОНОМІЦІ

2.1. Машинне навчання та його ключові елементи

Термін "машинне навчання" у 1959 р. ввів у наукову лексику А. Семюел, американський дослідник у галузі комп'ютерних ігор та штучного інтелекту [37]. Як наукова дисципліна машинне навчання відокремилося під час досліджень технологій штучного інтелекту (ШІ). Перші дослідники були зацікавлені в тому, щоб машини навчалися на масивах даних і намагалися підійти до проблеми за допомогою перших прототипів нейронних мереж: це були головним чином перцептрони та інші моделі, які пізніше були узагальнені в межах лінійних моделей статистики.

У останній чверті ХХ ст. в рамках машинного навчання були запропоновані такі підходи до аналізу даних, як дерева рішень, асоціативні правила та самоорганізовані карти ознак [38-40]. В ХХІ ст. українські вчені активно проводили дослідження використання методів машинного навчання в економічних процесах, зокрема Черняк О.І., Черноус Г.О., Кучерук Л.В., Ситник В.Ф., Краснюк М.Т. тощо.

Машинне навчання – це частина теорії штучного інтелекту, предметом якої є пошук рішень для поставлених проблем, шляхом навчання під час вирішення схожих кейсів. Базою для розробки алгоритмів машинного навчання стала математика та її методи, включаючи такі її розділи, як алгебра, математична статистика, дискретна математика, теорія оптимізації, чисельні методи тощо.

Машинне навчання лежить на стику традиційної математики та математичної статистики. Крім того, машинне навчання вирішує проблеми, що пов'язані з точністю обчислень під час перенавчання. Найбільш поширені методи машинного навчання проектувалися для заміни традиційних статистичних підходів. Майже всі способи стосуються отримання даних з подальшим їх аналізом [41].

Деякі сегменти машинного навчання віднесені до спеціального окремого напрямку і називаються доктриною обчислювального навчання. Певні методи тісно пов'язані з "добуванням" інформації, інтелектуальним аналізом даних (Data Mining) [42].

Машинне навчання має широке застосування на практиці, а не лише аналітичний та теоретичний зміст. Перевірка різних методів та алгоритмів на реальних даних досягається за рахунок емпіричного досвіду. Для досягнення ефективної роботи запропонованого рішення застосовуються додаткові методи, які базуються на мінімізації величини похибки між прогнозними значеннями та реальними даними. Для оцінки практичної користі алгоритму використовують різні експерименти на прогнозних значеннях і реальних даних.

Є три типи методів машинного навчання: дедуктивний, індуктивний та трансдуктивний [43].

Дедуктивне навчання або навчання "зверху-вниз" (від загального до конкретного), передбачає формалізацію знань експертів та їх перенесення в комп'ютерну систему у вигляді бази знань. Дедуктивне навчання прийнято відносити до галузі експертних систем. Тобто спочатку формуються знання, сформульовані експертом та якимось чином формалізовані через рівняння, теореми, залежності тощо. Після цього програма – експертна система – виводить із цих правил конкретні факти та нові правила.

Індуктивне навчання чи навчання "знизу-вгору" (від конкретного до загального), являє собою зазвичай навчання з прикладів, навчання по прецедентах, засноване на виявленні закономірностей в емпіричних даних, тобто даних, отриманих шляхом спостереження або експерименту.

Індуктивне навчання комп'ютерів прийнято відносити до машинного навчання. За підсумками аналізу емпіричних даних програма будує загальне правило.

Емпіричні дані можуть бути отримані самою програмою у попередні сеанси її роботи або просто надані їй користувачем [44].

Трансдуктивне навчання або навчання від конкретного до конкретного дозволяє на основі емпіричних даних без виявлення загальних закономірностей і формалізації знань зробити висновки про інші емпіричні дані.

Поняття трансдукції було запропоновано В. Вапником у 1990 році: "При вирішенні проблеми, що цікавить, не вирішуйте більш загальну проблему як проміжний крок. Постарайтеся отримати відповідь, яка вам дійсно потрібна, але не ту, яка є загальною" [45]. Приклад трансдуктивного навчання наведено на рис. 2.1. Якщо не враховувати об'єкти без мітки, тоді неможливо правильно сегментувати множину, тому що занадто мало розмічених об'єктів.

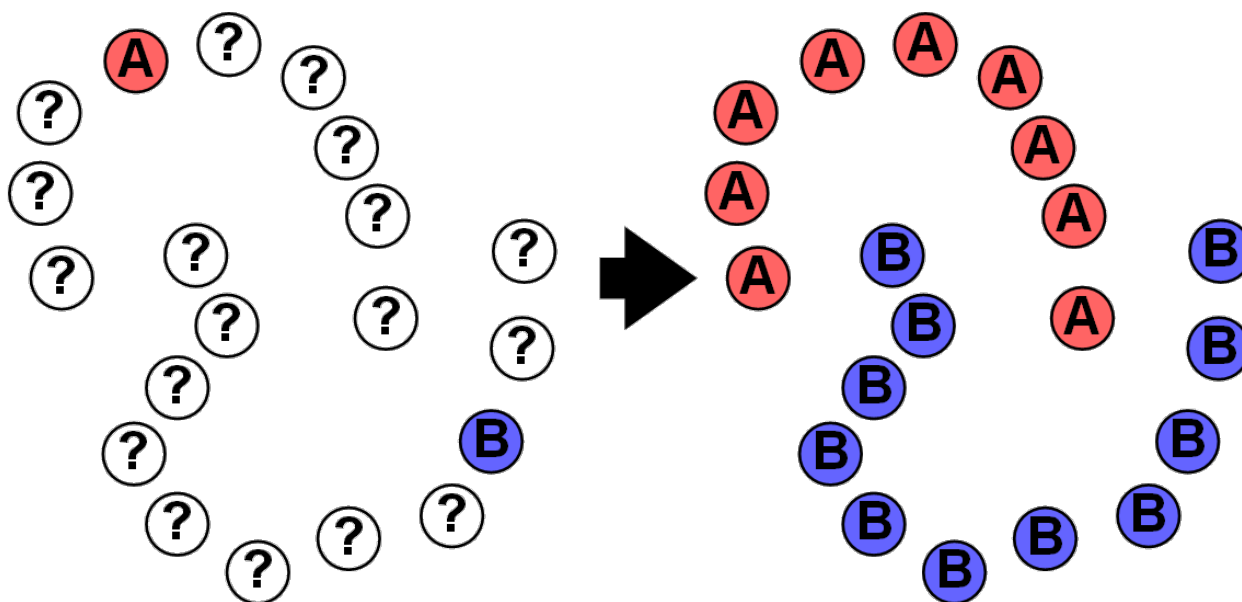


Рис. 2.1. Приклад трансдуктивного навчання

Джерело: [45]

При розв'язанні задачі пошуку загального рішення для множини усіх випадків методом індукції, нерозмічені об'єкти не враховуються. Для навчання моделі ці дані виключаються, оскільки нерозмічені дані є так званими збуреннями, що знижують точність результату моделі, створеної за допомогою методу індукції [46].

Облік присутніх нерозмічених даних може кардинально змінити якість рішення, але якщо з'являться нові нерозмічені дані, їх поява може повністю змінити відповідь. Трансдуктивне навчання застосовується у деяких методах машинного навчання із частковим залученням вчителя (semi-supervised learning).

Навчання з учителем – це напрямок машинного навчання, що поєднує алгоритми та методи побудови моделей на основі множини об'єктів, що містять пари "відомий вхід – відомий вихід".

Алгоритм відноситься до навчання з учителем, якщо цей алгоритм базується не лише на векторі незалежних змінних (атрибутів, ознак), а й включає в себе значення, яке має видавати модель після навчання (таке значення називається цільовим) [47].

Різниця між цільовим і фактичним виходами моделі називається помилкою навчання, яка мінімізується в процесі навчання і виступає як "вчитель". Значення вихідної помилки використовується для обчислення корекцій параметрів моделі на кожній ітерації навчання.

В аналізі даних машинне навчання з учителем використовується у задачах класифікації та регресії. У першому випадку як цільова змінна використовується мітка класу, а в другому – зазвичай змінна числового типу.

В даний час розроблено велику кількість алгоритмів навчання з учителем, кожен з яких має свої сильні та слабкі сторони. Немає єдиного алгоритму, який найкраще підходить всім завданням аналізу [48].

До алгоритмів навчання з учителем для вирішення завдань класифікації відносяться: дерева рішень, машини опорних векторів, байєсівський класифікатор, лінійний дискримінантний аналіз, метод k-найближчих сусідів. Алгоритмами навчання з учителем для вирішення задачі регресії є лінійна регресія, логістична регресія, нейронні мережі [49].

Формальна загальна постановка задачі машинного навчання з учителем має наступний вигляд: нехай ϵ навчальна множина, що складається з N прикладів. Кожен навчальний приклад задається в наступному вигляді: $\{(x_1, y_1), \dots, (x_N, y_N)\}$, де x_i - вектор вхідних ознак i -го прикладу, а y_i – цільове значення i -го прикладу.

Тоді алгоритм навчання шукає функцію $g : X \rightarrow Y$, де X – простір входів моделі, Y – простір виходів. Функція g є елементом простору функцій G , який називають простором гіпотез.

Функцію g зручно представляти у вигляді іншої функції $f: X \times Y \rightarrow R$, такої, що g визначається як значення y , що повертається, яке забезпечує рівність $g(x) = \operatorname{argmax}_y f(x, y)$, де $f \in F$.

Хоча G і F можуть бути будь-якими просторами функцій, багато алгоритмів навчання є ймовірнісними, де g має вигляд умовної ймовірності $g(x) = P(y|x)$ або f набуває вигляду сумісної ймовірнісної моделі $f(x, y) = P(x, y)$. Наприклад, простий класифікатор Байеса та лінійний дискримінантний аналіз є моделями сумісної ймовірності, а логістична регресія – умовної ймовірності [50].

Існує два основних підходи до вибору функцій g і f : мінімізація емпіричного ризику та мінімізація структурного ризику. Мінімізація емпіричного ризику шукає функцію, яка найкраще відповідає навчальним даним. Мінімізація структурного ризику включає функцію штрафу, яка шукає компроміс між зміщенням і дисперсією.

В обох випадках передбачається, що навчальна множина складається з незалежних і однаково розподілених пар (x_i, y_i) . З метою перевірити наскільки добре функція відповідає навчальним даним, визначається функція втрат: $L(y_i, \hat{y})$, де \hat{y} – значення, спрогнозоване моделлю для прикладу (x_i, y_i) . Ризик $R(g)$ визначається як втрати g , які на даних можуть бути оцінені як $R(g) = \frac{1}{N} \sum_{i=1}^N L(y_i, g(x_i))$ [51].

Альтернативною технікою є навчання без вчителя. Навчання без вчителя – технологія машинного навчання, в якій для корекції параметрів моделі не використовується цільова функція. Іншими словами, у навчальних прикладах під час навчання без вчителя не потрібно мати заздалегідь задані виходи моделі.

У алгоритмах навчання без вчителя вихідна помилка моделі на навчальній множині не обчислюється. Замість неї використовується інформація про поточний стан параметрів моделі та прикладів навчальної множини. Наприклад, це може бути Евклідова відстань між вектором ознак входу і вектором ваг нейрона, яка керуватиме корекцією параметрів моделі в ході навчання.

Основне застосування навчання без вчителя – побудова моделей для кластеризації. Оскільки кластерна структура даних заздалегідь невідома, а визначається процесі навчання моделі, використовувати будь-які цільові значення неможливо [52].

Альтернативною технологією є навчання з учителем, коли для кожного навчального прикладу має бути задане цільове значення та обчислено вихідну помилку, від величини та знаку якої обчислюватимуться корекції параметрів моделі [53].

Навчання з частковим залученням учителя – це широка категорія методів машинного навчання, які використовують як помічені, так і немічені дані. Отже, як впливає з назви, це гібридна техніка між навчанням з учителем і навчанням без учителя.

Загалом, основна ідея навчання з частковим залученням учителя полягає в тому, щоб обробляти точку даних по-різному залежно від того, має вона мітку чи ні: для мічених точок алгоритм використовуватиме традиційний навчання з учителем для оновлення ваг моделі; а для немічених точок алгоритм мінімізує різницю в прогнозах між іншими подібними навчальними прикладами, тобто використовує навчання без учителя.

За наявності двох ідентичних наборів даних навчання з учителем з повністю міченим набором даних у результаті дасть набагато кращу модель, ніж набір із частиною немічених точок. Однак на практиці часто зустрічаються масиви даних, коли значна частина даних є неміченою, саме у цьому випадку навчання з частковим залученням учителя є дуже ефективним. У цьому випадку модель отримує доступ до немічених даних, не витрачаючи час і гроші на помічення тисяч і тисяч додаткових точок даних [54-55].

Навчання з підкріпленням (reinforcement learning) – спосіб машинного навчання, при якому система навчається, взаємодіючи з деяким середовищем. У навчанні з підкріпленням існує агент, який взаємодіє з навколишнім середовищем, роблячи певні дії, за які він отримує винагороду та продовжує дану взаємодію [56].

Алгоритми з частковим навчанням намагаються знайти стратегію, яка приписує станам навколишнього середовища дії, які може обирати агент у цих станах.

Середовище зазвичай формулюється як марківський процес прийняття рішень (МППР) з детермінованою множиною станів, що вказує на тісний зв'язок з динамічним програмуванням. Імовірності виграшів та переходу станів у МППР зазвичай є величинами випадковими, але стаціонарними у межах завдання [57].

При навчанні з підкріпленням, пари "вхід-вихід", які очікуються як правильний результат, не надаються моделі при її створенні, а прийняття рішень, які дають локальний екстремум, не обмежується учителем.

Базова модель навчання з підкріпленням складається з певної множини станів оточення S ; множини дій A ; множини скалярних "виграшів" R . У довільний час t агент характеризується станом $s_t \in S$ і множиною можливих дій $A(s_t)$. Вибираючи дію $a \in A(s_t)$, він переходить у стан s_{t+1} і отримує виграш r_t .

Ґрунтуючись на такій взаємодії з навколишнім середовищем, агент, що навчається з підкріпленням, має створити таку стратегію $\pi : S \rightarrow A$, яка максимізує

величину $R = r_0 + r_1 + \dots + r_n$ у разі МППР, що має термінальний стан, або величину $R = \sum_t \gamma^t r_t$ для МППР без термінальних станів, де γ – дисконтуючий множник для "потенційного виграшу" [58-59].

Таким чином, навчання з підкріпленням є доцільним підходом для вирішення завдань, пов'язаних із вибором між довгостроковою та короткостроковою вигодою.

Ще одним з підвидів машинного навчання є ансамблеві методи. В ансамблевих методах використовується ідея комбінування декількох слабкіших прогнозних алгоритмів для отримання якісних прогнозів, ніж кожен з алгоритмів може дати сам по собі.

Це дуже потужний клас і тому він дуже популярний. Наприклад, алгоритм випадкового лісу – це спосіб ансамблю, що пов'язує безліч дерев рішень, навчених із різними наборами даних. Підсумки якості моніторингом випадкового лісу кращі, ніж якість моніторингів одного дерева рішень.

Методи ансамблю – це спосіб зменшити дисперсію і систематичну помилку однієї моделі машинного навчання. Одна модель може бути точною за певно заданих умов, але неточною за інших умов. З іншого моделлю відносна точність може бути зворотною. Поєднуючи дві моделі, якість прогнозів балансується [60-61].

2.2. Глибинне навчання як сучасний метод аналізу даних

Глибинне навчання (deep learning) – це форма машинного навчання, яка включає добування або моделювання атрибутів певного масиву даних за допомогою впорядкованих шарів, що обробляють вхідну інформацію. Оскільки глибинне навчання є загальним методом моделювання, воно здатне вирішувати багато складних проблем, таких як комп'ютерний зір, обробка природної мови або прогнозування показників, що залежать від багатьох ознак різних типів. Цей підхід

дуже відрізняється від традиційного програмування та інших методів машинного навчання.

Визначальною особливістю глибинного навчання є те, що між входом і виходом моделі існує більше одного шару. Як правило, глибинне навчання відноситься до використання глибинних нейронних мереж, але існує багато інших алгоритмів, які реалізують глибинне навчання в моделях.

У глибинному навчанні кожен шар вчиться перетворювати свої вхідні дані. Важливо, що процес глибинного навчання може самостійно дізнатися, які функції оптимально розмістити на якому рівні. Це не позбавляє від необхідності ручного налаштування; наприклад, різна кількість шарів і розміри шарів можуть забезпечити різний ступінь абстракції.

Слово "глибинний" у "глибинному навчанні" означає кількість шарів, через які дані проходять під час свого перетворення. Точніше, системи глибокого навчання мають значну глибину розподілу кредитів (САР). САР – це ланцюг перетворень від входу до виходу.

САР описують потенційно причинно-наслідкові зв'язки між входом і виходом. Для прямої нейронної мережі глибина САР дорівнює глибині мережі та є кількістю прихованих шарів плюс один (оскільки вихідний рівень також параметризований). Для рекурентних нейронних мереж, в яких сигнал може поширюватися через шар більше одного разу, глибина САР потенційно необмежена [62].

Немає універсально узгодженого порогу глибини, який розділяє поверхнєве навчання від глибокого, але більшість дослідників погоджуються, що глибинне навчання передбачає глибину САР більше 2. САР з глибиною 2 є універсальним апроксиматором, тому що він може обробити вхідні дані, характер яких описуються будь-якими функціями, при цьому дуже згладжуючи результати, що може дати некоректну відповідь на виході [63].

Алгоритми глибинного навчання можна застосовувати до завдань навчання без учителя. Це важлива перевага, оскільки частка немічених даних у загальних масивах даних частіше є більшою, ніж частка мічених даних. Прикладами глибинних структур, які можна тренувати без учителя, є мережі глибинних переконань (deep belief networks – DBN) [64-65].

У машинному навчанні мережа глибоких переконань (DBN) – це генеративна графічна модель або клас глибинної нейронної мережі, що складається з кількох шарів прихованих змінних із зв'язками між шарами, але не між одиницями всередині кожного шару [66-67].

Деякі джерела вказують на те, що вперше розробив і дослідив усі основні компоненти сучасних систем глибокого навчання Френк Розенблатт. Він описав це у своїй книзі "Принципи нейродинаміки: перцептрони та теорія механізмів мозку", опублікованій Корнельським університетом у 1962 році [68].

Перший загальний, робочий алгоритм навчання для керованих, глибинних, прямих, багат шарових перцептронів був опублікований О. Івахненком і В.Лапою в 1967 році [69]. У статті 1971 року описується глибинна мережа з восьми рівнів, яка навчена груповим методом обробки даних [70].

Термін Deep Learning у контексті машинного навчання був вперше представлений спільноті Р. Дехтером у 1986 році [71], а в контексті штучних нейронних мереж І. Айзенбергом та його колегами у 2000 році у вигляді булевих порогових нейронів [72].

У 1989 році Ян Лекюн застосував стандартний алгоритм зворотного поширення, до глибинного нейронної мережі з метою розпізнавання рукописних поштових індексів у пошті. Робота алгоритму займала близько 3 днів [73].

У 1994 році Андре де Карвальо разом з Майком Фейрхерстом і Девідом Біссетом опублікували експериментальні результати багат шарової булевої нейронної мережі, також відомої як невагома нейронна мережа, що складається з 3-

рівневого модуля нейронної мережі, що самоорганізується, для виділення ознак, а потім модуль багаторівневої класифікації нейронної мережі, які були незалежно навчені. Кожен шар у модулі вилучення ознак видобував об'єкти зі зростаючою складністю щодо попереднього рівня [74].

Багато задач розпізнавання мови та образів було розв'язано за допомогою одного з методів глибинного навчання, що називається довгою короткочасною пам'яттю (LSTM), яка являє собою рекурентну нейронну мережу. Перші роботи по даному методу були опубліковані Хохрайтером і Шмідхубером у 1997 році [75]. LSTM уникають проблеми зникнення градієнта та можуть вивчати завдання "дуже глибокого навчання", які вимагають спогадів про події, які відбулися у часі набагато раніше, що важливо для розпізнавання мови та образів [76].

У 2003 році LSTM почав конкурувати з традиційними розпізнавачами мови в певних завданнях. Пізніше її об'єднали з коннекціоністською часовою класифікацією (CTC) у стеках LSTM [77].

Одним з найбільш популярних методів глибинного навчання є глибинні нейронні мережі (DNN). Глибинна нейронна мережа – це штучна нейронна мережа (INS) з кількома шарами між вхідним і вихідним шарами [78]. DNN містить коректний метод перетворення, щоб перетворити вхідні дані у вихідні, незалежно від наявності лінійної або нелінійної кореляції.

Мережа проходить по шарам, розраховуючи ймовірність кожного виходу. Користувач може переглядати результати та вибирати ймовірності, які мають відображати набір (наприклад, вище визначеного порога), і повертати в набір запропоновану мітку, помітивши таким чином дані. Кожне математичне перетворення вважається шаром, а складні DNN мають багато шарів, звідки і береться назва "глибинні" мережі.

DNN можуть моделювати складні нелінійні відношення. Архітектури DNN генерують композиційні моделі, в яких об'єкт виражається у вигляді багаторівневої

композиції примітивів. Додаткові рівні дозволяють залишати елементи з більш низьких рівнів, потенційно моделюючи складні дані з меншою кількістю одиниць, ніж набір з аналогічними показниками [79].

Глибинна архітектура включає в себе безліч варіантів кількох основних підходів. Кожна архітектура має найвищу ефективність в різних напрямках. Не завжди можна порівняти продуктивність кількох архітектур, якщо вони не були оцінені на одних і тих же наборах даних.

DNN, як правило, представляють собою мережі з прямим зв'язком, в яких дані передаються від вхідного рівня до вихідного рівня без зворотного зв'язку. Спочатку DNN створює карту віртуальних нейронів і призначає випадкові числові значення або "ваги" з'єднанням між ними. Ваги і вхідні дані множаться і повертають вихідний сигнал у межах від 0 до 1. Якщо встановити неточно розпізнаний конкретний шаблон, алгоритм скоригує вагові коефіцієнти до таких значень, за яких визначені коефіцієнти правильно оброблятимуть дані.

Глибинне навчання досягло значного поширення і в дослідженні економічних процесів. Одним з напрямів використання глибинного навчання є моделювання процесів на фондових ринках. З економічної точки зору вартість фондового ринку та його розвиток є важливими для розвитку бізнесу.

У поточній економічній ситуації в усьому світі є багато інвесторів, які зацікавлені у роботі на фондовому ринку, щоб отримати швидкий і відносно великий прибуток порівняно з іншими секторами. Наявність невизначеності та ризику в прогнозуванні цін на акції ставить перед дослідником проблеми щодо розробки ринкової моделі для прогнозування.

Незважаючи на всі успіхи в розробці математичних моделей для прогнозування, вони все ще не настільки успішні. Тема глибинного навчання приваблює науковців і практиків, оскільки вона може стати ключовим елементом

для отримання вищого рівня доходів, одночасно підвищуючи точність прогнозування за допомогою методів глибинного навчання [80].

Іншим застосуванням методів глибинного навчання є страховий сектор. Одним із завдань страхових компаній є ефективне управління виявленням шахрайства. В останні роки методи машинного навчання широко використовувалися для розробки практичних алгоритмів у цій галузі через високий ринковий попит на нові підходи порівняно з традиційними методами для практичного вимірювання всіх типів ризиків. Наприклад, існує багато вимог до страхування автомобілів, що змушує компанії знаходити нові стратегії, щоб покращити та оновити свою систему.

Механізм аукціону та тендерів має велике значення у економічних системах сьогодення, оскільки дозволяє підприємствам надавати кращі послуги своїм клієнтам, які отримують їх за нижчу ціну. Величезним завданням для проведення надійного аукціону є те, що його учасники потребують оптимальної стратегії для максимізації прибутку. У цьому напрямку Маєрсон розробив оптимальний аукціон з одним предметом. Є багато робіт з результатами для окремих учасників торгів, але найчастіше досягаються результати з частковою оптимальністю [81-83]. Методи глибинного навчання можуть дати змогу підвищити результати ефективності для всіх учасників аукціону чи тендера у моделях.

Таким чином, можна зазначити, що методи глибинного навчання уже частково використовуються для прогнозування вартості цінних паперів на фондових ринках, для оцінки курсу валют тощо. У зв'язку з сталим розвитком ринку криптовалют у світі проблема прогнозування курсу криптовалют стає все більш актуальним, тому використання методів глибинного навчання може дати змогу трейдерам підвищити якість прогнозування вартості криптовалют та підвищити рівень свого прибутку.

Програми глибинного навчання можна писати будь-якою сучасною мовою програмування. Однак існує уже велика кількість готових фреймворків, які набагато ефективніше використовувати, адже вони фокусуються саме на методах

глибинного навчання, використовуючи акселератори роботи. Це зумовлює значно вищу ефективність роботи таких фреймворків порівняно з вручну написаними програмами особливо тому, що вони оптимізовані для використання з графічним процесором та іншими прискорювачами. Найвідомішим фреймворком є TensorFlow від компанії Google, а найефективнішим API високого рівня TensorFlow є Keras, який можна використовувати з іншими фреймворками на стороні сервера.

Keras з'явився як зручне розширення над Theano, який також є фреймворком для глибинного навчання. Зараз це бібліотека нейронної мережі з відкритим кодом, написана мовою програмування Python. Він націлений на оперативну роботу мереж глибокого навчання та розроблений як компактний, модульний і розширюваний. Також є можливість використовувати Keras в рамках пакету TensorFlow.js, де основний функціонал написаний на мові JS. У цьому пакеті алгоритми використовують двигун V8 платформи Node.js, який потребує значно менше ресурсів (електроенергії та можливостей процесора та відеокарти порівняно з фреймворком на Python).

Keras створили інженери Google, і Google планувала підтримувати Keras в основній бібліотеці TensorFlow, але Франсуа Шольє, головний розробник бібліотеки, виділив Keras в окреме доповнення. Keras являє собою зручну надбудову над фреймворком TensorFlow, тобто фактично є інтерфейсом для високого рівня user experience користувачів.

Основною причиною для використання глибинного навчання для прогнозування вартості криптовалют полягає в тому, що ринок криптовалют є дуже нестабільним, адже ціни змінюються кожної секунди. Через це класичні методи статистичного аналізу не зможуть адаптуватися до мінливих ринкових умов, і буде великий часовий лаг між отриманням вхідних сигналів про зміни показників і відправкою вихідних сигналів з прогнозами.

Алгоритми глибинного навчання стійкі до шуму в даних, що дозволяє витрачати менше ресурсів на підготовку даних і зменшити вплив відсутніх або нелогічних даних на кінцевий результат виходу моделі. Глибинні нейронні мережі не роблять строгих припущень щодо функції відображення, тому легко вивчити лінійні та нелінійні зв'язки між функціями.

РОЗДІЛ 3. ПРАКТИЧНЕ ЗАСТОСУВАННЯ МЕТОДІВ DEEP LEARNING ПРИ ПРОГНОЗУВАННІ КУРСУ КРИПТОВАЛЮТ

Для прогнозування курсу криптовалют буде використовуватися метод глибинних нейронних мереж (DNN), оскільки даний метод дає змогу постійно перенавчатися і за допомогою цього досягати сталого покращення продуктивності роботи алгоритму та точності отриманих результатів.

Основним інструментом, що буде використовуватися для створення та навчання моделі, яка буде займатися прогнозуванням курсу криптовалют, буде Keras – відкрита бібліотека, що написана на мові програмування Python. Ця бібліотека є фактично зручним засобом для взаємодії з алгоритмами штучних нейронних мереж.

До 2019 року Keras підтримував майже всі великі нейромережеві бібліотеки: Theano, TensorFlow, Deeplearning4j, Microsoft Cognitive Toolkit тощо. Однак через складність підтримки синхронізації Keras з кожною бібліотекою на даний момент Keras можна використовувати лише з TensorFlow.

Keras є високорівневим, інтуїтивним набором абстракцій, що робить формування нейронних мереж простим незалежно від обраних алгоритмів, оскільки навчання та створення нейронних мереж відбувається всередині "чорного ящика", яким можна назвати Keras.

Для навчання глибинної нейронної мережі буде використано дані по 10 найбільш капіталізованих криптовалютах за період з 2015 року по кінець 2022 року. Даний датасет буде мати наступні поля:

- date: дата спостереження за вартістю криптовалюти;
- price: ціна криптовалюти у певний момент часу;
- total_volume: кількість транзакцій на день;
- market_cap: капіталізація криптовалюти в доларах США.

На графіку наведено динаміку зміни щоденного курсу біткойна з 1 січня 2015 року по 31 грудня 2022 року.




Рис. 3.1. Щоденна динаміка зміни курсу біткойна

Джерело: [33]

Для моделювання вартості криптовалюти буде використано модель багатошарового перцептрону. Багатошаровий перцептрон (MLP) – це тип штучної нейронної мережі, яка складається з кількох шарів взаємопов’язаних нейронів, включаючи вхідний рівень, один або кілька прихованих шарів і вихідний рівень.

Багатошаровий перцептрон було обрано як основну модель через наступні ключові переваги:

- нелінійне моделювання: багатошаровий перцептрон може моделювати нелінійні зв’язки між входами та виходами, через що зникає проблема нормалізації та фільтрації даних для дослідження лише лінійних зв’язків;
- висока точність: багатошарові перцептрони можуть досягти високої точності в задачах класифікації та регресії, особливо при використанні великих наборів даних;

- гнучкість: багатошаровий перцептрон може обробляти широкий спектр типів вхідних даних і може вивчати як структуровані, так і неструктуровані дані;
- надійність: дані моделі є стійкими до перешкод і можуть обробляти відсутні або неповні дані;
- розпаралелювання: MLP можна навчати паралельно за допомогою сучасного обладнання, що може значно прискорити час навчання;
- самостійне вивчення взаємозв'язків: багатошарові перцептрони можуть автоматично досліджувати зв'язки між полями з вхідних даних, що зменшує потребу в розробці функцій для даної мети;
- узагальнення: MLP може робити узагальнення нових та невідомих даних, що робить їх корисними для прогнозування майбутніх результатів.

Загалом MLP мають кілька переваг перед іншими моделями машинного навчання, що робить їх популярним вибором для широкого спектру програм, включаючи розпізнавання зображень, обробку природної мови та фінансове прогнозування.

Для побудови перцептрону буде використано модель `Sequential` з бібліотеки `Keras`. Модель `Sequential` – це набір шарів, де можна зручно і легко додавати, видаляти або змінювати шари під час навчання мережі. Шари у цій моделі додаються послідовно, тому якщо для навчання є необхідність у паралельному додаванні шарів, то необхідно використовувати іншу модель нейронної мережі.

У послідовній моделі можна додавати шари, викликаючи метод `add()`. Шари додаються в порядку їх передачі у функції. Нижче наведено приклад створення простої послідовної моделі з трьома шарами:

1. Імпортуємо модель:

```
from keras.models import Sequential  
from keras.layers import Dense
```

2. Ініціалізуємо модель:

```
model = Sequential()
```

3. Додаємо перший та другий приховані шари з 32 та 64 нейронами відповідно функцією активації "relu":

```
# add the first hidden layer with 32 units and relu activation
model.add(Dense(32, input_shape=(784,), activation='relu'))
# add the second hidden layer with 64 units and relu activation
model.add(Dense(64, activation='relu'))
```

5. Додаємо вихідний шар з 10 нейронами та функцією активації "softmax":

```
# add the output layer with 10 units and softmax activation
model.add(Dense(10, activation='softmax'))
```

Sequential модель – це простий і простий у використанні спосіб побудови нейронних мереж, особливо при роботі з простими архітектурами, такими як нейронні мережі прямого зв'язку. Важливо зауважити, що послідовна модель обмежена одним входом і одним виходом і може не підходити для більш складних моделей, які вимагають кількох входів і виходів або мають спільні рівні.

Розробку моделі нейронної мережі буде проведено у текстовому редакторі Jupyter Notebook, який орієнтований на роботу саме з кодом на мові Python. Цей засіб є дуже зручним, оскільки він існує як веб-сервіс, а отже, процес розробки може бути доступний одразу на кількох пристроях.

Основою розробку буде бібліотека NumPy. NumPy (скорочення від Numerical Python) – це популярна бібліотека Python, яка широко використовується для чисельних обчислень і аналізу даних. Ось деякі з основних випадків використання NumPy:

- операції з N-вимірним масивом: NumPy надає потужні інструменти роботи з N-вимірними масивами, які дозволяє виконувати швидкі та ефективні операції з великими масивами даних. Це робить його важливим інструментом для наукових обчислень і аналізу даних;

- математичні операції: NumPy надає широкий спектр математичних функцій, які можна використовувати для базової арифметики, тригонометрії, логарифмів тощо. Ці функції оптимізовані для швидкості та ефективності, що робить їх ідеальними для великомасштабної обробки даних;
- лінійна алгебра: NumPy включає різноманітні функції лінійної алгебри, такі як множення матриць, обчислення власних векторів і розкладання сингулярного значення. Ці функції особливо корисні для програм машинного навчання та аналізу даних;
- перетворення Фур'є: NumPy містить функції для обчислення дискретного перетворення Фур'є (DFT), яке є основним інструментом для обробки сигналів і аналізу зображень;
- генерація випадкових чисел: NumPy надає функції для генерації випадкових чисел і випадкових масивів, які корисні для моделювання, тестування та інших процесів;

Загалом, NumPy є важливою бібліотекою для наукових обчислень та аналізу даних у Python, і вона широко використовується в таких сферах, як машинне навчання, наука про дані, фізика, інженерія та фінанси.

Підготуємо для навчання дані про криптовалюти, починаючи з 2015 року. Для тих криптовалют, що з'явилися після 1 січня 2015 року – беремо усі історичні показники щодо вартості. Загалом було взято дані про 50 криптовалют. У дослідженні буде проаналізовано результати ефективності 4 моделей для прогнозування криптовалют Bitcoin, Ethereum та Binance Coin.

Для підготовки та завантаження даних буде використано бібліотеку pandas. Pandas – популярна бібліотека Python для обробки та аналізу даних. Хоча ця бібліотека безпосередньо не використовується для створення нейронних мереж, вона може бути дуже корисною у підготовці даних для навчання нейронної мережі.

Нейронні мережі часто вимагають введення великих обсягів даних у певному форматі, що може зайняти багато часу та спричинити помилки. Pandas може спростити цей процес, надаючи інструменти для очищення, перетворення та маніпулювання даними. Наприклад, pandas можна використовувати для:

- завантаження даних з різних джерел, таких як CSV, Excel, бази даних SQL тощо;
- попередньої обробки даних шляхом видалення відсутніх значень, перетворення категоріальних змінних, масштабування числових змінних тощо;
- розділення даних на навчальні та тестові набори;
- комбінування та об'єднання кількох джерел даних.

Для оцінювання моделі буде використано середньоквадратичну похибку (RMSE) та середню абсолютну відсоткову похибку (MAPE).

Показник RMSE вимірює різницю між спрогнозованими та фактичними даними. RMSE являє собою квадратний корінь від частки квадрату суми різниць фактичних та спрогнозованих даних в певний момент часу до довжини набору даних.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (\hat{y}_t - y_t)^2}{n}}, \quad (3.1)$$

де \hat{y}_t – спрогнозована ціна в момент часу t , y_t – фактична ціна в момент часу t , n – довжина досліджуваного датасету.

Середня абсолютна похибка MAPE характеризує точність прогнозу та рахується за формулою:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{y}_t - y_t}{y_t} \right| \quad (3.2)$$

Чим меншими є дані показники, тим точнішою є модель.

Для створення більш ефективної моделі необхідно здійснити нормалізацію даних. Нормалізація робиться за формулою:

$$x_t^{norm} = \frac{x_t - x_{min}}{x_{max} - x_{min}}, \quad (3.3)$$

де x_t^{norm} – нормалізовані дані, x_{min} – мінімальне значення серед усіх вхідних даних x_t , x_{max} – максимальне значення серед усіх вхідних даних x_t .

Після створення моделі та отримання спрогнозованих значень необхідно зробити денормалізацію даних за формулою:

$$\hat{y}_t = y^{norm}(y_{max} + y_{min}) + y_{min}, \quad (3.4)$$

де \hat{y}_t – спрогнозовані дані після денормалізації, y_{max}, y_{min} – максимальне та мінімальне значення у датасеті y^{norm} .

Для навчання моделі поділимо датасет у відношення 80% до 20% на тренувальні та тестову вибірки.

Встановлюємо бібліотеку NumPy в операційну систему за допомогою команди *pip install numpy*.

Також встановлюємо Keras за допомогою команди *pip install keras*. Як зазначено вище, Keras – це бібліотека, що використовує фреймворк TensorFlow для зручної побудови нейронних мереж. Тому необхідно також встановити фреймворк TensorFlow за допомогою команди *pip install tensorflow*.

Встановлюємо бібліотеку pandas за допомогою команди *pip install pandas*. Завантажуємо датасет за допомогою команди `read_csv` з бібліотеки pandas:

```
dataset = pd.read_csv('all_crypto_by2022.csv', delimiter=',')
```

Ініціалізуємо модель нейронної мережі Sequential з бібліотеки Keras:

```
model = Sequential()
```

Додаємо шари до моделі нейронної мережі за допомогою функції *model.add(Dense(units, activation))*:

```
model.add(Dense(64, activation='relu'))
```

```
model.add(Dense(32, activation='relu'))
```

```
model.add(Dense(1, activation='sigmoid'))
```

Шар "Dense" представляє собою шар нейронної мережі, де кожен нейрон з'єднаний з кожним нейроном попереднього шару. Параметр `unit` визначає кількість нейронів у шарі, а параметр `activation` визначає функцію активації, яка буде використовуватися в шарі.

У даній моделі було додано 3 шари. Перший шар включає в себе 64 нейронів та функцію активації "relu", другий шар включає в себе 32 нейронів з функцією активації "relu", третій шар – 1 нейрон з функцією активації "sigmoid". Програмний код для створення та оцінювання даної моделі наведено в додатку А.

Після побудови даної моделі для біткойну отримані наступні значення оцінок за допомогою функцій `mean_squared_error` та `mean_absolute_percentage_error` з бібліотеки `sklearn.metrics`:

RMSD = 229,69

MAPE = 0,1

Використаємо ту ж саму модель для прогнозування значень криптовалюти ефіріум (ETH). Отримані результати оцінок:

RMSD = 367,04

MAPE = 0,28

Використаємо ту ж саму модель для прогнозування значень криптовалюти binance coin (BNB). Отримані результати оцінок:

RMSD = 241,74

MAPE = 0,19

Побудуємо LSTM модель на тих же наборах даних. Для цього використаємо шар LSTM та шар Dense з типом оптимізації 'adam'. Програмний код для створення та оцінювання даної моделі наведено в додатку Б. Отримані результати оцінки для біткойну:

RMSD = 99,19

$$\text{MAPE} = 0,014$$

Результати оцінки для ефіріуму:

$$\text{RMSD} = 20,76$$

$$\text{MAPE} = 0,009$$

Результати оцінки для binance coin:

$$\text{RMSD} = 0,75$$

$$\text{MAPE} = 0,008$$

Далі побудуємо модель RBF – мережа радіальних базисних функцій. Для цього використаємо різні пакети з бібліотеки sklearn. Програмний код для створення та оцінювання даної моделі наведено в додатку В.

Отримані результати оцінки для біткойну:

$$\text{RMSD} = 11,14$$

$$\text{MAPE} = 0,003$$

Отримані результати оцінки для ефіріуму:

$$\text{RMSD} = 0,0013$$

$$\text{MAPE} = 0,00046$$

Отримані результати оцінки для binance coin:

$$\text{RMSD} = 0,0024$$

$$\text{MAPE} = 0,00062$$

Також побудуємо модель BP – модель зворотного поширення помилки. Для цього знову використаємо різні пакети з бібліотеки sklearn. Програмний код для створення та оцінювання даної моделі наведено в додатку Г.

Отримані результати оцінки для біткойну:

$$\text{RMSD} = 329,76$$

$$\text{MAPE} = 0,085$$

Отримані результати оцінки для ефіріуму:

$$\text{RMSD} = 365,12$$

$$\text{MAPE} = 0,095$$

Отримані результати оцінки для binance coin:

$$\text{RMSD} = 324,50$$

$$\text{MAPE} = 0,083$$

Отримані результати показано у табл. 3.1.

Табл. 3.1. Результати оцінки моделей

Криптовалюта	Похибка	Базова модель	LSTM	RBF	BP
Біткойн	RMSD	229,69	99,19	11,14	329,76
	MAPE	0,1	0,014	0,003	0,085
Ефіріум	RMSD	367,04	20,76	0,0013	365,12
	MAPE	0,28	0,009	0,00046	0,095
Binance coin	RMSD	241,74	0,75	0,0024	324,50
	MAPE	0,19	0,008	0,00062	0,083

При прогнозуванні на наборах даних мережа RBF має найменші показники RMSD та MAPE для усіх трьох криптовалют. Таким чином, прогноз саме цієї моделі є найбільш точним.

Варто зазначити, що базова модель та модель BP дали дуже неточні результати, оцінюючи показники RMSD та MAPE. Таким чином, можна зробити висновок, що дані моделі не є ефективними для прогнозування таких динамічних часових рядів, як курс криптовалюти.

Модель LSTM дала досить непогані результати, а отже, може використовуватися для прогнозування на рівні з результатами моделі RBF для порівняння, оскільки при використанні однієї моделі можна отримати некоректні дані та не запідозрити, що результат не є адекватним.

На рис. 3.2. та 3.3. зображено результати оцінювання моделей за допомогою показників RMSD та MAPE. На рис. 3.4. зображено графік спрогнозованих даних курсу біткойну на 2023 рік за методом RBF.

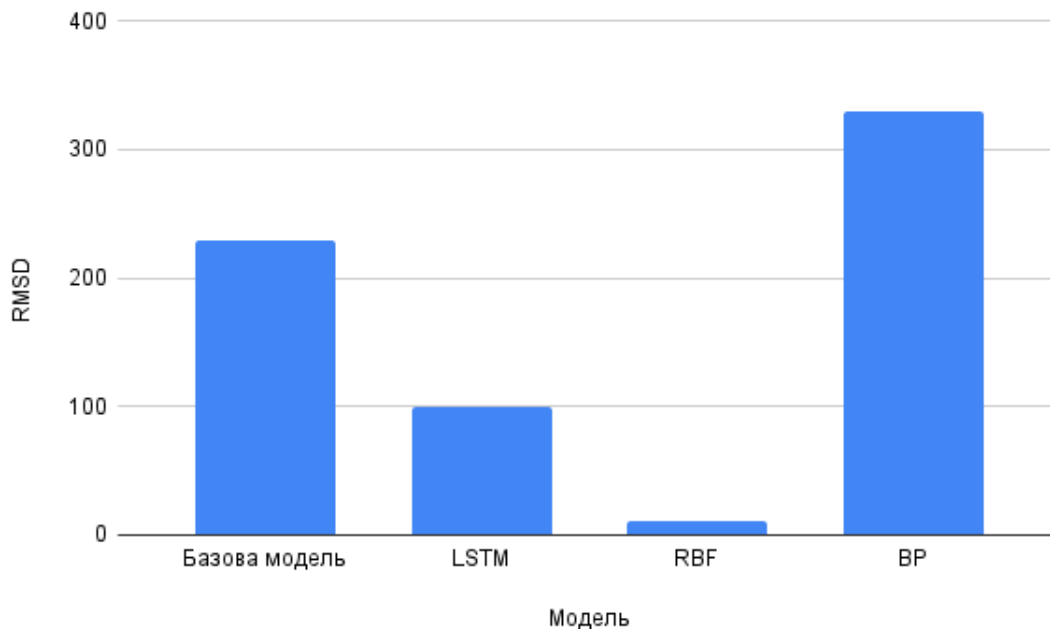


Рис. 3.2. Оцінка моделей за показником RMSD

Джерело: розроблено автором

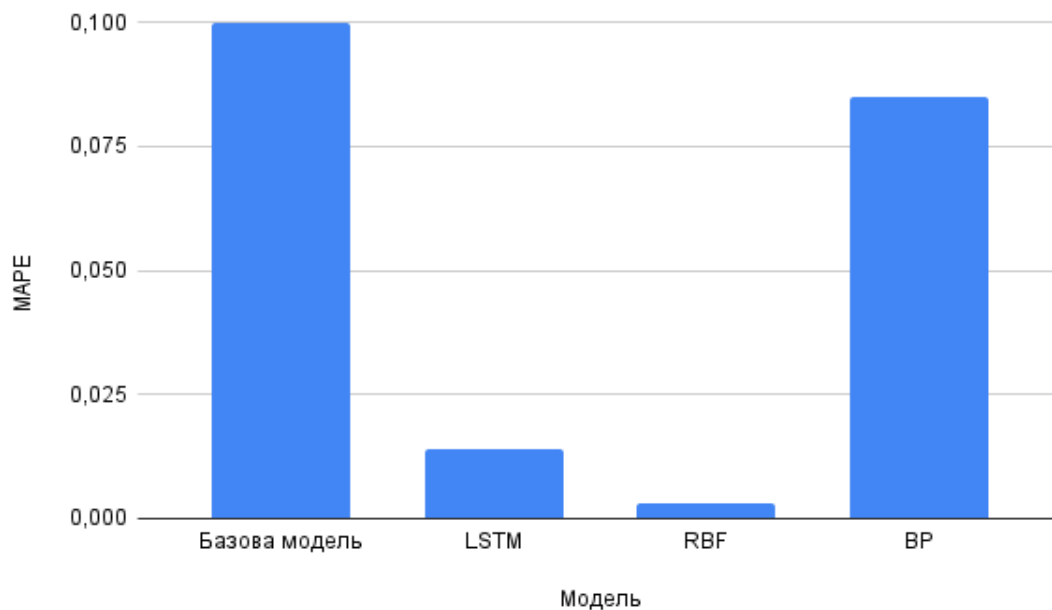


Рис. 3.3. Оцінка моделей за показником MAPE

Джерело: розроблено автором



Рис. 3.4. Прогноз курсу біткойну за методом RBF

Джерело: розроблено автором

На рис. 3.5 та 3.6 наведено прогноз курсу ефіріуму та binance coin за методом RBF.



Рис. 3.5. Прогноз курсу ефіріуму за методом RBF

Джерело: розроблено автором



Рис. 3.6. Прогноз курсу binance coin за методом RBF

Джерело: розроблено автором

Проаналізувавши результати моделі, можна зробити висновок, що прогноз передбачає зростання кожної з проаналізованих криптовалют у травні-червні 2023 року, після чого до кінця року буде спостерігатися стрімке падіння курсу.

Порівнюючи спрогнозовані дані з історичними варто відмітити, що прогнозний курс відповідає загальному тренду зміни ціни на криптовалюту упродовж усієї історії.

Дані результати корелюють зі станом ринку навесні 2023 року, адже станом на квітень 2023 року курс криптовалют до долара має тенденцію до помірному зростання після кризи 2022 року, а також стрімкого розпродажу криптовалют після банкрутства кількох американських великих банків.

Оскільки світова фінансова система переживає досить складні часи через відсутність державного регулювання ринку криптовалют, фінансові махінації, що пов'язані з продажем криптовалют, скандали з найбільшими біржами на ринку, то можна передбачити, що флуктуації та нестабільність на ринку буде продовжуватися

і в 2023 році. Банкрутство банків, що є критично важливими у США знижує довіру інвесторів до криптовалют, а саме до її ліквідності у майбутньому.

Падінню ринку буде сприяти і світова криза, що пов'язана з російським вторгненням на територію України, нестабільністю зовнішніх відносин між Китаєм та США, що зумовлює сумніви інвесторів щодо вкладення коштів у будь-які активи, включно з криптовалютами.

Також одним із важливих чинників кризи на ринку криптовалют є і високі ціни на енергоносії, що зумовлює високу вартість електроенергії, а також проблеми з виробництвом відеокарт, що продовжується кілька років. Оскільки блокчейн є дуже енергозатратною системою, то вартість майнінгу значно зросла, через що криптоферми закриваються, адже винагорода за майнінг не покриває витрати на майнінг.

Усі ці фактори, на мою думку, можуть зумовити ще більше падіння ціни на криптовалюту у 2023 році, що і є спрогнозовано нейромережевими моделями.

Іншим сценарієм може бути стабілізація ринку криптовалют, що може бути забезпечена великими інвестиціями з боку крупних бірж або державним регулюванням ринку. Однак, зважаючи на стан ринку криптовалют на даний момент, державне регулювання ринку криптовалют не є на часі для влади більшості держав.

Також вплив державного регулювання може зумовити ще більше падіння ринку, оскільки однією з переваг криптовалют є те, що їх вартість регулюється повністю законом попиту та пропозиції. Тому інвестори можуть вийти з ринку, продавши усі активи, якщо з'явиться "невидима рука" держави, що буде впливати на стан ринку. Це може зумовити повний крах ринку.

Таким чином, аналізуючи прогноз створених моделей, можна зробити висновок, що потрібно постійно слідкувати за ринком, використовуючи дані моделі, що навчаються без учителя, аналізувати тенденції. Також варто

диверсифікувати портфель, оскільки згідно з прогнозами binance coin не очікує таке стрімке падіння, як ефіріум та біткойн. Отже, не варто купувати один вид криптовалют, незважаючи на дуже привабливі низькі ціни на біткойн та ефіріум.

Блокчейн-технології дуже добре себе зарекомендували, адже попри величезні флуктуації на ринку, дана система не дала жодного збою. Криза на ринку була зумовлена лише зовнішніми впливами на ринок, однак не внутрішніми.

ВИСНОВКИ

За останні два десятиліття світова фінансова система пережила немало збурень та флуктуацій, що призвело до світових фінансових криз. Через це довіра до фіатних грошей знижується, а все більш популярними стають криптовалюти, що представляють собою цифровий засіб платежів, що базується на принципах криптографії та математичних алгоритмах.

Криптовалюти мають безперечну перевагу у тому, що є децентралізованим платіжним засобом, а отже, для проведення платежів більше не потрібно залучати посередника у вигляді банку, який може заблокувати операцію, видалити її, відмінити тощо. Усі транзакції зберігаються на персональних пристроях усіх учасників даної системи, що робить фактично неможливим злам системи та крадіжку коштів.

Однак криптовалюти мають високу волатильність та низьку передбачуваність, а оскільки криптовалюти базуються фактично лише на довірі населення і не є підкріплені державою, дорогоцінними металами чи товарами, то питання прогнозування вартості криптовалют є дуже важливим, оскільки існує ризик втратити велику кількість коштів.

Сучасним методом моделювання ціни криптовалют, зокрема біткойна, є глибинні нейронні мережі. Нейронні мережі є дуже гнучким інструментом, що може самостійно навчатися на історичних даних, має дуже високу швидкість обробки даних та надання результату. За допомогою методу нейронних мереж на мові програмування Python було розроблено кілька моделей нейронних мереж, що базуються на методі мережі довгої короткострокової пам'яті (LSTM), на методі зворотного поширення помилки (BP), на методі радіальних базисних функцій (RBF) та базовій моделі нейронної мережі з кількома шарами.

Для дослідження було взято щоденні історичні дані ціни закриття криптовалют, починаючи з 1 січня 2015 до кінця 2022 року. Дана вибірка була

нормалізована та поділена на тестову та тренувальну вибірки у відношення 20% до 80%.

Найбільш ефективною моделлю згідно з оцінками RMSD та MAPE стала нейронна мережа, що була побудована на основі методу RBF. За даною моделлю було здійснено прогноз цін криптовалют біткойн, ефіріум та binance coin до кінця 2023 року.

Таким чином, для моделювання вартості ціни криптовалюти доцільно використовувати різні методи нейронних мереж та за допомогою оцінок відхилень фактичних та прогнозованих значень обирати найбільш ефективну для прогнозування значень для майбутнього.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Ликтян, Д. Т. (2005). Економічна інтеграція та глобалізація. Проблеми сучасності. Київ: КНЕУ.
2. Навчально науковий інститут бізнес-технологій "УАБС" Сумського державного університету. (2020). Проблеми та перспективи розвитку фінансово-кредитної системи України: матеріали V Всеукраїнської науково-практичної онлайн конференції (м. Суми, 19–20 листопада 2020 року). Суми, Україна: Сумський державний університет.
3. Поченчук, Г. М. (2017). Фінансові технології: розвиток і регулювання. Економіка і суспільство, (13), 1193-1200.
4. Волосович, С. В. (2017). Домінанти технологічних інновацій у фінансовій сфері. Економічний вісник університету, (33 (1)), 15-21.
5. Яцик, Т. В. (2019). Поняття крипто-активів у системі фінансового обліку. Молодий вчений. Економічні науки, (2 (66)), 295-298.
6. Алішов, Г. Н. (2016). Роль транснаціональних компаній у розвитку національної економіки України. Ефективна економіка, (4).
7. Вороніна, О. О. (2016). Світові тенденції розвитку криптовалют. Харківський національний університет міського господарства імені О. М. Бекетова
8. Поливка, Н. (рік невідомий). Криптовалюти і "різноманітні біткоіни". Юридична Газета online. URL: <http://jur-gazeta.com/publications/practice/informaciyne-pravo-telekomunikaciyi/kriptovalyuti-i-riznomanitni-bitkoini.html>
9. Українська, Л.О., & Мащенко, М.А. (2020). Інноваційні фінансові продукти як цифрові інструменти оптимізації обороту товарів і послуг. Ефективна економіка, 11. URL: http://www.economy.nayka.com.ua/pdf/11_2020/6.pdf
10. Шірінян, Л. В., Роганова, Г. О., & Шірінян, А. С. (2018). Вплив факторів на формування вартості біткойна. Проблеми економіки, (2), 116-126.

11. Лубенець, І. (2014). Огляд цифрових криптовалют. Блог експертів про фінанси. URL: http://www.prostoblog.com.ua/lichnye/byudzhhet/obzor_tsifrovyyh_kriptovalyut.
12. Ковбаса, В.А. (2017). Комплементарні валютні системи та криптовалюти: класифікація та аналіз доцільності використання. Інтелект XXI (Index Copernicus), (5), 17-22.
13. Мерінова, С.В., & Половенко, Л.П. (2021). Роль криптовалюти у цифровій економіці. Вісник ХДУ Серія Економічні науки, (42), 80-87.
14. Танклевська, Н.С., Петренко, В.С., & Карнаушенко, А.С. (2017). Економічна сутність та види криптовалюти у світі. Бізнес-навігатор, 4-2, 133-138
15. Шинкаренко, О.М., Рогова, Н.В., & Панівник, І.А. (2018). Особливості нормативного регулювання криптовалют: світовий досвід. Фінансовий простір, 3, 139-146.
16. Гонак, І.М. (2021). Теоретичне обґрунтування визначення криптовалюти як грошей. Інноваційна економіка, (5-6), 123-130. URL: <http://inneco.org/index.php/innecoua/article/view/830>
17. Яровий, К.О., Мартиненко, О.В., & Шнурко, А.М. (2022). Поняття криптовалюти та механізм її державного регулювання. Modern Economics, 35(2022), 10-15.
18. May, T.C. (1994). Crypto Anarchy and Virtual Communities. URL: <https://www.activism.net/cypherpunk/crypto-anarchy.html>
19. Nakamoto, S. (2008). Bitcoin: A Peer-to-Peer Electronic Cash System. Bitcoin.org. URL: <https://bitcoin.org/bitcoin.pdf>
20. Jakobsson, M., & Juels, A. (1999). Proofs of Work and Bread Pudding Protocols. In Secure Information Networks: Communications and Multimedia Security (pp. 258-272). Kluwer Academic Publishers.

21. Laurie, B., & Clayton, R. (2004, May). Proof-of-work proves not to work. Paper presented at the Workshop on the Economics of Information Security 2004.
22. Лелу, Л. (2019). Блокчейн від А до Я. Все про технологію десятиліття.
23. Dannen, C. (2017). Introducing Ethereum and Solidity. Brooklyn, New York, USA: Apress
24. Liu, Y., Zhang, L., & Zhao, Y. (2021). Deciphering Bitcoin Blockchain Data by Cohort Analysis, 7.
25. Аналіз хеш функції (2014). URL: <https://studfile.net/preview/5384017/page:3/>
26. Rouse, M. (2015, June 5). Asymmetric cryptography (public key cryptography). SearchSecurity. URL: <https://searchsecurity.techtarget.com/definition/asymmetric-cryptography>
27. Mougayar, W. (2016). The Business Blockchain: Promise, Practice, and Application of the Next Internet Technology. New York, USA: John Wiley & Sons Inc.
28. Tapscott, D., & Tapscott, A. (2016). Blockchain Revolution: How the Technology Behind Bitcoin is Changing Money, Business, and the World. New York, USA: Penguin Random House.
29. Zarrin, J., Wen, P. H., Babu-Saheer, L., & Zarrin, B. (2020). Blockchain for Decentralization of Internet: Prospects, Trends, and Challenges. URL: <https://arxiv.org/pdf/2011.01096.pdf>
30. Ali, S., Wang, G., White, B., & Leslie Cottrell, R. (2018). Blockchain-based Decentralized Data Storage and Access Framework for PingER, 6.
31. Grand View Research. (2023). Cryptocurrency Market Size, Share & Trend Analysis Report By Component, By Hardware, By Software, By Process (Mining, Transaction), By Type, By End-use, By Region, And Segment Forecasts, 2023 – 2030. URL: <https://www.grandviewresearch.com/industry-analysis/cryptocurrency-market-report#:~:text=The%20global%20cryptocurrency%20market%20was,USD%20800%20billion%20in%202022.>

32. Wood, J. (2022, December 8). 2022 – Crypto Markets: A Year in Review. CoinDesk. URL: <https://www.coindesk.com/markets/2022/12/08/2022-crypto-markets-a-year-in-review/>
33. Duggan, W. (2023, April 13). April 2023 Crypto Market Forecast. Forbes Advisor. URL: <https://www.forbes.com/advisor/investing/cryptocurrency/crypto-market-outlook-forecast/>
34. Закон України «Про віртуальні активи» № 2074-IX (2022). URL: <https://zakon.rada.gov.ua/laws/show/504/96-%D0%B2%D1%80#Text>
35. Криптовалюти: бухоблік і декларування (2021). URL: <https://buhplatforma.com.ua/article/9106-kriptovalyuti-pravoviy-status-oblk-deklaruvannya-2021>
36. Криптозима прийшла й до України (2022, June 16). Forbes. URL: <https://forbes.ua/inside/kriptozima-priyshla-y-do-ukraini-ukrainski-skorochuyut-vidatki-ta-donati-i-chekayut-na-bankrutstva-spekulyantiv-khto-postrazhdae-naybilshe-16062022-6616>
37. Samuel, A. L. (1988). Some studies in machine learning using the game of checkers. I. Computer Games I. Springer
38. Черняк О. І., & Захарченко П. В. (2014). Інтелектуальний аналіз даних [Intellectual data analysis]. Знання.
39. Poncelet, P., Teisseire, M., & Maseglia, F. (2008). Data mining patterns: New methods and applications. Information Science Reference
40. Kohavi, R. (1996). Scaling up the accuracy of naive-Bayes classifiers: A decision-tree hybrid. In Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (pp. 202-207). AAAI Press

41. Dhillon, I., Guan, Y., & Kulis, B. (2004). Kernel k-means, spectral clustering and normalized cuts. In Proceedings of the 10th International Conference on Knowledge Discovery and Data Mining.
42. Berry, M., & Browne, M. (2006). Lecture notes in data mining. World Scientific
43. Diday, E., & Simon, J. C. (1995). Clustering analysis. In Digital Pattern Recognition (pp. 47-94). Springer.
44. Sebastiani, F. (2002). Machine learning in automated text categorization. ACM Computing Surveys, 34(1), 1-47. URL: <http://nmis.isti.cnr.it/sebastiani/Publications/ACMCS02.pdf>
45. Vapnik, V. N. (1998). Statistical learning theory. Wiley
46. Goldberg, D. E. (1989). Genetic algorithms in search, optimization and machine learning. Addison-Wesley
47. Sebastiani, F. (2002). Machine learning in automated text categorization. ACM Computing Surveys, 34(1), 1-47.
48. Villa N. Support Vector Machine For Functional Data Classification / N. Villa, F. Rossi // European Symposium on Artificial Neural Networks, Bruges (Belgium), 2005. – P. 467-472.
49. Boser B.E. A training algorithm for optimal margin classifiers / B.E. Boser, I.M. Guyon, V.N. Vapnik // In D. Haussler, editor, 5th Annual ACM Workshop on COLT. – Pittsburgh, PA: ACM Press, 1992. – P. 144-152.
50. Ryszard S. Michalski, Jaime G. Carbonell, Tom M. Mitchell (1983), Machine Learning: An Artificial Intelligence Approach, Tioga Publishing Company, ISBN 0-935382-05-4
51. Hastie, T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. — 2nd ed. — Springer-Verlag, 2009. — 746 p. — ISBN 978-0-387-84857-0...

52. Hinton, G. (2012). "A Practical Guide to Training Restricted Boltzmann Machines" (PDF). *Neural Networks: Tricks of the Trade. Lecture Notes in Computer Science*. Vol. 7700. Springer. pp. 599–619.
53. Buhmann, J.; Kuhnel, H. (1992). "Unsupervised and supervised data clustering with competitive neural networks". [Proceedings 1992] *IJCNN International Joint Conference on Neural Networks*. Vol. 4. IEEE. pp. 796–801.
54. Roman, Victor (2019). "Unsupervised Machine Learning: Clustering Analysis". Medium.
55. Garbade, Dr Michael J. (2018). "Understanding K-means Clustering in Machine Learning". Medium.
56. Kaelbling, Leslie P.; Littman, Michael L.; Moore, Andrew W. (1996). "Reinforcement Learning: A Survey". *Journal of Artificial Intelligence Research*. 4: 237–285.
57. Van Otterlo, M.; Wiering, M. (2012). Reinforcement learning and markov decision processes. *Reinforcement Learning. Adaptation, Learning, and Optimization*. Vol. 12. pp. 3–42.
58. Russell, Stuart J.; Norvig, Peter (2010). *Artificial intelligence: a modern approach* (Third ed.). Upper Saddle River, New Jersey. pp. 830, 831
59. Lee, Daeyeol; Seo, Hyojung; Jung, Min Whan (2012). "Neural Basis of Reinforcement Learning and Decision Making". *Annual Review of Neuroscience*. 35 (1): 287–308.
60. Opitz, D.; Maclin, R. (1999). "Popular ensemble methods: An empirical study". *Journal of Artificial Intelligence Research*. 11: 169–198.
61. Rokach, L. (2010). "Ensemble-based classifiers". *Artificial Intelligence Review*. 33 (1–2): 1–39.
62. Schmidhuber, J. (2015). "Deep Learning in Neural Networks: An Overview". *Neural Networks*. 61: 85–117

63. Shigeki, S. (2019). Human Behavior and Another Kind in Consciousness: Emerging Research and Opportunities: Emerging Research and Opportunities. IGI Global.
64. Bengio, Y., Lamblin, P., Popovici, D., & Larochelle, H. (2007). Greedy layer-wise training of deep networks (PDF). *Advances in neural information processing systems*. pp. 153–160.
65. Bengio, Y., Courville, A., & Vincent, P. (2013). Representation Learning: A Review and New Perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798–1828.
66. Hinton, G.E. (2009). Deep belief networks. *Scholarpedia*, 4(5), 5947.
67. Hinton, G.E., Osindero, S., & Teh, Y.W. (2006). A fast learning algorithm for deep belief nets (PDF). *Neural Computation*, 18(7), 1527–1554
68. Tappert, C.C. (2019). Who Is the Father of Deep Learning?. In *2019 International Conference on Computational Science and Computational Intelligence (CSCI)* (pp. 343-348). IEEE.
69. Ivakhnenko, A.G., & Lapa, V.G. (1967). *Cybernetics and Forecasting Techniques*. American Elsevier Publishing Co
70. Ivakhnenko, A. (1971). Polynomial theory of complex systems (PDF). *IEEE Transactions on Systems, Man and Cybernetics*, SMC-1(4), 364–378.
71. Dechter, R. (1986). Learning while searching in constraint-satisfaction problems. University of California, Computer Science Department, Cognitive Systems Laboratory. Online
72. Aizenberg, I., Aizenberg, N.N., & Vandewalle, J.P.L. (2000). *Multi-Valued and Universal Binary Neurons: Theory, Learning and Applications*. Springer Science & Business Media

73. LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural Computation*, 1, 541–551.
74. De Carvalho, A. C. L. F., Fairhurst, M. C., & Bisset, D. (1994). An integrated Boolean neural network for pattern classification. *Pattern Recognition Letters*, 15(8), 807–813.
75. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
76. Graves, A., Eck, D., Beringer, N., & Schmidhuber, J. (2003). Biologically plausible speech recognition with LSTM neural nets [PDF]. In 1st Intl. Workshop on Biologically Inspired Approaches to Advanced Information Technology, Bio-ADIT 2004 (pp. 175–184). Lausanne, Switzerland
77. Graves, A., Fernández, S., & Gomez, F. (2006). Connectionist temporal classification: Labeling unsegmented sequence data with recurrent neural networks. *Proceedings of the International Conference on Machine Learning, ICML 2006*, 369–376
78. Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and Trends in Machine Learning*, 2(1), 1–127. URL: <https://doi.org/10.1561/22000000006>
79. Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117.
80. Patel, J., Shah, S., Thakkar, P., & Kotecha, K. (2015). Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert Systems with Applications*, 42, 259–268.
81. Manelli, A. M., & Vincent, D. R. (2006). Bundling as an optimal selling mechanism for a multiple-good monopolist. *Journal of Economic Theory*, 127, 1–35.
82. Pavlov, G. (2011). Optimal mechanism for selling two goods. *The B.E. Journal of Theoretical Economics*, 11, 122–144.

83. Cai, Y., Daskalakis, C., & Weinberg, S. M. (2012). An algorithmic characterization of multi-dimensional mechanisms. In *Proceedings of the Forty-Fourth Annual ACM Symposium on Theory of Computing* (pp. 459–478). Association for Computing Machinery.

ДОДАТКИ

Додаток А

```

import numpy as np
import tensorflow as tf
import pandas as pd
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Activation
from sklearn.model_selection import train_test_split
from datetime import datetime
from sklearn.preprocessing import StandardScaler
df = pd.read_csv("C:/bitcoin.csv")
df["date"] = df["date"].apply(lambda x: datetime.strptime(x,
"%m/%d/%Y").timestamp())
X = pd.concat([df["price"], df["date"]], axis=1)
X_train, X_test, y_train, y_test = train_test_split(X, df["price"], test_size=0.2,
random_state=42)
scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_test_scaled = scaler.transform(X_test)
model = Sequential()
model.add(Dense(64, activation='relu', input_shape=(X_train.shape[1],)))
model.add(Dropout(0.5))
model.add(Dense(32, activation='relu'))
model.add(Dropout(0.5))
model.add(Dense(1, activation='sigmoid'))
model.summary()
model.compile(loss='binary_crossentropy', optimizer='adam', metrics=['accuracy'])

```

```
history = model.fit(X_train_scaled, y_train, epochs=50, batch_size=32,
validation_split=0.2)
y_pred = model.predict(X_test)
rmsd = np.sqrt(mean_squared_error(y_test, y_pred))
mape = mean_absolute_percentage_error(y_test, y_pred)
print("RMSD: ", rmsd)
print("MAPE: ", mape)
```

Додаток Б

```
import numpy as np
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
from keras.models import Sequential
from keras.layers import LSTM, Dense
from sklearn.metrics import mean_squared_error
df = pd.read_csv('C:/bitcoin.csv')
scaler = MinMaxScaler(feature_range=(0, 1))
df['price'] = scaler.fit_transform(df['price'].values.reshape(-1, 1))
df['date'] = pd.to_datetime(df['date'])
df['date'] = (df['date'] - pd.Timestamp("1970-01-01")) // pd.Timedelta('1s')
train_size = int(len(df) * 0.8)
train = df[:train_size]
test = df[train_size:]
train_X = train[['date', 'price']].values.reshape((train.shape[0], 2, 1))
test_X = test[['date', 'price']].values.reshape((test.shape[0], 2, 1))
train_y = train['price'].values
test_y = test['price'].values
model = Sequential()
model.add(LSTM(units=50, input_shape=(2, 1)))
model.add(Dense(units=1))
model.compile(optimizer='adam', loss='mean_squared_error')
model.fit(train_X, train_y, epochs=100, batch_size=32)
predictions = model.predict(test_X)
predictions = scaler.inverse_transform(predictions)
test_y = scaler.inverse_transform(test_y.reshape(-1, 1))
```

```
rmsd = np.sqrt(mean_squared_error(test_y, predictions))  
mape = np.mean(np.abs((test_y - predictions) / test_y)) * 100  
print('RMSD:', rmsd)  
print('MAPE:', mape)
```

Додаток В

```
import pandas as pd
import numpy as np
import csv
from sklearn.preprocessing import MinMaxScaler
from sklearn.cluster import KMeans
from sklearn.metrics.pairwise import euclidean_distances
from sklearn.metrics import mean_squared_error
from sklearn.metrics import mean_absolute_percentage_error
from sklearn.linear_model import LinearRegression
from sklearn.pipeline import Pipeline
from sklearn.compose import TransformedTargetRegressor
from sklearn.neural_network import MLPRegressor
from sklearn.decomposition import PCA
from sklearn.svm import SVR
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import train_test_split
from sklearn.metrics import r2_score
df = pd.read_csv('C:/bitcoin.csv')
train_data, test_data = train_test_split(df, test_size=0.2, shuffle=False)
scaler = MinMaxScaler()
train_data_norm = scaler.fit_transform(train_data[['price']])
test_data_norm = scaler.transform(test_data[['price']])
rbf_pipeline = make_pipeline(RBFSampler(n_components=2000, gamma=0.1,
random_state=42), LinearRegression())
rbf_pipeline.fit(train_data_norm, train_data['price'])
y_pred = rbf_pipeline.predict(test_data_norm)
```

```
try:
    np.savetxt("my_array.csv", y_pred, delimiter=",")
except Exception as e:
    print("Error:", e)
rmsd = np.sqrt(mean_squared_error(test_data['price'], y_pred))
mape = mean_absolute_percentage_error(test_data['price'], y_pred) * 100
print('RMSD:', rmsd)
print('MAPE:', mape)
```

Додаток Г

```
import numpy as np
import pandas as pd
from sklearn.neural_network import MLPRegressor
from sklearn.metrics import mean_squared_error, mean_absolute_percentage_error
df = pd.read_csv('C:/bitcoin.csv')
df['date'] = pd.to_datetime(df['date']).astype(np.int64) // 10**9
train_size = int(len(df) * 0.7)
train_data, test_data = df[:train_size], df[train_size:]
X_train, y_train = train_data['date'].values.reshape(-1, 1), train_data['price'].values
X_test, y_test = test_data['date'].values.reshape(-1, 1), test_data['price'].values
model = MLPRegressor(hidden_layer_sizes=(10,), max_iter=1000)
model.fit(X_train, y_train)
y_pred = model.predict(X_test)
rmsd = np.sqrt(mean_squared_error(y_test, y_pred))
mape = mean_absolute_percentage_error(y_test, y_pred) * 100
print('RMSD:', rmsd)
print('MAPE:', mape)
```