

Київський національний університет імені Тараса Шевченка

Економічний факультет

Кафедра економічної кібернетики

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА


**МОДЕЛЮВАННЯ КУРСУ БІТКОІНА ЗА ДОПОМОГОЮ НЕЙРОННИХ
МЕРЕЖ, ЩО ВИКОРИСТОВУЮТЬ АЛГОРИТМИ ШТУЧНОГО
ІНТЕЛЕКТУ**

студента 2 курсу магістратури
спеціальності 051 «Економіка»
ОНП «Економічна кібернетика»
денної форми навчання
Репецького Євгенія Олеговича

Науковий керівник:

кандидат фізико-математичних наук, доцент
Кравець Тетяна Вікторівна

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

Студент 
(підпис)

Роботу допущено до захисту перед ЕК
рішенням кафедри економічної кібернетики
від 4 травня 2022 р., протокол № 13

Завідувач кафедри:

доктор економічних наук, професор
Ляшенко Олена Ігорівна

(підпис)

Київ – 2022

РЕФЕРАТ

Мета дослідження: порівняти прогностичні можливості досліджуваних нейронних мереж та визначити, який з алгоритмів з штучного інтелекту є найкращим для моделювання ціни відкриття Біткоіна.

Методи дослідження: аналіз та синтез, індукція та дедукція, комплексний та системний підхід, моделювання за допомогою алгоритмів штучного інтелекту.

Практична цінність полягає у можливості використання результатів при прийнятті інвестиційних рішень на ринку Біткоін.

Ключові слова: штучний інтелект; нейронна мережа; зворотне поширення помилки; радіальна базисна функція; нейронна система нечіткого виведення; машина екстремального навчання; короткострокова та довгострокова пам'ять; біткоін.

Магістерська робота містить 48 сторінок, 21 рисунок, 6 таблиць, додатки.

RESUME

The purpose of the study: to compare the predictive capabilities of the studied neural networks and determine which of the algorithms from artificial intelligence is the best for modeling the price of the discovery of bitcoin.

Research methods: analysis and synthesis, induction and deduction, complex and system approach, modeling with the help of artificial intelligence algorithms.

The practical value lies in the possibility of using the results when making investment decisions in the Bitcoin market.

Key words: artificial intelligence; neural network; back propagation; radial basis function; neural fuzzy inference system; extreme learning machine; long short term memory; bitcoin.

The bachelor's thesis contains 48 pages, 21 figures, 6 tables, appendices.

ЗМІСТ

ВСТУП	4
РОЗДІЛ 1 ПЛАТІЖНА СИСТЕМА БІТКОІН.....	6
1.1. Характеристика складових елементів платіжної системи Біткоін	6
1.2. Ланцюг блоків (блокчейн) як основа функціонування платіжної системи Біткоін.....	7
1.3. Аналіз основних теорій щодо перспектив розвитку Біткоіна.....	11
РОЗДІЛ 2 АЛГОРИТМИ ШТУЧНОГО ІНТЕЛЕКТУ	15
2.1. Характеристика та архітектура штучних нейронних мереж.....	15
2.2. Нейронні мережі з алгоритмом зворотного поширення помилки та мережі з радіальною базисною функцією активації	19
2.3. Машини екстремального навчання та нейронні системи нечіткого виведення	24
2.4. Нейронні мережі з коротко та довгостроковою пам'яттю	29
РОЗДІЛ 3 МОДЕЛЮВАННЯ КУРСУ БІТКОІНА З ВИКОРИСТАННЯМ АЛГОРИТМІВ ШТУЧНОГО ІНТЕЛЕКТУ	34
3.1. Попередня підготовка бази даних та визначення критеріїв оцінки результатів прогнозування.....	34
3.2. Моделювання курсу Біткоіна з використанням штучних нейронних мереж	38
ВИСНОВКИ.....	47
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	49
ДОДАТКИ.....	56

ВСТУП

У сучасному світі усе більших обертів набирають розвиток глобалізаційних процесів, поширення та інтеграція інформаційних і комп'ютерних технологій в усіх сферах життєдіяльності людини. Під впливом вищезазначених факторів з'являються альтернативи класичним фінансовим інститутам та інструментам, формам економічної взаємодії між суб'єктами економіки. Яскравим прикладом такого еволюційного процесу є поява криптовалюти – цифрового аналога фіатних коштів – та її найбільш популярної та поширеної грошової одиниці – Біткоіна. Безперервний рух грошових коштів в світовій економіці, що передбачає необхідність перманентного моніторингу, на сьогоднішній день формує тенденції грошово-валютних систем на глобальному ринку.

Найбільш актуальною темою натеper є можливість прогнозування курсу криптовалют, адже це дає змогу відслідковувати тенденції розвитку даного сегменту валютних ринків. На сучасному етапі досліджень активно використовуються моделі штучних нейронних мереж. Серед вітчизняних науковців, що займалися даною тематикою, необхідно відзначити Т. В. Кравець, О. І. Ляшенко, Б. А. Камінського, В. В. Шпирко, С. А. Рибальченко, С. В. Науменкову, В. А. Делас. Вагомим внеском є праці таких зарубіжних вчених, як Хочрайтер, Фрасконі, Яо, Вонг, Женг, Ву та ін.

У даній роботі проведено порівняльний аналіз побудованих моделей нейронних мереж, що використовують алгоритми штучного інтелекту, з використанням мови програмування R та Python.

Об'єкт дослідження: ринок криптовалюти Біткоін.

Предмет дослідження: моделювання ціни Біткоіна за допомогою нейронних мереж, що використовують алгоритми штучного інтелекту.

Мета дослідження: порівняти прогностичні можливості досліджуваних нейронних мереж та визначити, який з алгоритмів з штучного інтелекту є найкращим для моделювання ціни відкриття Біткоіна.

Основні завдання:

- дослідження платіжної системи Біткоін та технології її функціонування

- аналіз статистичних даних
- дослідження архітектури штучних нейронних мереж та алгоритмів штучного інтелекту
- визначення найкращого алгоритму для моделювання ціни Біткоіна.

Інформаційною та аналітичною базою дослідження моделювання ціни Біткоіна за допомогою штучних нейронних мереж є наукові праці вітчизняних та зарубіжних вчених, а також Інтернет-ресурси.

Дипломна робота складається з вступу, першого розділу, у якому представлена загальна інформація про платіжну систему Біткоін, технологію її функціонування, а також аналіз теорій стосовно її подальшого напрямку розвитку. У другому розділі наведені теоретичні основи побудови нейронних мереж, що використовують різні алгоритми штучного інтелекту. У третьому розділі описані емпіричні результати моделювання та їх аналіз. Також дипломна робота містить висновки, перелік використаних джерел та додатки з програмними кодами на мові R і Python.

РОЗДІЛ 1 ПЛАТІЖНА СИСТЕМА БІТКОІН

1.1. Характеристика складових елементів платіжної системи Біткоїн

Біткоїн - це криптовалюта, яка є однойменною одиницею обліку операцій в піринговій платіжній системі. Його метою є бути схожим на фідуціарні гроші. Біткоїни по суті не мають цінності, їх вартість визначається тими, хто користується даною криптовалютою як платіжним засобом. Незважаючи на те, що він був створений ще у 2009 році як відповідь на світову фінансову кризу, Біткоїн нещодавно викликав величезну кількість інтересів у засобах масової інформації, і дав поштовх до появи криптовалют, що копіюють його (Litecoin, Gaelcoin та ін.). Він також викликав інтерес дослідників стосовно аспекту конфіденційності користувачів, через спроби отримати уявлення про його використання у транзакціях, а також через спроби краще зрозуміти наслідки імплементації Біткоїна як глобальної платіжної системи [31].

Біткоїн - це своєрідна цифрова валюта, в якій використовуються методи шифрування для контролю генерування одиниць грошової одиниці та для перевірки переказу коштів, що діють незалежно від центрального банку. Біткоїни виробляються користувачами, які «видобувають» їх шляхом надання обчислювальної потужності для перевірки транзакцій інших користувачів. Вони зберігаються в «цифровому гаманці», який існує або в хмарі, або на комп'ютері користувача. Гаманець - це свого роду віртуальний банківський рахунок, який дозволяє користувачам надсилати або отримувати Біткоїни, платити за товар або зберігати свої гроші. Основною відмінністю між фізичною валютою (наприклад, фунтом Великої Британії або доларом США) та Біткоїнами або між банківськими рахунками та цифровим гаманцем Біткоїнів є те, що фізична валюта та банківські рахунки застраховані схемою компенсації фінансових послуг (FSCS) у Великобританії або Федеральній корпорації страхування депозитів (FDIC) у Сполучених Штатах, тоді як Біткоїни і Біткоїн гаманці не є такими [25].

Фундаментальним для Біткоїна є відкритий обліковий запис, визнаний як ланцюг блоків. Цей ланцюг записує всі здійснені транзакції, а також кількість Біткоїнів, які знаходяться в окремих публічних адресах, кожен з яких має

відповідний секретний ключ. Власник приватного ключа має право передавати цифрові монети, які проводяться лише за вказаною адресою. Щоб витратити певну кількість Біткоїнів, користувачеві необхідно використовувати його або її приватний ключ для криптографічного підписання транзакції, відправлення Біткоїнів на іншу адресу. Це повідомлення або транзакція потім передається в мережу, і комп'ютери в мережі починають записувати, що дана адреса більше не має суми, яку було надіслано, але тепер вона зберігається на адресі прийому. Всі комп'ютери, які працюють над записом нових блоків у ланцюг, відомі як майнери [9].

1.2. Ланцюг блоків (блокчейн) як основа функціонування платіжної системи Біткоїн

Блокчейн - це технологія, що лежить в основі функціонування платіжної системи Біткоїн. Він є розповсюдженою, децентралізованою базою даних і призначений для досягнення послідовної та надійної згоди щодо здійснення транзакцій між незалежними учасниками мережі [11].

Блок транзакцій - спеціальна структура для запису груп транзакцій в систему Біткоїн. Транзакція вважається завершеною і достовірною, коли перевірені її формат і підписи, і коли сама транзакція об'єднана в групу з кількома іншими і записана в спеціальну структуру. Вміст блоків може бути перевірено, так як кожен блок містить інформацію про попередній блок. Усі блоки вибудовуються в один ланцюг, який містить інформацію про всі здійснені операції в базах. Перший блок в ланцюзі - первісний блок - розглядається як окремий випадок, так як у нього відсутній блок, що передує йому. Блок складається з заголовка і списку транзакцій. Заголовок блоку включає в себе свій хеш, хеш попереднього блока, хеші транзакцій і додаткову службову інформацію. В системі Біткоїн першою транзакцію в блоці завжди зазначається отримання комісії, яка стане нагородою за створений блок. Далі йде список транзакцій, що формуються з транзакцій, ще не записаних у попередні блоки. Критерій відбору з черги майнер задає самостійно. Наприклад, можуть бути

включені тільки операції з високою комісією або з учасниками заданих списків. Для транзакції в блоці використовується деревоподібне хешування [37].

Створений блок буде прийнятий іншими користувачами, якщо числове значення хешу заголовка дорівнює або менше певного цільового значення, величина якого періодично коригується. Якщо хеш не задовольняє умову, то в заголовку змінюється параметр «nonce» і хеш перераховується. Потрібно дуже багато таких розрахунків. Коли необхідний варіант знайдений, вузол розсилає отриманий блок іншим підключеним вузлам, які перевіряють блок. Якщо помилок немає, то блок вважається доданим в ланцюг і наступний блок має включати в себе його хеш (див. рис. 1.1).




Рис. 1.1. Схема даних ланцюга блоків мережі Біткоїн

Джерело: [37]

Величина цільового числа, з яким порівнюється хеш у системі Біткоїн коректується через кожні 2016 блоків. Уся мережа системи Біткоїн має витратити на створення одного блока приблизно 10 хвилин, на 2016 блоків – близько двох тижнів. Якщо 2016 блоків сформовані швидше, то складність обчислень зростає і навпаки. Зміна складності обчислень не впливає на надійність мережі Біткоїн і необхідна лише для того, щоб система створювала блоки з майже постійною швидкістю, що не залежить від обчислювальної потужності учасників мережі.

На рис. 1.2 продемонстровано процес формування ланцюга блоків. Основна послідовність (зображена чорним кольором) є найдовшою, починаючи від початкового блока (зображений зеленим кольором) до поточного. Побічні гілки (зображені фіолетовим кольором) відсікаються.

Таким чином, ланцюг блоків містить історію володіння криптовалютою, з якою можна ознайомитися. Блокчейн формується як неперервно зростаючий ланцюг з записами про всі транзакції. Копії бази або її частини одночасно зберігаються на багатьох комп'ютерах та синхронізуються відповідно до формальних правил побудови блоку ланцюгів. Інформація в блоках не зашифрована і доступна у відкритому вигляді, але відсутність змін засвідчується криптографічно через хеш-ланцюги.

База публічно зберігає у незашифрованому вигляді інформацію про усі транзакції, що підписані за допомогою асиметричного шифрування. Для запобігання багаторазовій витраті однієї і тієї ж суми використовуються позначки часу, реалізовані шляхом розбиття бази даних на ланцюг спеціальних блоків, кожен з яких, містить у собі хеш попереднього блока і свій порядковий номер. Кожен новий блок здійснює підтвердження транзакцій, інформацію про які містить і додаткове підтвердження транзакцій у всіх попередніх блоках ланцюга. Змінювати інформацію в блоці, який вже знаходиться в ланцюзі, непрактично так як у цьому разі довелось би редагувати інформацію у всіх наступних блоках. Завдяки цьому повторна витрата раніше витрачених коштів дуже малоймовірна. Найчастіше умисна зміна інформації в будь-якій з копій бази або навіть у досить великій кількості копій не буде визнана істинною, так як не буде відповідати правилам. Деякі зміни можуть бути прийняті, якщо будуть внесені у всі копії бази. Наприклад, видалення декількох останніх блоків через помилки у їх формуванні [37].

Доки транзакція не включена до блоку, система вважає, що кількість Біткоїнів на деякій адресі залишається незмінною. У той же час існує ймовірність оформити декілька різних транзакцій з перерахування з одної адреси одних і тих самих Біткоїнів різним отримувачам. Але як тільки одна з таких транзакцій буде

включена до блоку, інші транзакції з цими же Біткоїнами система буде вже ігнорувати. Наприклад, якщо до блоку включена більш пізня транзакція, то більш рання вважається помилковою. Існує мала ймовірність, що при розгалуженні дві подібні транзакції потраплять в блоки різних гілок. Кожна з них вважатиметься достовірною, лише при відхиленні гілки одна з транзакцій стане помилковою. При цьому час здійснення транзакції не матиме значення.

Таким чином, включення транзакції в блок є підтвердженням її достовірності незалежно від наявності інших транзакцій з цими же Біткоїнами. Кожен новий блок є додатковим підтвердженням транзакцій з попередніх блоків. Якщо у ланцюзі 3 блоки, то транзакції з останнього блока будуть підтверджені 1 раз, а з першого матимуть 3 підтвердження. Достатньо дочекатись декількох підтверджень, для того, щоб ймовірність відміни транзакції стала дуже малою. Для зменшення впливу подібних ситуацій на мережу існують обмеження на користування щойно отриманими Біткоїнами.

Можливість учасників системи блокчейн автономно забезпечувати надійність спільної бази даних, не покладаючись на довірену третю сторону, є однією з основних переваг використання цієї технології. Блокчейни мають на меті збільшити рівень надійності шляхом здійснення автономно перевірених дій в рамках системи кожним учасником, покращуючи підзвітність і перешкоджаючи неправомірним діям через можливість громадського аудиту. Іншими словами, правила, що регулюють блокчейн, можуть успішно ліквідувати типи несанкціонованих передач або обманних дій, які стали надто частими у багатьох сферах бізнесу та суспільства [25].

1.3. Аналіз основних теорій щодо перспектив розвитку Біткоїна

Майбутнє Біткоїна є дуже непередбачуваним. Існує велика множина можливих варіантів його подальшого розвитку. Натепер найбільш можливими та популярними є декілька теорій стосовно даної проблематики.

Попри те, що це здається майже неможливим, деякі дослідники притримуються думки, що Біткоїн має потенціал стати світовою валютою. Для цього він має виконувати функції засобу обміну, одиниці розрахунку та

нагромадження вартості. Першу з них криптовалюта частково виконує. Існує багато різноманітних послуг, які можна оплачувати Біткоїнами, проте така практика не є загально розповсюдженою. Біткоїн є засобом нагромадження у тому сенсі, що його можна продавати і зберігати для майбутнього використання. При цьому складним аспектом є досягнення стійкої вартості криптовалюти, так як її ціна базується переважно на взаємозв'язку попиту та пропозиції. З досить великою мірою точності можна розрахувати дисконтовану вартість 100 доларів США, зважаючи лише на поточний рівень інфляції. У той же час ціна Біткоїну є дуже мінливою [48].




Рис. 1.3. Щоденний курс Біткоіна

Джерело: розроблено автором

На рис. 1.3 зображено графік зміни курсу Біткоіна з моменту його появи. Як бачимо, Біткоін характеризується дуже високою волатильністю, що робить його надзвичайно вразливим до спекулятивних атак, також майже унеможливорює його використання як розрахункової одиниці для здійснення повсякденних грошових операцій.

Інша група науковців вважає, що Біткоїн стане доповненням до світового фінансового сектору як один з можливих способів здійснення транзакцій, співіснуючи з іншими світовими валютами. Якщо Біткоїн певною мірою може стати більш контрольованою і стабільною валютою, такий спосіб переказу

грошей на глобальному рівні має велику перспективу, адже не вимагає участі посередників. Гроші могли обмінюватися на Біткоїни, дешево надсилатися по всьому світу і обмінюватися на звичайну валюту, хоча для цього реципієнт повинен мати обліковий запис на платформі обміну, щоб продати Біткоїн і отримати гроші. Завдяки низькій комісії Біткоїн створює основу функціонування та популярності сегменту мікро-платежів. Серед інших позитивних рис даної криптовалюти – її глобальна доступність, можливість створення багатофункціональних рахунків, спрощення системи краудфандингу.

Прихильники останньої теорії наголошують на незворотному обвалі ринку криптовалюти, виходячи з того, що Біткоїн є масштабною схемою Понці. Схема Понці є шахрайською інвестиційною операцією, в якій оператор надає сфабриковані звіти та генерує прибутки для старих інвесторів за рахунок доходів, що сплачуються новими інвесторами, а не від законної діяльності або прибутку від фінансової торгівлі. Оператори схеми привертають увагу нових інвесторів, пропонуючи аномально високі короткострокові прибутки. Така система є нестабільною у довгостроковій перспективі, оскільки здатна працювати, доки до неї приєднується все більше учасників, створюючи нові грошові потоки. Падіння ж відбувається або у разі виведення лівової частки капіталу засновником системи, або у разі припинення надходження нових учасників [10].

Серед останніх робіт щодо перспектив розвитку та використання Біткоїна увагу заслуговує публікація Яна і Дас, присвячена дослідженню стійкості Біткоїнів для хеджування на китайських агрегованих і галузевих фондових ринках і збільшення прибутковості альткойнів після спалаху пандемії коронавірусу. Автори роблять висновок, що Біткоїн поступається золоту в аспекті хеджування та перспектив збереження цінності активу на китайському фондовому ринку [36].

Еом у своїй праці дослідив зв'язок між ціною на Біткоїн та об'ємом торгів. Автор підкреслює, що фундаментальна невизначеність, що характерна для

Біткоіна, породжує велику розбіжність в гетерогенних настроях серед інвесторів і призводить до високого об'єму торгівлі і появи спекулятивних бульбашок [19].

У роботі Агарвала, Чандрасекарана та Аннамалая використовується метод опорних векторів для визначення його прогностичних можливостей щодо цін на Біткоін. Як висновок, було встановлено, що метод опорних векторів дозволяє робити прогноз на п'ять періодів вперед для короткострокового, середньострокового, довгострокового та загального рівня цін на Біткоін [6].

Необхідно також відзначити публікацію Зенга, Янга та Шена. Автори дослідили кореляцію між Біткоїном та традиційними фінансовими активами з точки зору пов'язаності мереж цих активів. Відокремлення позитивної та негативної дохідності на ринку Біткоін доводить існування асиметричної моделі супутнього ефекту між Біткоїном та традиційними фінансовими активами [49].

Дуже актуальною на сьогоднішній день є праця Мусялковської, Клібер, Сверчинської та Маршалек. Метою роботи було визначити, який з активів: золото, нафта чи Біткоін є найбільш безпечним для інвесторів у Венесуелі, що знаходиться у кризисному стані. Автори також розглядають зміни в позиції влади щодо використання та майнінгу криптовалют. Результати дослідження показали, що Біткоін є доволі слабким (у розрізі збереження цінності) активом для інвесторів, проте він може виконувати (в певній мірі) функції грошей у країні, яка перебуває у кризисному стані [33].

РОЗДІЛ 2 АЛГОРИТМИ ШТУЧНОГО ІНТЕЛЕКТУ

2.1. Характеристика та архітектура штучних нейронних мереж

Штучна нейронна мережа – це відносно нова комп'ютерна система обробки інформації, що заснована на сучасних дослідженнях в галузі неврології і формується завдяки абстрагуванню, спрощенню та моделюванню біологічних структур. Особливості штучних нейронних мереж полягають в наступному. Вони можуть повністю апроксимувати будь-які складні нелінійні залежності. Уся кількісна або якісна інформація зберігається рівномірно у кожному нейроні мережі, тому вона є дуже стійкою. Штучна нейронна мережа є в певному розумінні системою, яка здатна емулювати та адаптовуватись до невідомої системи і може одночасно мати справу з кількісними та якісними даними. Основне завдання дослідження штучних нейронних мереж полягає в тому, щоб змусити комп'ютер моделювати та реалізовувати здатність людини до самонавчання та математичного мислення для виділення внутрішніх зв'язків з вибірок обмеженої довжини. Саме шляхом вивчення і збереження залежності даних, розподілу ймовірностей відомої вибірки можливо вивести та розкрити інформацію про потенційні залежності між змінними в невідомій вибірці даних [38].

Штучна нейронна мережа сама по собі не є алгоритмом, а радше фундаментом, базою для цілої низки алгоритмів машинного навчання. Такі системи навчаються виконувати різноманітні задачі, тренуючись на прикладах, без попереднього програмування будь-яких правил для конкретних задач. Наприклад, стосовно розпізнавання образів вони можуть визначати зображення, на яких є людина, аналізуючи зображення, які були попередньо промаркіровані відносно наявності на них людини. При цьому, штучні нейронні мережі виконують такі задачі за відсутності апіорних знань про вигляд людини. Натомість, вони автоматично генерують визначальні характеристики з тренувальної вибірки.




Рис. 2.1. Схема штучної нейронної мережі

Джерело: [2]

Штучна нейронна мережа складається з пов'язаних між собою елементів або вузлів, які називаються штучними нейронами. Саме вони поверхнево моделюють роботу нейронів біологічного мозку. На рисунку 2.1. зображена схема найпростішої штучної нейронної мережі з одним прихованим шаром. Залежно від розташування нейронів у топології мережі виділяють:

- вхідні нейрони, які отримують закодований вхідний сигнал у вигляді вектора (як правило, вони передають зважений отриманий сигнал на вихід без здійснення інших обчислювальних операцій)
- проміжні або приховані нейрони, які виконують основні обчислювальні операції
- вихідні нейрони, які є виходами мережі (у них можуть виконуватися необхідні обчислювальні операції).

Штучні нейрони є елементарними частинами нейронної мережі. Штучний нейрон має один або більше входів, що представляють збуджуючі

постсинаптичні потенціали і інгібіторні постсинаптичні потенціали в нервових дендритах, і підсумовує їх для отримання вихідного сигналу або активації, що представляє потенціал дії нейрона, який передається по його аксону. Зазвичай усі входні сигнали окремо зважуються, і сума передається через нелінійну функцію, що має назву функція активації або функція передачі [20].




Рис. 2.2. Схема штучного нейрона (1 – нейрони, вихідні сигнали яких надходять до даного нейрона; 2 – суматор входних даних; 3 – обчислювач функції активації; 4 – нейрони, на вхід яких подаються вихідні сигнали даного нейрона; ω_i – ваги входних значень)

Джерело: [2]

Тобто, штучний нейрон математично є ваговими суматором, вихідний сигнал якого визначається через входні сигнали і вагову матрицю наступним чином:

$$y = f(u), \text{ де } u = \sum_{i=1}^n \omega_i x_i + \omega_0 x_0.$$

Тут x_i і ω_i – входні сигнали та ваги входів відповідно, функція u називається індукованим локальним полем, $f(u)$ – функція активації. Додатковий входний сигнал x_0 та відповідна йому вага використовується для ініціалізації нейрона.

Під ініціалізацією мається на увазі зсув функції активації нейрона по горизонтальній осі, тобто формування порогу чутливості нейрона [38].

Функція активації або передавальна функція є відображенням множини сум зважених сигналів на входах нейрона у множину його можливих вихідних сигналів. У більшості випадків вона є монотонно зростаючою, має область значень $[-1;1]$ або $[0;1]$. Найбільш популярними функціями активації, що використовуються у штучних нейронних мережах є сигмоїди. Зазвичай під сигмоїдою розуміють логістичну функцію (див. рис. 2.3) виду:

$$\sigma(x) = \frac{1}{1 + e^{-x}}.$$




Рис. 2.3. Сигмоїда

Джерело: розроблено автором

До класу сигмоїдних кривих також відносять такі функції як арктангенс, гіперболічний тангенс та інші функції подібного вигляду.

Останнім часом усе більше використовується ReLU (rectified linear unit) функція, яка поступово витісняє логістичну функцію, адже виявилась більш практичною.

Найбільший інтерес до нейронних мереж викликає можливість їх навчання. Маючи особливу задачу для вирішення та клас функцій F , навчання означає пошук такого оптимального розв'язку $f^* \in F$, використовуючи обмежений набір

спостережень, при якому визначена заздалегідь функція витрат досягає свого мінімуму, тобто:

$$C(f^*) \leq C(f) \forall f \in F,$$

де $C(\cdot)$ - функція витрат.

У наступних підрозділах описано види штучних нейронних мереж та алгоритми їх тренування, що використовувалися при дослідженні.

2.2. Нейронні мережі з алгоритмом зворотного поширення помилки та мережі з радіальною базисною функцією активації

Нейронні мережі, що використовують алгоритм зворотного поширення помилки (ВР)

ВР-мережа на сьогоднішній день є однією з найбільш використовуваних та найбільш популярних моделей. Основна ідея алгоритму ВР полягає в тому, щоб розділити навчальний процес на два етапи: пряме поширення сигналу і зворотне поширення помилки. На етапі прямого поширення сигналу вхідна інформація поступає з вхідного шару на вихідний шар через прихований шар. Ваги мережі фіксуються в процесі прямої передачі сигналу. Стан нейронів кожного шару впливає тільки на стан нейронів наступного шару. Якщо бажане вихідне значення не досягається на виході, то сигнал помилки повернеться назад. На етапі зворотного розповсюдження сигнал помилки, який не відповідав вимозі точності, поширюється крок за кроком, і помилка поділяється на всі нейрони кожного шару. Ваги зв'язків коригуються динамічно відповідно до сигналу помилки. Значення ваг продовжує коригуватися через цикл прямого й зворотного регулювання [12].

Для розуміння алгоритму розглянемо найпростішу ВР мережу з одним прихованим шаром. Кількість вхідних нейронів дорівнює вимірності вхідного вектора. Кількість нейронів у вихідному шарі дорівнює типу вихідного значення. Кількість нейронів у прихованому шарі асоціюється з конкретною задачею, яка зазвичай обирається у ході проведення тестування. Найбільш розповсюдженим алгоритмом для знаходження ваг, що мінімізують похибку є метод градієнтного

спуску. При цьому метод зворотного поширення помилки використовується для пошуку найбільш крутого напрямку спуску.

Метод градієнтного спуску включає обчислення часткових похідних квадрату функції витрат по усіх вагах мережі. Квадрат функції похибки обчислюється як:

$$E = \frac{1}{2}(t - y)^2,$$

де t – цільове значення вихідного сигналу, y – отримане значення вихідного сигналу нейрона.

Для кожного нейрона j його вихідне значення обчислюється як

$$o_j = \varphi(net_j) = \varphi\left(\sum_{k=1}^n \omega_{kj} o_k\right)$$

Вхідний сигнал net_j є зваженою сумою вихідних сигналів o_k попередніх нейронів. Якщо нейрон знаходиться у першому прихованому шарі, o_k вхідного шару є просто вхідними даними x_k до мережі. Кількість вхідних нейронів дорівнює n . Змінна ω_{kj} визначає вагу зв'язку між нейроном k -им нейроном попереднього шару та j -им нейроном поточного шару. Функція активації φ є нелінійною та диференційовною. Як зазначалося раніше, найчастіше використовується логістична функція:

$$\varphi(z) = \frac{1}{1 + e^{-z}},$$

що має досить зручну похідну:

$$\frac{d\varphi(z)}{dz} = \varphi(z)(1 - \varphi(z)).$$

Обчислимо часткову похідну функції витрат по ω_{ij} таким чином:

$$\frac{\partial net_j}{\partial \omega_{ij}} = \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial net_j} \frac{\partial net_j}{\partial \omega_{ij}}.$$

Останній множник правої частини рівності в останньому виразі виражаємо як:

$$\frac{\partial net_j}{\partial \omega_{ij}} = \frac{\partial}{\partial \omega_{ij}} \left(\sum_{k=1}^n \omega_{kj} o_k \right) = \frac{\partial}{\partial \omega_{ij}} \omega_{ij} o_i = o_i.$$

Для нейрону першого прихованого шару $o_i = x_i$. Похідна вихідного сигналу j -го нейрона по його вхідному сигналу є частковою похідною функції активації:

$$\frac{\partial o_j}{\partial net_j} = \frac{\partial}{\partial net_j} \varphi(net_j) = \varphi(net_j) (1 - \varphi(net_j)).$$

Саме тому накладається умова необхідності того, щоб функція активації була диференційовною.

Множник $\frac{\partial E}{\partial o_j}$ легко визначити, якщо нейрон є складовою вихідного шару, оскільки в такому разі $o_j = y$, і:

$$\frac{\partial E}{\partial o_j} = \frac{\partial E}{\partial y} = \frac{\partial}{\partial y} \frac{1}{2} (t - y)^2 = y - t.$$

Однак, якщо j -ий нейрон знаходиться в довільному проміжному шарі мережі, обчислення похідної функції похибки E по o_j є більш складним. Позначимо множину нейронів, що отримують сигнал від j -го нейрона, $L = \{u, v, \dots, w\}$. Тоді:

$$\frac{\partial E(o_j)}{\partial o_j} = \frac{\partial E(net_u, net_v, \dots, net_w)}{\partial o_j},$$

обчисливши повну похідну виразу по o_j , отримуємо рекурентне співвідношення:

$$\frac{\partial E}{\partial o_j} = \sum_{l \in L} \left(\frac{\partial E}{\partial net_l} \frac{\partial net_l}{\partial o_j} \right) = \sum_{l \in L} \left(\frac{\partial E}{\partial o_l} \frac{\partial o_l}{\partial net_l} \frac{\partial net_l}{\partial o_j} \right) = \sum_{l \in L} \left(\frac{\partial E}{\partial o_l} \frac{\partial o_l}{\partial net_l} \omega_{lj} \right).$$

Таким чином, похідна по o_j може бути обчислена, якщо всі похідні по вихідним сигналам o_l наступного шару відомі. Підсумовуючи усе вищезазначене:

$$\frac{\partial E}{\partial \omega_{ji}} = o_i \delta_j,$$

$$\delta_j = \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial net_j} = \begin{cases} (o_j - t_j) o_j (1 - o_j), \text{ якщо } j - \text{ий нейрон є вихідним} \\ \left(\sum_{l \in L} \omega_{lj} \delta_l \right) o_j (1 - o_j), \text{ якщо } j - \text{ий нейрон є проміжним.} \end{cases}$$

Для того, щоб оновити ваги ω_{ji} , необхідно задати швидкість навчання $\eta > 0$. Зміна ваг впливає на значення функції затрат. Якщо $\frac{\partial E}{\partial \omega_{ji}} > 0$, зростання ω_{ji} спричиняє зростання E , якщо $\frac{\partial E}{\partial \omega_{ji}} < 0$ зменшення ω_{ji} спричиняє збільшення E .

$$\Delta \omega_{ji} = -\eta \frac{\partial E}{\partial \omega_{ji}} = -\eta \delta_j o_i$$

Отже, змінюючи кожен цикл ваги на величину $\Delta \omega_{ji}$ ми гарантуємо зменшення значення функції витрат [38].

Нейронні мережі, що використовують радіальні базисні функції (RBF)

RBF-мережі є тришаровими штучними нейронними мережами, кожен нейрон прихованого шару яких використовує радіальну базисну функцію у якості функції активації [46].

Радіальною базисною функцією є дійснозначною функцією, значення якої залежить від відстані до початку системи координат, тобто:

$$\varphi(x) = \varphi(\|x\|),$$

або від відстані до деякої іншої точки c , що називається центром, тоді:

$$\varphi(x, c) = \varphi(\|x - c\|).$$

Найчастіше в RBF-мережах використовують евклідову відстань як функцію відстані, що визначається як:

$$\|x - c\| = \sqrt{\sum_{i=1}^n (x_i - c_i)^2},$$

де n - вимірність векторів x і c . Найбільш поширеною радіальною базисною функцією є функція Гауса, що має вигляд:

$$\varphi(r) = \exp\left(\frac{-r^2}{2\sigma^2}\right).$$




Рис. 2.4. Функція Гауса

Джерело: розроблено автором

Зсув функцій у вихідному шарі моделюється за рахунок додаткового нейрона у проміжному шарі, що має сталу функцію активації:

$$\varphi_0(r) = 1.$$

Для вхідного значення x вихідне значення RBF мережі обчислюється як:

$$y_i(x) = \sum_{k=1}^{J_2} \omega_{ki} \varphi(\|x - c_k\|), i = 1, \dots, J_3,$$

де J_2 – кількість проміжних нейронів, J_3 – кількість вихідних нейронів, $y_i(x)$ – сигнал i -го вихідного нейрона, ω_{ki} – вага зв'язку від k -го проміжного до i -го вихідного нейрона, $\|\cdot\|$ - відстань, $\varphi(\cdot)$ – радіальна базисна функція.

Найпростіший алгоритм тренування даної мережі включає використання методу градієнтного спуску. Критерієм оптимізації моделі є мінімізація середньоквадратичного відхилення. Запишемо похибку наступним чином:

$$E = \frac{1}{N} \sum_{n=1}^N \sum_{i=1}^{J_3} (e_{n,i})^2,$$

де N – довжина тренувального набору даних, e – похибка апроксимації i -го нейрона для n -го тренувального екземпляру:

$$e_{n,i} = y_{n,i} - \sum_{m=1}^{J_2} \omega_{mi} \varphi(\|x_n - c_m\|) = y_{n,i} - \omega_i^T \varphi_n.$$

Диференціюючи E по ω_{mi} та c_m отримуємо відповідно:

$$\frac{\partial E}{\partial \omega_{mi}} = -\frac{2}{N} \sum_{n=1}^N e_{n,i} \varphi(\|x_n - c_m\|), m = 1, \dots, J_2, i = 1, \dots, J_3,$$

$$\frac{\partial E}{\partial c_m} = \frac{2}{N} \omega_{mi} \sum_{n=1}^N e_{n,i} \varphi'(\|x_n - c_m\|) \frac{x_n - c_m}{\|x_n - c_m\|}, m = 1, \dots, J_2, i = 1, \dots, J_3,$$

де $\varphi'(\cdot)$ – перша похідна функції $\varphi(\cdot)$.

Використовуючи метод градієнтного спуску кожен ітерацію оновлюємо параметри мережі на величини:

$$\Delta \omega_{mi} = -\eta_1 \frac{\partial E}{\partial \omega_{mi}},$$

$$\Delta c_m = -\eta_1 \frac{\partial E}{\partial c_m},$$

де η_1 та η_2 – сталі, що визначають швидкість навчання. Ініціалізація мережі може базуватись на випадковому генеруванні малих чисел як центрів радіальних базисних функцій та елементів матриці ваг. Також можна використати методи кластеризації для визначення початкових центрів та метод найменших квадратів для пошуку початкових ваг [45].

2.3. Машини екстремального навчання та нейронні системи нечіткого виведення

Машини екстремального навчання (ELM)

ELM як відносно новий алгоритм навчання тришарових нейронних мереж є дуже швидким та ефективним. Нижче наведений розгорнутий опис даного алгоритму.

Маючи N окремих тренувальних екземплярів $(x_i, t_i) \in R^n \times R^m$ ($i = 1, 2, \dots, N$), вихідне значення мережі з $\tilde{N}$ проміжними нейронами може бути представлене у вигляді:

$$o_j = \sum_{i=1}^{\tilde{N}} \beta_i f(x_j) = \sum_{i=1}^{\tilde{N}} \beta_i f(a_i x_j + b_i), j = 1, \dots, N,$$

де o_j – вихідний вектор мережі, що відповідає вхідному вектору x_j тренувального екземпляра, $a_i = [a_{i1}, a_{i2}, \dots, a_{in}]^T$, b_i є випадково генерованими тренувальними параметрами j -го проміжного нейрона, $[\beta_i = \beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ – ваги зв'язків між i -им прихованим нейроном та вихідними нейронами, $f(\cdot)$ є функцією активації нейронів.

Запишемо попереднє рівняння у компактній матричній формі:

$$H\beta = O,$$

де

$$H = \begin{bmatrix} f(a_1x_1 + b_1) & \cdots & f(a_{\tilde{N}}x_1 + b_{\tilde{N}}) \\ \vdots & \ddots & \vdots \\ f(a_1x_N + b_1) & \cdots & f(a_{\tilde{N}}x_N + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}},$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m}, O = \begin{bmatrix} o_1^T \\ \vdots \\ o_N^T \end{bmatrix}_{N \times m}.$$

Метою тренування мережі є мінімізація функції витрат, що має вигляд:

$$E = \|O - T\|,$$

де T – матриця вихідних значень тренувальних екземплярів [26]:

$$T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}.$$

Таким чином, β можна визначити аналітичним шляхом, використовуючи наступну рівність:

$$\hat{\beta} = H^+T,$$

де H^+ - псевдообернена матриця Мура-Пенроуза до матриці H [41].

Отже, обчислення ваг відбувається за допомогою математичних перетворень, що дозволяє позбавитись довгих навчальних процесів з коригуванням параметрів мережі, використовуючи ітераційні методи.

Нейронні системи нечіткого виведення (NFIS)

Нейронні системи нечіткого виведення є поєднанням алгоритмів нейронних мереж та систем нечіткого виведення.

Система нечіткого виведення (fuzzy inference system) – система логічного виведення, що базується на алгоритмі отримання нечітких висновків на основі нечітких передумов з використанням розглянутих основних понять нечіткої логіки. Системи нечіткого виведення засновані на теорії нечітких множин та мають характерну будову (див. рис. 2.5).




Рис. 2.5. Будова системи нечіткого виведення

Джерело: [47]

Імплементація алгоритмів нейронних мереж дозволяє оптимізувати параметри такої системи. Існує множина можливих архітектур нейронної системи нечіткого виведення. У даній роботі ми розглянули адаптивну нейронну систему нечіткого виведення (adaptive neural based fuzzy inference system або ANFIS), будова якої дозволяє вирішувати завдання регресії (див. рис. 2.6).




Рис. 2.6. Будова адаптивної нейронної системи нечіткого виведення

Джерело: [47]

Для спрощення розглянемо нейронну систему нечіткого виведення з двома вхідними величинами x та y та однією вихідною величиною z . Нехай база правил містить два нечітких правила типу Такагі-Сугено.

Правило 1: Якщо x відповідає A_1 та y відповідає B_1 , тоді $f_1 = p_1x + q_1y + r_1$.
Правило 2: Якщо x відповідає A_2 та y відповідає B_2 , тоді $f_2 = p_2x + q_2y + r_2$.

Шар 1: кожен вузол цього шару має функцію $O_i^1 = \mu_{A_i}(x)$, де x – вхідні дані до i -го вузла, A_i – лінгвістична змінна, що відповідає функції цього вузла. Іншими словами, O_i^1 – функція належності A_i , що визначає наскільки задана величина цього шару кількісно задовольняє A_i . Зазвичай у якості функції $\mu_{A_i}(x)$ використовують функцію Гауса, значення якої знаходяться в межах від 0 до 1, наприклад:

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}},$$

або

$$\mu_{A_i}(x) = \exp \left\{ - \left(\frac{x - c_i}{a_i} \right)^2 \right\}$$

де $\{a_i, b_i, c_i\}$ – набір параметрів. Зі зміною даних параметрів, вигляд функції відповідно змінюється. На практиці також можуть використовуватись будь-які неперервні частково диференційовні функції.

Шар 2: кожен вузол у цьому шарі відображає фагу кожного правила. Вхідний сигнал у вузлі множиться на певну величину та подається на вихід. Функцією, що використовується у вузлах цього шару є нечітке «І»:

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(x).$$

Шар 3: у вузлах цього шару розраховується частка ваги і-го правила та суми ваг усіх правил.

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2.$$

Розраховану величину називатимемо нормалізованою вагою правила.

Шар 4: кожен вузол даного шару містить функцію:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i),$$

де $\bar{w}_i$ – вихідні величини попереднього шару, $\{p_i, q_i, r_i\}$ – набір параметрів.

Шар 5: у цьому шарі відбувається розрахунок суми всіх вхідних сигналів

$$O_i^5 = \sum_i \bar{w}_i f_i.$$

Для коригування параметрів мережі використовується метод градієнтного спуску. Нехай мережа містить L шарів та $n(k)$ вузлів у k -му шарі, пара значень (k, i) визначає i -ий вузол у шарі k , для якого задамо функцію належності

$$O_i^k = O_i^k(O_i^{k-1}, \dots, O_{n(k-1)}^k, a, b, c, \dots),$$

де $a, b, c, \dots$ - параметри вузла.

Припускаючи, що тренувальний набір даних містить P екземплярів та позначивши $T_{m,p}$ як m -ий компонент p -го цільового значення і $T_{m,p}$ як $O_{m,p}^L$ як m -ий компонент p -го фактичного вихідного значення, похибку для p -го екземпляру та загальну похибку моделі представимо як:

$$E_p = \sum_{m=1}^{n(L)} (T_{m,p} - O_{m,p}^L)^2 \Rightarrow E = \sum_{p=1}^P E_p$$

Градiєнт для i -го вузла вихідного шару розрахуємо як:

$$\frac{\partial E_p}{\partial O_{i,p}^L} = -2(T_{i,p} - O_{i,p}^L)$$

Для вузла проміжних шарів градієнт може бути розрахований як:

$$\frac{\partial E_p}{\partial O_{i,p}^L} = \sum_{m=1}^{n(k+1)} \frac{\partial E_p}{\partial O_{m,p}^{k+1}} \frac{\partial O_{m,p}^{k+1}}{\partial O_{i,p}^k}, 1 \leq k \leq L - 1.$$

Таким чином, градієнт вузла проміжного шару може бути виражений як лінійна комбінація градієнтів вузлів наступного шару. Отже, для всіх $1 \leq k \leq L$ і $1 \leq i \leq n(k)$, можемо знайти $\frac{\partial E_p}{\partial O_{i,p}^k}$.

Якщо α – параметр заданої мережі, маємо:

$$\frac{\partial E_p}{\partial \alpha} = \sum_{O^* \in S} \frac{\partial E_p}{\partial O^*} \frac{\partial O^*}{\partial \alpha},$$

де S – множина вузлів, вихідний сигнал яких залежить від α . Тоді похідна загальної похибки від α обчислимо як:

$$\frac{\partial E}{\partial \alpha} = \sum_{p=1}^P \frac{\partial E_p}{\partial \alpha}$$

Відповідно, формула для оновлення параметрів мережі, має вигляд:

$$\Delta \alpha = -\eta \frac{\partial E}{\partial \alpha},$$

де параметр навчання η може бути надалі виражений, як:

$$\eta = \frac{k}{\sqrt{\sum_{\alpha} \left(\frac{\partial E}{\partial \alpha} \right)^2}}.$$

Для навчання мереж даного типу також використовують гібридні алгоритми, що поєднують методи градієнтного спуску та найменших квадратів, проте більшою популярністю користується описаний вище метод [48].

2.4. Нейронні мережі з коротко та довгостроковою пам'яттю

Нейронна мережа з коротко та довгостроковою пам'яттю (LSTM) є рекурентною нейронною мережею. До цього моменту ми розглядали лише прямі штучні нейронні мережі, вихідні значення яких залежали від вхідних даних та

значень параметрів мережі на момент надходження вхідного сигналу. Тепер ми пропонуємо ознайомитися з архітектурою рекурентних нейронних мереж, яка продемонстрована на рис. 2.7.




Рис. 2.7. Архітектура рекурентної нейронної мережі

Джерело: [39]

Вихідне значення вектору h_t залежить від вхідного значення x_t , параметрів мережі у момент часу t , а також параметрів мережі в момент часу $t - 1$. Таким чином, рекурентні нейронні мережі здатні використовувати свою внутрішню пам'ять для обробки цілих послідовностей у часі, а не окремо взятих екземплярів даних.

У даному підрозділі ми розглянемо архітектуру та алгоритм навчання нейронної мережі з коротко та довгостроковою пам'яттю. Ця модель виникла як вирішення проблеми так званого «вицвітання градієнта» в мережах, які використовують алгоритми градієнтного спуску та зворотного поширення помилки, у тому числі й звичайних рекурентних нейронних мережах. Дана проблема виникає у зв'язку з поступовим наближенням градієнта функції витрат до нуля з кожним наступним циклом тренування, що робить неможливим коригування параметрів мережі та подальше її тренування [21].

LSTM-мережа є штучною нейронною мережею, що містить LSTM-блоки замість або у додаток до інших блоків мережі. LSTM-блок – це рекурентний модуль мережі, що здатний запам'ятовувати значення як на короткі так і на

тривалі проміжки часу. Ключем до такої особливості є те, що LSTM-блок не використовує функцію активації у своїх рекурентних компонентах [24].

=




Рис. 2.8. Схема LSTM-блоку

Джерело: розроблено автором на основі [34]

Схематичне представлення LSTM-блоку зображено на рисунку 2.8. Він включає три так звані вентиля (вхідний, забуття, вихідний), вхідний шар, а також вихідний шар, що рекурентно пов'язаний з іншими блоками мережі. Алгоритм роботи мережі описаний нижче.

Нехай x^t - вхідний вектор в момент часу t , N - кількість LSTM-блоків, M - довжина тренувального набору даних. Тоді маємо наступні ваги для LSTM шару:

- Вхідні ваги: $W_z, W_i, W_f, W_o \in R^{N \times M}$
- Рекурентні ваги: $R_z, R_i, R_f, R_o \in R^{N \times M}$
- Ваги зміщень: $b_z, b_i, b_f, b_o \in R^N$.

Запишемо формули для розрахунків:

$$\begin{aligned}
 \bar{z}^t &= W_z x^t + R_z y^{t-1} + b_z, \\
 z^t &= g(\bar{z}^t), \\
 \bar{i}^t &= W_i x^t + R_i y^{t-1} + b_i, \\
 i^t &= \sigma(\bar{i}^t), \\
 \bar{f}^t &= W_f x^t + R_f y^{t-1} + b_f, \\
 f^t &= \sigma(\bar{f}^t), \\
 c^t &= z^t \odot i^t + c^{t-1} \odot f^t, \\
 \bar{o}^t &= W_o x^t + R_o y^{t-1} + p_o \odot c^{t-1} + b_o, \\
 o^t &= \sigma(\bar{o}^t), \\
 y^t &= h(c^t) \odot o^t,
 \end{aligned}$$

де σ – функція активації вентилів (логістична сигмоїда), g та h – функції активації вхідного та вихідного шару відповідно (гіперболічний тангенс), $\odot$ - оператор по елементного множення векторів.

Для тренування мереж даного типу використовують алгоритм зворонього поширення помилки у часі. Зміни параметрів усередині LSTM-блоку можуть бути визначені як:

$$\begin{aligned}
 \delta y^t &= \Delta^t + R_z^T \delta z^{t+1} + R_i^T \delta i^{t+1} + R_f^T \delta f^{t+1} + R_o^T \delta o^{t+1} \\
 \delta \bar{o}^t &= \delta y^t \odot h(c^t) \odot \sigma'(\bar{o}^t) \\
 \delta c^t &= \delta y^t \odot o^t \odot h'(c^t) + \delta c^{t+1} \odot f^{t+1} \\
 \delta \bar{f}^t &= \delta c^t \odot c^{t-1} \odot \sigma'(\bar{f}^t) \\
 \delta \bar{i}^t &= \delta c^t \odot z^t \odot \sigma'(\bar{i}^t) \\
 \delta \bar{z}^t &= \delta c^t \odot i^t \odot \sigma'(\bar{z}^t).
 \end{aligned}$$

Тут Δ^t – вектор змінних δ з наступного шару мережі. У разі наявності шару перед блоком також розраховуємо:

$$\delta x^t = W_z^T \delta \bar{z}^t + W_i^T \delta \bar{i}^t + W_f^T \delta \bar{f}^t + W_o^T \delta \bar{o}^t.$$

Градiєнти для ваг мережі розраховуються таким чином:

$$\begin{aligned}\delta W_* &= \sum_{t=0}^T \langle \delta_{*^t}, x^t \rangle, \\ \delta R_* &= \sum_{t=0}^{T-1} \langle \delta_{*^{t+1}}, y^t \rangle, \\ \delta b_* &= \sum_{t=0}^T \delta_{*^t},\end{aligned}$$

де $*$ є одним з множини векторів $\{\bar{z}, \bar{l}, \bar{f}, \bar{o}\}$ і $\langle *_1, *_2 \rangle$ – результат по елементного множення двох векторів [34].

РОЗДІЛ 3 МОДЕЛЮВАННЯ КУРСУ БІТКОІНА З ВИКОРИСТАННЯМ АЛГОРИТМІВ ШТУЧНОГО ІНТЕЛЕКТУ

3.1. Попередня підготовка бази даних та визначення критеріїв оцінки результатів прогнозування

Для досліджень було завантажено базу даних щохвилинного курсу Біткоїна на період з 01.01.2022 по 01.05.2022. У тестах використовувалися дані з 01.04.2022 по 08.04.2022.




Рис. 3.1. Щохвилинний курс Біткоїна

Джерело: розроблено автором у програмному середовищі Python на основі часового ряду ціни відкриття Біткоїна

На рис. 3.1 зображено щохвилинну зміну курсу Біткоїна упродовж 01.04.2022 – 08.04.2022. Варто зауважити, що на графіку помітні значні коливання курсу протягом даного періоду. Це дає змогу робити певні висновки стосовно придатності нейронних мереж для прогнозування у разі високої точності отриманого прогнозу.

Використовуючи алгоритми глибинного навчання, необхідно попередньо здійснити підготовку даних, що включає в себе зменшення різниці між пороговим значенням та фактичними даними. Зазвичай дані нормалізують перед тим як використовувати їх у нейронній мережі:

$$x'_t = \frac{x_t - x_{min}}{x_{max} - x_{min}},$$

де x'_t - дані після нормалізування, x_{min} і x_{max} - мінімальне та максимальне значення відповідно серед вхідних даних x_t . Після розрахунків виконуємо операцію, зворотну до нормалізування:

$$\hat{y}_t = y'(y_{max} + y_{min}) + y_{min},$$

де $\hat{y}_t$ - прогнозовані дані після зворотної нормалізації, y_{min} і y_{max} - мінімальне та максимальне значення відповідно вихідних даних y' .

Для оцінки точності прогнозу при дослідженні використовуються три критерії: середньоквадратична похибка (root mean squared error - RMSE), середня абсолютна відсоткова похибка (mean absolute percentage error - MAPE), та точність прогнозування напрямку зміни ціни (directional accuracy - DA).

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

де y_t і $\hat{y}_t$ - фактична і прогнозована ціна відповідно в момент часу t , N - довжина досліджуваного набору даних. RMSE характеризує стандартне відхилення між прогнозованими і фактичними значеннями.

Середня абсолютна похибка (MAPE), також відома як середнє абсолютне відхилення (mean absolute percentage deviation - MAPD), характеризує точність прогнозу у відсотковому вираженні і визначається як:

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


Ці два показники широко використовуються для виміру точності прогнозування. Чим вони менші, тим вища точність моделі.

Більше того, ми також зацікавлені щодо точності передбачення напрямку зміни курсу, ми визначаємо оцінку даної характеристики як:

$$DA = \frac{1}{N} \sum_{t=1}^N D_t, \quad D_t = \begin{cases} 1, & (y_{t+1} - y_t)(\hat{y}_{t+1} - y_t) \geq 0, \\ 0, & (y_{t+1} - y_t)(\hat{y}_{t+1} - y_t) < 0. \end{cases}$$

Чим ближча DA до одиниці, тим вища точність прогнозування напряму зміни ціни.

Для визначення ефективності кожної нейронної мережі при різних розмірах набору даних, ділимо базу даних на малі, середні та великі набори даних.




	Unix Timestamp	Date	Symbol	Open	High	Low	Close	Volume
0	1648771200000	2022-04-01 00:00:00	BTCUSD	45537.67	45568.25	45479.34	45479.34	1.603230
1	1648771260000	2022-04-01 00:01:00	BTCUSD	45479.34	45479.34	45444.53	45444.53	0.014785
2	1648771320000	2022-04-01 00:02:00	BTCUSD	45444.53	45552.68	45444.53	45552.68	11.035987
3	1648771380000	2022-04-01 00:03:00	BTCUSD	45552.68	45574.00	45503.45	45503.46	0.183015
4	1648771440000	2022-04-01 00:04:00	BTCUSD	45503.46	45564.75	45503.46	45562.96	0.227906
...	...	...	...	...	...	...	...	...
2195	1648902900000	2022-04-02 12:35:00	BTCUSD	46833.72	46857.49	46818.89	46857.08	0.039231
2196	1648902960000	2022-04-02 12:36:00	BTCUSD	46857.08	46867.29	46819.77	46819.77	0.038483
2197	1648903020000	2022-04-02 12:37:00	BTCUSD	46819.77	46867.96	46819.64	46867.96	0.322021
2198	1648903080000	2022-04-02 12:38:00	BTCUSD	46867.96	46869.24	46831.42	46842.48	0.551100
2199	1648903140000	2022-04-02 12:39:00	BTCUSD	46842.48	46842.48	46811.31	46811.31	0.000320

Рис. 3.2. Малий набір даних

Джерело: розроблено автором у програмному середовищі Python

На рис. 3.2 зображено малий набір даних. Кожен набір містить 2200 значень. У ході дослідження використовуємо 5 таких наборів.




	Unix Timestamp	Date	Symbol	Open	High	Low	Close	Volume
0	1648771200000	2022-04-01 00:00:00	BTCUSD	45537.67	45568.25	45479.34	45479.34	1.603230
1	1648771260000	2022-04-01 00:01:00	BTCUSD	45479.34	45479.34	45444.53	45444.53	0.014785
2	1648771320000	2022-04-01 00:02:00	BTCUSD	45444.53	45552.68	45444.53	45552.68	11.035987
3	1648771380000	2022-04-01 00:03:00	BTCUSD	45552.68	45574.00	45503.45	45503.46	0.183015
4	1648771440000	2022-04-01 00:04:00	BTCUSD	45503.46	45564.75	45503.46	45562.96	0.227906
...	...	...	...	...	...	...	...	...
5495	1649100900000	2022-04-04 19:35:00	BTCUSD	45824.35	45845.63	45824.35	45829.99	1.092644
5496	1649100960000	2022-04-04 19:36:00	BTCUSD	45829.99	45842.35	45829.99	45832.36	0.054772
5497	1649101020000	2022-04-04 19:37:00	BTCUSD	45832.36	45832.84	45803.06	45816.93	1.631783
5498	1649101080000	2022-04-04 19:38:00	BTCUSD	45816.93	45816.93	45786.11	45795.93	0.073610
5499	1649101140000	2022-04-04 19:39:00	BTCUSD	45795.93	45798.23	45795.93	45798.23	0.000196

Рис. 3.3. Середній набір даних

Джерело: розроблено автором у програмному середовищі Python

На рис. 3.3 зображено середній набір даних. Кожен набір містить 5500 значень. У ході дослідження використовуємо 2 таких набори.



	Unix Timestamp	Date	Symbol	Open	High	Low	Close	Volume
0	1648771200000	2022-04-01 00:00:00	BTCUSD	45537.67	45568.25	45479.34	45479.34	1.603230
1	1648771260000	2022-04-01 00:01:00	BTCUSD	45479.34	45479.34	45444.53	45444.53	0.014785
2	1648771320000	2022-04-01 00:02:00	BTCUSD	45444.53	45552.68	45444.53	45552.68	11.035987
3	1648771380000	2022-04-01 00:03:00	BTCUSD	45552.68	45574.00	45503.45	45503.46	0.183015
4	1648771440000	2022-04-01 00:04:00	BTCUSD	45503.46	45564.75	45503.46	45562.96	0.227906
...	...	...	...	...	...	...	...	...
10995	1649431020000	2022-04-08 15:17:00	BTCUSD	43815.11	43854.50	43690.29	43846.99	15.817057
10996	1649431080000	2022-04-08 15:18:00	BTCUSD	43846.99	43880.00	43846.99	43864.87	1.089274
10997	1649431140000	2022-04-08 15:19:00	BTCUSD	43864.87	43871.38	43843.64	43843.64	0.165605
10998	1649431200000	2022-04-08 15:20:00	BTCUSD	43843.64	43843.64	43803.67	43825.46	2.434432
10999	1649431260000	2022-04-08 15:21:00	BTCUSD	43825.46	43841.57	43811.67	43811.67	0.042467

Рис. 3.4. Великий набір даних

Джерело: розроблено автором у програмному середовищі Python

На рис. 3.4 зображено великий набір даних. Набір містить 11000 значень. У ході дослідження використовуємо 1 такий набір.

Для малих наборів перші 2000 значень використовуємо для тренування нейронних мереж, решту 200 – для оцінки точності прогнозування. Для середніх та великого набору даних ця пропорція залишається незмінною. Усі підрахунки виконувалися з використанням програмного забезпечення RStudio на базі R версії 4.2.0, а також Python версії 3.10.4.

При використанні алгоритмів глибинного навчання, слід враховувати, що кількість нейронів досить сильно впливає на результат прогнозування. Не існує єдиного підходу до визначення оптимальної кількості нейронів у кожному прихованому шарі мережі, і досвід автора моделі грає визначальну роль при побудові її архітектури. У нашому досліді кількість нейронів має виключно експериментальний характер. BP, RBF, ELM та ANFIS мережі містять один прихований шар, що складається з 50 нейронів. LSTM мережа містить один прихований шар, що складається з 50 LSTM вузлів. Розмір ковзкого вікна дорівнює 5. Кількість навчальних циклів для кожної мережі становить 150.

3.2. Моделювання курсу Біткоіна з використанням штучних нейронних мереж

Як зазначалося раніше кожен малий набір даних містить 2200 значень, для аналізу використовується 5 таких наборів. 10000 значень (приблизно 90%) використовуються для тренування мережі, інші 1000 значень (приблизно 10%) – для оцінки точності прогнозування.

На рис. 3.5 зображено результати прогнозування курсу Біткоіна упродовж різних періодів. У табл. 3.1 наведено оцінки точності прогнозування нейронних мереж, побудованих різними методами.




Рис. 3.5. Фактичний та прогнозований курс Біткоіна (малі набори даних)

Таблиця 3.1

Оцінки точності прогнозу (малі набори даних)

Період	Похибка	ELM	RBF	ANFIS	BP	LSTM
1.04.2022 9:20 - 12:40	RMSE	34,54	95,30	37,00	55,62	40,01
	MAPE	0,00048	0,00195	0,00043	0,00103	0,00046
	DA	0,578	0,568	0,608	0,578	0,618
4.04.2022 18:40 - 22:00	RMSE	28,01	138,62	29,71	133,60	33,43
	MAPE	0,00042	0,00282	0,00044	0,00246	0,00052
	DA	0,503	0,503	0,482	0,503	0,508

Продовження таблиці 3.1

5.04.2022 4:00 - 7:20	RMSE	22,59	68,98	20,24	58,35	27,88
	MAPE	0,00035	0,00144	0,00028	0,00116	0,00047
	DA	0,568	0,523	0,578	0,568	0,573
6.04.2022 13:20 - 16:40	RMSE	145,41	160,98	117,38	113,29	69,89
	MAPE	0,00295	0,00318	0,00205	0,00218	0,00117
	DA	0,437	0,563	0,472	0,563	0,542
7.04.2022 22:40 - 8.04.2022 2:00	RMSE	23,97	69,34	28,04	24,30	31,12
	MAPE	0,00039	0,00150	0,00044	0,00039	0,00050
	DA	0,548	0,482	0,513	0,528	0,538
Середні значення	RMSE	50,90	106,65	46,47	77,03	40,47
	MAPE	0,00092	0,00218	0,00073	0,00144	0,00063
	DA	0,527	0,528	0,531	0,548	0,556

Джерело: розроблено автором на основі часових рядів цін відкриття Біткоіна та програмних кодів на мові R і Python (див. дод. А, Б, В, Г, Д)

При прогнозуванні на малих наборах даних LSTM-мережа має найменшу середньоквадратичну похибку та середню абсолютну відсоткову похибку (40,47 та 0,00063 відповідно), випереджаючи всі інші мережі за цими показниками. Найвищу точність прогнозування на пряму зміни курсу також має LSTM-мережа (0,556).

Кожен середній набір даних містить 5500 значень, для аналізу використовуємо 2 таких набори. 10000 значень (приблизно 90%) використовуються для тренування мережі, інші 1000 значень (приблизно 10%) – для оцінки точності прогнозування.

На рис. 3.6 продемонстровано фактичний та прогнозований курс упродовж двох періодів. У табл. 3.2 наведено відповідні оцінки точності прогнозу.




Рис. 3.6. Фактичний та прогнозований курс Біткоіна (середні набори даних)

Джерело: розроблено автором у програмному середовищі Python (див. дод. А, Б, В, Г, Д)

Таблиця 3.2

Оцінки точності прогнозу (середні набори даних)

Період	Похибка	ELM	RBF	ANFIS	BP	LSTM
4.04.2022 11:20 - 4.04.2022 19:40	RMSE	30,90	108,71	46,30	66,64	31,99
	MAPE	0,00045	0,00230	0,00069	0,00129	0,00048
	DA	0,574	0,536	0,580	0,570	0,570
7.04.2022 22:40 - 8.04.2022 7:00	RMSE	25,16	81,51	28,82	23,12	19,64
	MAPE	0,00046	0,00178	0,00050	0,00037	0,00032
	DA	0,588	0,606	0,566	0,563	0,598
Середні значення	RMSE	28,03	95,11	37,56	44,88	25,82
	MAPE	0,00046	0,00204	0,00060	0,00083	0,00040
	DA	0,581	0,571	0,573	0,567	0,584

Джерело: розроблено автором на основі часових рядів цін відкриття Біткоіна та програмних кодів на мові R і Python (див. Додатки А, Б, В, Г)

Отримані результати демонструють, що при прогнозуванні на середніх наборах даних найкращі результати демонструють LSTM та ELM мережі. Вони мають найменші середньоквадратичні похибки (25,82 та 28,03 відповідно), а також найменші значення середньої абсолютної відсоткової похибки (0,00040 та

0,00046 відповідно). У передбаченні напрямку зміни курсу усі мережі показали приблизно однаковий результат з відхиленнями в різниці на рівні статистичної похибки.

Великий набір даних містить 11000 значень, для аналізу використовуємо 1 такий набір даних. Перші 10000 значень дозволяють натренувати мережу, решта 1000 – оцінити точність прогнозування отриманої моделі.

На рисунку 3.7 зображені фактичний та прогнозований курс Біткоіна упродовж відповідного періоду. У табл. 3.3 наведені оцінки отриманих результатів прогнозу.




Рис. 3.7. Фактичний та прогнозований курс Біткоіна (великий набір даних)

Джерело: розроблено автором у програмному середовищі Python (див. дод. А, Б, В, Г, Д)

Оцінки точності прогнозу (великий набір даних)

Період	Похибка	ELM	RBF	ANFIS	BP	LSTM
7.04.2022 22:40 - 8.03.2022 15:20	RMSE	37,48	161,46	42,89	72,13	30,87
	MAPE	0,00066	0,00365	0,00059	0,00141	0,00051
	DA	0,605	0,561	0,546	0,550	0,600

Джерело: розроблено автором на основі часових рядів цін відкриття Біткоіна та програмних кодів на мові R і Python (див. дод. А, Б, В, Г, Д)

З наведених розрахунків можна зробити висновок, що при прогнозуванні на великому наборі даних, найкраще себе показує LSTM-мережа, маючи найменшу середньоквадратичну похибку та середню абсолютну відсоткову похибку (30,87 та 0,00051 відповідно), випереджаючи ELM-мережу (37,48 та 0,00066 відповідно), ANFIS-мережу (42,89 та 0,00059 відповідно), RBF-мережу (161,46 та 0,00365 відповідно) та BP-мережу (72,13 та 0,00141 відповідно). За показником точності прогнозування найкращий результат показала ELM-мережа (0,605).




Рис. 3.8. RMSE мереж

Джерело: розроблено автором




Рис. 3.9. MAPE мереж

Джерело: розроблено автором




Рис. 3.10. DA мереж

Джерело: розроблено автором

Рисунки 3.8 – 3.10 демонструють результати емпіричних досліджень для наборів даних різної довжини та порівняння середньої точності передбачень. Як бачимо, найкращі показники має LSTM-мережа, особливо в разі прогнозування на великих наборах даних, що обумовлено особливостями архітектури даного типу мереж.

Важливим показником якості моделі також є похибка тренування, яка характеризує наскільки добре показує себе мережа при прогнозуванні на тренувальних даних.

Похибки навчання для малих наборів даних представлені у табл. 3.4. Найменші похибки має ELM-мережа та LSTM-мережа.

Таблиця 3.4

Похибки навчання (малі набори даних)

Період	Похибка	ELM	RBF	ANFIS	BP	LSTM
1.04.2022 0:00 - 2.04.2022 9:19	RMSE	19,58	126,27	33,90	47,47	36,82
	MAPE	0,00020	0,00234	0,00035	0,00079	0,00038
2.04.2022 9:20 - 3.04.2022 18:39	RMSE	61,18	156,92	64,79	127,72	59,38
	MAPE	0,00062	0,00244	0,00095	0,01077	0,00103
3.04.2022 18:40 - 5.04.2022 3:59	RMSE	24,15	77,41	28,80	91,97	42,92
	MAPE	0,00028	0,00177	0,00034	0,00164	0,00054
5.04.2022 4:00 - 6.04.2022 13:19	RMSE	99,64	128,82	89,80	94,63	51,69
	MAPE	0,00188	0,00259	0,00162	0,00205	0,00085
6.04.2022 13:20 - 7.04.2022 22:39	RMSE	19,78	77,14	27,57	23,17	32,40
	MAPE	0,00030	0,00187	0,00046	0,00037	0,00060
Середні значення	RMSE	44,86	113,31	48,97	76,99	44,64
	MAPE	0,00066	0,00220	0,00074	0,00313	0,00068

Джерело: розроблено автором

Похибки навчання на середніх наборах даних представлені у табл. 3.5. Найменшою величиною похибок характеризується ELM-мережа та LSTM-мережа.

Таблиця 3.5

Похибки навчання (середні набори даних)

Період	Похибка	ELM	RBF	ANFIS	BP	LSTM
1.04.2022 0:00 - 4.04.2022 11:19	RMSE	9,82	59,24	16,41	15,67	10,23
	MAPE	0,00012	0,00100	0,00021	0,00027	0,00013
4.04.2022 11:20 - 28.04.2022 22:39	RMSE	43,30	91,10	66,41	51,92	37,07
	MAPE	0,00083	0,00174	0,00146	0,00123	0,00071
Середні значення	RMSE	26,56	75,17	41,41	33,79	23,65
	MAPE	0,00048	0,00137	0,00083	0,00075	0,00042

Джерело: розроблено автором

Похибки навчання на великому наборі даних представлені у табл. 3.6. Найменші похибки має LSTM-мережа.

Таблиця 3.6

Похибки навчання (великий набір даних)

Період	Похибка	ELM	RBF	ANFIS	BP	LSTM
1.04.2022 0:00 - 3.04.2022 22:39	RMSE	30,78	186,53	39,30	71,75	21,42
	MAPE	0,00058	0,00525	0,00070	0,00217	0,00044

Джерело: розроблено автором

В цілому, майбутнє Біткоіна дуже непередбачуване. З листопада минулого року спостерігається стабільна тенденція до зменшення курсу криптовалюти. Ситуація на ринку обумовлена тим, що з 2020 року основними гравцями ринку є інституційні інвестори – великі компанії зі значними об’ємами вкладень. Їх інтереси та цілі в основному й визначають ціну Біткоіна. Через збільшення інфляції у США, фінансова спільнота очікувала від регулятора – Федеральної резервної системи – збільшення ключової ставки, що спричиняє зростання ставок за кредитами та іншими запозиченнями, через що перевага відходить з високоризикованих активів до більш консервативних фінансових інструментів. Водночас у березні-квітні спостерігалось підвищення попиту на криптовалюту серед малих гравців, який поглинув частину ринкової пропозиції та стримав падіння курсу. Однак вже в травні Біткоін продовжив передбачуване падіння на

фоні раніше зазначених факторів, що впливають на інвестиційні настрої ринку.

Важливим фактором, що залишає впевненість інвесторів у подальшому підвищенні курсу криптовалюти є та званий халвінг. Халвінг передбачає зменшення винагороди вдвічі за додавання нового блоку в блокчейн. У мережі Біткоїн халвінг проводився вже тричі у 2012, 2016, 2020 роках. Наступний халвінг відбудеться у квітні 2024 року. Винагорода за майнінг скоротиться з 6,25 Біткоіна до 3,125 Біткоіна, що відповідно зменшить пропозицію криптовалюти на ринку. На традиційних фінансових ринках зниження пропозиції при стійкому попиті, як правило, приводить до підвищення ціни. Оскільки халвінг таким же чином зменшує число нових Біткоїнів, а попит при цьому залишається незмінним, ця процедура також приводить до збільшення ціни Біткоіна. Зокрема, після зменшення винагороди у 2012 році з 50 до 25 Біткоїнів за створення блоку, через рік ціна криптовалюти досягла свого історичного на той момент максимуму в 1000 доларів США. Аналогічно відобразився на курсі й халвінг у 2016 році, після якого у середині грудня 2017 року ціна Біткоіна встановила рекорд, досягши позначки у 19500 доларів США. Подібні явища спостерігались після халвінгу в 2020 році, проте визначальною причиною зростання ціни на Біткоїн стало значне зростання попиту на нього після початку пандемії COVID-19.

Станом на ранок 12 травня курс Біткоіна становив 25000 дол. США, знизившись з позначки 27600 доларів США фактично за 5 годин. Через декілька годин ситуація стабілізувалась і курс становив 27400 доларів США, проте такі різкі обвали, спричинені спекулятивними діями великих гравців на ринку, залишаються одним з основних факторів, що відлякують потенційних користувачів мережі. Вплив так званих «китів» (великих гравців) на формування курсу на даний момент є занадто великим. Проте, з подальшим розширенням мережі Біткоїн на ринку платіжних систем цей вплив буде поступово нівелюватися. Враховуючи зростаючу популярність технології блокчейн загалом та безпосередньо Біткоіна, він має перспективу стати світовою платіжною системою.

ВИСНОВКИ

Проблема нестійкості існуючої системи грошового обігу яскраво проявилася під час та після світової фінансової кризи 2008-2009 рр. У результаті з'явилася ідея створення нових валют і набув поширення термін «криптовалюта». Криптовалюта – цифрова система платежів та грошових переказів, заснована на новітніх технологіях за принципами криптографії з метою функціонування як безпечної, анонімної, децентралізованої, стабільної віртуальної валюти.

Найпоширенішим видом криптовалют сьогодні є Біткоїни. Основними перевагами даного виду валют є відсутність емісійного центру, контролю та обмежень випуску, повна анонімність, здатність генерувати валюту самостійно за допомогою майнінгу, захищеність від інфляції, відсутність впливу факторів зовнішнього середовища, окрім ринкових попиту і пропозиції. Головним недоліком Біткоїна є його надзвичайно висока волатильність. Більшість дослідників схильні до думки, що Біткоїн не можна вважати повноцінною валютою за визначенням, проте з подальшим розвитком інформаційних технологій та системи Інтернет-платежів у нього є потенціал стати глобальним платіжним засобом.

Одним з сучасних методів моделювання ціни Біткоїна є нейронні мережі, що використовують алгоритми штучного інтелекту. За допомогою мов програмування R та Python у даній роботі було побудовано нейронну мережу, що використовує алгоритм зворотного поширення помилки, машину екстремального навчання, нейронну мережу, що використовує радіальні базисні функції, нейронну адаптивну систему нечіткого виведення, а також рекурентну нейронну мережу з коротко та довгостроковою пам'яттю.

При дослідженні було використано часовий ряд щохвилинної ціни Біткоїна. Для того, щоб продемонструвати вплив розміру вибірки на навчання та ефективність роботи мережі, ми поділили вибірку на набори даних різної довжини та порівняли результати, отримані на кожному з них.

У результаті проведених досліджень було виявлено, що довжина часового ряду впливає на процес тренування та прогнозування. Найменші середньоквадратичну та середню абсолютну похибку мала мережа з коротко та довгостроковою пам'яттю. При прогнозуванні на великому наборі даних та середніх наборах даних машина екстремального навчання показала досить близькі до вищезазначеної мережі результати, однак поступилася їй при прогнозуванні на малих наборах даних. Мережа, що використовує радіальну базисну функцію показала досить близькі хороші результати у прогнозуванні зміни курсу Біткоіна на середніх та великому наборі даних, однак вона мала найбільші серед досліджуваних мереж середньоквадратичну та середню абсолютну похибку. Тому при дослідженні часових рядів рекомендується проводити комплексний аналіз даних із застосуванням відповідних мереж залежно від довжини рядів та специфіки бази даних.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Баликова Н. Японія визнала біткоїн платіжним засобом / Н. Баликова // Голос України. – 2017. – № 61. – С. 5.
2. Вільна енциклопедія «Вікіпедія» [Електронний ресурс]. – Режим доступу: <https://uk.wikipedia.org/wiki/>.
3. Куцевол М.А. Поняття та економічна природа крипто валюти / М.А. Куцевол, О.А. Шевченко-Наумова. – [Електронний ресурс]. – Режим доступу: <http://ir.kneu.edu.ua/handle/2010/16391>.
4. Ліхачов М. Скромна чарівність Біткоїна: українські реалії використання криптовалют / М. Ліхачов // Forbes Україна. – [Електронний ресурс]. – Режим доступу: <http://forbes.net.ua/ua/opinions/1428255-skromna-charivnist-bitkoina-ukrayinski-realiyi-vikoristannya-kriptovalyut>
5. Поливка Н. Криптовалюти і «різноманітні Біткоїни» / Н. Поливка // Юридична Газета online. – [Електронний ресурс]. – Режим доступу: <http://yur-gazeta.com/publications/practice/informaciyne-pravo-telekomunikaciyi/kriptovalyuti-i-riznomanitni-bitkoini.html/>
6. Aggarwal D. A complete empirical ensemble mode decomposition and support vector machine-based approach to predict Bitcoin prices [Електронний ресурс] / D. Aggarwal, S. Chandrasekaran, B. Annamalai // Journal of Behavioral and Experimental Finance. – 2020. – Режим доступу до ресурсу: <https://www.sciencedirect.com/science/article/abs/pii/S2214635019302266?via%3Dihub>.
7. An Advanced CNN-LSTM Model for Cryptocurrency Forecasting [Електронний ресурс] / L.Ioannis, K. Niki, S. Stavros, P. Panagiotis // Electronics. – 2021. – Режим доступу до ресурсу: <https://www.mdpi.com/2079-9292/10/3/287>.
8. An Overview of Blockchain Technology:Architecture, Consensus, and Future Trends [Електронний ресурс] / [Z. Zheng, S. Xie, H. Dai et al.]. – 2017. – Режим доступу до ресурсу: https://www.researchgate.net/publication/318131748_An_Overview_of_Blockchain_Technology_Architecture_Consensus_and_Future_Trends.

9. Anderson T. Bitcoin, Blockchain & Initial Coin Offerings: A Global Review [Электронный ресурс] / T. Anderson, L. Scanlon, C. Clarence-Smith. – 2017. – Режим доступа до ресурсу: <https://www.pinsentmasons.com/PDF/2017/FinTech/Bitcoin-Blockchain-guide.pdf>.
10. Andersson G. Prospects of Bitcoin: An evaluation of its future [Электронный ресурс] / G. Andersson, A. Wegdell. – 2014. – Режим доступа до ресурсу: <http://lup.lub.lu.se/luur/download?func=downloadFile&recordId=4462711&fileId=4462717>.
11. Blockchain Technology Overview [Электронный ресурс] / D.Yaga, P. Mell, N. Roby, K. Scarfone. – 2018. – Режим доступа до ресурсу: <https://nvlpubs.nist.gov/nistpubs/ir/2018/NIST.IR.8202.pdf>.
12. Brief Introduction of Back Propagation (BP) Neural Network Algorithm and Its Improvement [Электронный ресурс] / J. Li, J. Cheng, J. Shi, F. Huang // Advances in Computer Science and Information Engineering. – 2012. – P. 489 – 501. – Режим доступа до ресурсу: https://link.springer.com/chapter/10.1007/978-3-642-30223-7_87.
13. Chen X.-W. Big data deep learning: Challenges and perspectives / X.-W. Chen, X. Lin // IEEE Access – 2014. – №2. – P. 514 – 525.
14. Chiu J. The economics of cryptocurrencies–bitcoin and beyond [Электронный ресурс] / J. Chiu, T. Koepl. – 2017. – Режим доступа до ресурсу: https://www.chapman.edu/research/institutes-and-centers/economic-science-institute/_files/ifree-papers-and-photos/koeppel-april2017.pdf.
15. Chong E. Deep learning networks for stockmarket analysis and prediction: Methodology, data representations, and case studies [Электронный ресурс] / E. Chong, C. Han, F. Park // Expert Systems with Applications. – 2017. – №9. – P. 187–205. – Режим доступа до ресурсу: <https://www.sciencedirect.com/science/article/pii/S0957417417302750>.

16. Deep learning for event-driven stock prediction [Электронный ресурс] / X.Ding, Y. Zhang, T. Liu, J. Duan // Proc. IJCAI. – 2015. – Режим доступа до ресурсу: <https://www.ijcai.org/Proceedings/15/Papers/329.pdf>.
17. DeVries P. An Analysis of Cryptocurrency, Bitcoin, and the Future [Электронный ресурс] / Peter D. DeVries // International Journal of Business Management and Commerce. – 2016. – Режим доступа до ресурсу: <https://www.researchgate.net/publication/316656878>.
18. Ding S. Extreme learning machine: algorithm, theory and applications [Электронный ресурс] / S. Ding, X. Xu, N. Ru // Artificial Intelligence Review. – 2013. – Режим доступа до ресурсу: https://www.researchgate.net/publication/257512921_Extreme_learning_machine_algorithm_theory_and_applications.
19. Eom Y. Premium and speculative trading in bitcoin [Электронный ресурс] / Eom // Finance Research Letters. – 2020. – Режим доступа до ресурсу: <https://www.sciencedirect.com/science/article/abs/pii/S1544612319301357?via%3Dihub>.
20. Goodfellow I. Deep Learning [Электронный ресурс] / I. Goodfellow, Y. Bengio, A. Courville. – 2016. – Режим доступа до ресурсу: <https://github.com/janishar/mit-deep-learning-book-pdf/blob/master/complete-book-pdf/deeplearningbook.pdf>.
21. Gradient Flow in Recurrent Nets: the Difficulty of Learning Long-Term Dependencies [Электронный ресурс] / S.Hochreiter, Y. Bengio, P. Frasconi, J. Schmidhuber. – 2001. – Режим доступа до ресурсу: <https://www.bioinf.jku.at/publications/older/ch7.pdf>.
22. Gurney K. An introduction to neural networks [Электронный ресурс] / Kevin Gurney. – 1997. – Режим доступа до ресурсу: https://www.inf.ed.ac.uk/teaching/courses/nlu/assets/reading/Gurney_et_al.pdf.
23. Hamayel M. A Novel Cryptocurrency Price Prediction Model Using GRU, LSTM and bi-LSTM Machine Learning Algorithms [Электронный ресурс] / M.

- Hamayel, A. Owda // AI. – 2021. – Режим доступа до ресурсу: <https://www.mdpi.com/2673-2688/2/4/30/pdf>.
24. Hochreiter S. Long Short-Term Memory [Электронный ресурс] / S. Hochreiter, J. Schmidhuber // Neural Computation. – 1997. – №9. – P. 1735 – 1780. – Режим доступа до ресурсу: <https://www.bioinf.jku.at/publications/older/2604.pdf>.
 25. Hossin A. Bitcoin: Future Transaction Currency? [Электронный ресурс] / A. Hossin, S. Hosain. – 2018. – Режим доступа до ресурсу: https://www.researchgate.net/publication/327571604_Bitcoin_Future_Transaction_Currency.
 26. Huang G. Extreme learning machine: Theory and applications [Электронный ресурс] / G. Huang, Q. Zhu, C. Siew // Neurocomputing. – 2006. – P. 489 – 501 – Режим доступа до ресурсу <http://axon.cs.byu.edu/~martinez/classes/678/Presentations/Yao.pdf>.
 27. Huang W. Forecasting stock market movement direction with support vector machine / W. Huang, Y. Nakamori, S. Wang // Computers & Operations Research – 2005. – №10. – P. 2513 – 2522.
 28. Jana R. Did Bitcoin act as an antidote to the Chinese equity market and booster to Altcoins during the Novel Coronavirus outbreak? [Электронный ресурс] / R. Jana, D. Das. – 2020. – Режим доступа до ресурсу: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3544794.
 29. Jang J. ANFIS: adaptive-network-based fuzzy inference system [Электронный ресурс] / J.-S.R. Jang // IEEE Transactions on Systems, Man, and Cybernetics. – 1993. – Режим доступа до ресурсу: <https://www.dca.ufrn.br/~meneghet/FTP/anfis%2093.pdf>.
 30. Jaquart P. Short-term bitcoin market prediction via machine learning [Электронный ресурс] / P. Jaquart, D. Dann, C. Weinhardt // The Journal of Finance and Data Science. – 2021. – Режим доступа до ресурсу: <https://www.sciencedirect.com/science/article/pii/S2405918821000027/pdf?m>

d5=8bac118dd52338dfd870414cd58f1c7b&pid=1-s2.0-S2405918821000027-main.pdf.

31. Karame G. Double-Spending Fast Payments in Bitcoin [Електронний ресурс] / G. Karame, E. Androulaki, S. Capkun. – 2012. – Режим доступу до ресурсу: <https://www.eecis.udel.edu/~ruizhang/CISC859/S17/Paper/p9.pdf>.
32. Liashenko O. Neural Networks in Application to Cryptocurrency Exchange Modeling / O. Liashenko, T. Kravets, Y. Repetskyi // Proceedings of the International Conference on Information Technology and Interactions (IT&I-2020), December 02-03,2020. – Kyiv, 2021. CEUR Workshop Proceedings. – Vol. 2845. P. 350 – 360.
33. Looking for a safe-haven in a crisis-driven Venezuela: The Caracas stock exchange vs gold, oil and bitcoin [Електронний ресурс] / I.Musiakowska, A. Kliber, K. Świerczyńska, P. Marszałek // Transforming Government People Process and Policy. – 2020. – Режим доступу до ресурсу: www.emerald.com/insight/content/doi/10.1108/TG-01-2020-0009/full/html.
34. LSTM: A Search Space Odyssey [Електронний ресурс] / [K. Greff, R. Srivastava, J. Koutnik та ін.]. – 2017. – Режим доступу до ресурсу: <https://arxiv.org/pdf/1503.04069.pdf>.
35. Michankow J. LSTM in Algorithmic Investment Strategies on BTC and S&P500 Index [Електронний ресурс] / J. Michankow, P. Sakowski, R. Slepaczuk // sensors. – 2022. – Режим доступу до ресурсу: <https://www.mdpi.com/1424-8220/22/3/917/pdf>.
36. Modeling of nonlinear system based on deep learning framework / [X. Jin, J. Shao, X. Zhang, et al.] // Nonlinear Dynamics – 2016. – №3. – P. 1327 – 1340.
37. Nakamoto S. Bitcoin: A Peer-to-Peer Electronic Cash System [Електронний ресурс] / Satoshi Nakamoto. – 2008. – Режим доступу до ресурсу: <https://bitcoin.org/bitcoin.pdf>.

38. Nielsen M. Neural Networks and Deep Learning [Електронний ресурс] / Michael Nielsen. – 2015. – Режим доступу до ресурсу: <http://neuralnetworksanddeeplearning.com/>.
39. Olah C. Understanding LSTM Networks [Електронний ресурс] / Chris Olah. – 2016. – Режим доступу до ресурсу: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
40. Optimizing radial basis function neural network based on rough sets and affinity propagation clustering algorithm [Електронний ресурс] / X. Xu, S. Ding, Z. Shi, H. Zhu // Journal of Zhejiang University-SCIENCE C (Computers & Electronics). – 2012. – №2. – P. 131 – 138. – Режим доступу до ресурсу: <http://iip.ict.ac.cn/sites/default/files/publication/Optimizing%20radial%20basis%20function%20neural%20network%20based%20on%20rough%20sets%20and%20affinity%20propagation%20clustering%20algorithm.pdf>.
41. Penrose R. A generalized inverse for matrices [Електронний ресурс] / R. Penrose. – 1954. – Режим доступу до ресурсу: <https://www.cambridge.org/core/services/aop-cambridge-core/content/view/S0305004100030401>.
42. Schmidhuber J. Deep Learning in Neural Networks: An Overview [Електронний ресурс] / Jurgen Schmidhuber. – 2014. – Режим доступу до ресурсу: <https://arxiv.org/pdf/1404.7828v4.pdf>.
43. Techniques for Learning and Tuning Fuzzy Rule-Based Systems for Linguistic Modeling and their Application [Електронний ресурс] / [R. Alcala, J. Casillas, O. Cordon та ін.]. – 2014. – Режим доступу до ресурсу: https://www.researchgate.net/publication/239667434_Techniques_for_Learning_and_Tuning_Fuzzy_Rule-Based_Systems_for_Linguistic_Modeling.
44. Training ANFIS system with de algorithm [Електронний ресурс] / A.Zangeneh, M. Mansouri, M. Teshnehlal, A. Sedigh // 2011 – Режим доступу до ресурсу: https://www.researchgate.net/publication/239667434_Techniques_for_Learning_and_Tuning_Fuzzy_Rule-Based_Systems_for_Linguistic_Modeling_and_their_Application_E.

45. Using Radial Basis Function Networks for Function Approximation and Classification [Электронный ресурс] / Y.Wu, H. Wang, B. Zhang, K. Du. – 2012. – Режим доступа до ресурсу: <https://www.hindawi.com/journals/isrn/2012/324194/>.
46. Which Artificial Intelligence Algorithm Better Predicts the Chinese Stock Market? [Электронный ресурс] / [L. Chen, Z. Qiao, M. Wang et al.]. – 2018. – Режим доступа до ресурсу: https://www.researchgate.net/publication/326616105_Which_artificial_intelligence_algorithm_better_predicts_the_Chinese_stock_market.
47. Wicht B. DLL: A Fast Deep Neural Network Library [Электронный ресурс] / B. Wicht, A. Fischer, J. Hennebert. – 2018. – Режим доступа до ресурсу: https://www.researchgate.net/publication/327313654_DLL_A_Fast_Deep_Neural_Network_Library_8th_IAPR_TC3_Workshop_ANNPR_2018_Siena_Italy_September_19-21_2018_Proceedings.
48. Yermack D. Is Bitcoin a Real Currency? An Economic Appraisal [Электронный ресурс] / Yermack // National Bureau of Economic Research. – 2013. – Режим доступа до ресурсу: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2370203.
49. Zeng T. Fancy Bitcoin and conventional financial assets: Measuring market integration based on connectedness networks [Электронный ресурс] / T. Zeng, M. Yang, Y. Shen // Economic Modelling. – 2020. – Режим доступа до ресурсу: <https://www.sciencedirect.com/science/article/abs/pii/S0264999319320231?via%3Dihub>.

ДОДАТКИ

Додаток А

```

import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
btc_training_complete = pd.read_csv(r"C:\btc.csv")
btc_training_processed = btc_training_complete.iloc[0:10000, 3:4].values
from sklearn.preprocessing import MinMaxScaler
scaler = MinMaxScaler(feature_range = (0, 1))
btc_training_scaled = scaler.fit_transform(btc_training_processed)
btc_training_scaled
features_set = []
labels = []
for i in range(5, 10000):
    features_set.append(btc_training_scaled[i-5:i, 0])
    labels.append(btc_training_scaled[i, 0])
features_set, labels = np.array(features_set), np.array(labels)
features_set = np.reshape(features_set, (features_set.shape[0], features_set.shape[1],
1))
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from keras.layers import Dropout
model = Sequential()
model.add(LSTM(units=50))
model.add(Dense(units = 1))
model.compile(optimizer = 'adam', loss = 'mean_squared_error')
model.fit(features_set, labels, epochs = 150, batch_size = 100)
btc_testing_complete = pd.read_csv(r"C:\btc.csv")

```

```
btc_testing_processed = btc_testing_complete.iloc[0:10000, 3:4].values
btc_total = pd.concat((btc_training_complete['Open'][0:],
btc_testing_complete['Open']), axis=0)
test_inputs = btc_total[len(btc_training_processed)-1:].values
test_inputs = test_inputs.reshape(-1,1)
test_inputs = scaler.transform(test_inputs)
test_features = []
for i in range(5, 1001):
    test_features.append(test_inputs[i-5:i, 0])
test_features = np.array(test_features)
print(test_features.shape[0], test_features.shape[1])
test_features = np.reshape(test_features, (test_features.shape[0],
test_features.shape[1], 1))
predictions = model.predict(test_features)
predictions = scaler.inverse_transform(predictions)
```

Додаток Б

```
library(RSNNS)
library(DMwR)
btc_data = read.csv("C:/btc.csv")
btc_data=btc_data[,4]
btc_data=scale(btc_data)
predictions_rbf= 1:1000
actual_rbf= 1:1000
data.train_1 = matrix(btc_data[1:9995])
data.train_2 = matrix(btc_data[2:9996])
data.train_3 = matrix(btc_data[3:9997])
data.train_4 = matrix(btc_data[4:9998])
data.train_5 = matrix(btc_data[5:9999])
x_train = cbindX(data.train_1, data.train_2, data.train_3, data.train_4, data.train_5)
y_train = matrix(btc_data[6:10000])
rbf = rbf(x_train, y_train, size = c(50), maxit=150)
for(j in 1:1000) {
  newdata_1 = matrix(btc_data[9995+j])
  newdata_2 = matrix(btc_data[9996+j])
  newdata_3 = matrix(btc_data[9997+j])
  newdata_4 = matrix(btc_data[9998+j])
  newdata_5 = matrix(btc_data[9999+j])
  newdata = cbindX(newdata_1, newdata_2, newdata_3, newdata_4, newdata_5)
  predictions_rbf[j] = unscale(predict(rbf, newdata, btc_data)
}
```

Додаток В

```
library(nnfor)
btc_data = read.csv("C:/btc.csv")
elm = elm(ts(btc_data[1:10000,4]), hd=c(50))
predictions_elm= (1:1000)
for (i in 1:1000) {
  l = 9995+i
  u = 9999+i
  test_feature = ts(btc_data[l:u,4])
  predictions_elm[i] = as.numeric(forecast(elm, y = test_feature, h = 1)[[2]][1])
}
```

Додаток Г

```

library(DMwR)
library(deepnet)
btc_data = read.csv("C:/btc.csv")
predictions_bp = (1:1000)
btc_data=scale(btc_data[,4])
data.train_1 = matrix(btc_data[1:9995])
data.train_2 = matrix(btc_data[2:9996])
data.train_3 = matrix(btc_data[3:9997])
data.train_4 = matrix(btc_data[4:9998])
data.train_5 = matrix(btc_data[5:9999])
x_train = cbindX(data.train_1, data.train_2, data.train_3, data.train_4, data.train_5)
y_train = matrix(btc_data[6:10000])
bp = nn.train(x=x_train, y=y_train, hidden = c(50), numepochs = 150, batchsize = 50,
output = "linear")
newdata_1 = matrix(btc_data[9996:10995])
newdata_2 = matrix(btc_data[9997:10996])
newdata_3 = matrix(btc_data[9998:10997])
newdata_4 = matrix(btc_data[9999:10998])
newdata_5 = matrix(btc_data[10000:10999])
newdata = cbindX(newdata_1, newdata_2, newdata_3, newdata_4, newdata_5)
predictions = nn.predict(bp, x = newdata)
for (j in 1:1000) {
  predictions_bp[j] = unscale(predictions[j],btc_data)
}

```

Додаток Д

```

btc_data = read.csv("C:/btc.csv")

predictions = (1:1000)
actual = (1:1000)
for (i in 0:4) {
  print(i)
  data.train_1 = matrix(btc_data[(1+2000*i):(1995+2000*i),4])
  data.train_2 = matrix(btc_data[(2+2000*i):(1996+2000*i),4])
  data.train_3 = matrix(btc_data[(3+2000*i):(1997+2000*i),4])
  data.train_4 = matrix(btc_data[(4+2000*i):(1998+2000*i),4])
  data.train_5 = matrix(btc_data[(5+2000*i):(1999+2000*i),4])
  data.train_6 = matrix(btc_data[(6+2000*i):(2000+2000*i),4])
  data.train = cbindX(data.train_1, data.train_2, data.train_3, data.train_4, data.train_5,
data.train_6)
  min_data = min(btc_data[1:11000,4])
  max_data = max(btc_data[1:11000,4])
  range.data<-matrix(rep(c(min_data,max_data),3), ncol=3, byrow = FALSE)
  control.ANFIS <- list(num.labels = 20, max.iter = 150, step.size = 0.01, type.tnorm =
"MIN", type.implication.func = "ZADEH", name = "Sim-0")
  method.type <- "ANFIS"
  model <- frbs.learn(data.train, range.data, method.type, control.ANFIS)
  newdata_1 = matrix(btc_data[(1996+2000*i):(2195+2000*i),4])
  newdata_2 = matrix(btc_data[(2007+2000*i):(2196+2000*i),4])
  newdata_3 = matrix(btc_data[(1998+2000*i):(2197+2000*i),4])
  newdata_4 = matrix(btc_data[(1999+2000*i):(2198+2000*i),4])
  newdata_5 = matrix(btc_data[(2000+2000*i):(2199+2000*i),4])
  newdata = cbindX(newdata_1, newdata_2, newdata_3, newdata_4, newdata_5)
  current_predictions = predict(model, newdata)

```

```
for (j in 1:length(current_predictions)) {  
  predictions[j+i*200] = current_predictions[j]  
}  
}
```

Київський національний університет імені Тараса Шевченка

Економічний факультет

Кафедра економічної кібернетики

ЗАВДАННЯ

на кваліфікаційну роботу магістра


студента 2 курсу магістратури спеціальності 051 «Економіка», ОНП

«Економічна кібернетика»

Репецького Євгенія Олеговича

1. Тема роботи: Моделювання курсу біткоіна за допомогою нейронних мереж, що використовують алгоритми штучного інтелекту.
2. Термін завершення роботи: 14 квітня 2022 року.
3. Об'єкт дослідження: ринок криптовалюти біткоін.
4. Предмет дослідження: моделювання ціни біткоіна за допомогою нейронних мереж, що використовують алгоритми штучного інтелекту.
5. Мета дослідження: порівняти прогностичні можливості досліджуваних нейронних мереж та визначити, який з алгоритмів з штучного інтелекту є найкращим для моделювання ціни відкриття біткоіна.
6. Завдання дослідження:
 - 6.1. дослідження складових елементів криптовалют та технологій їх функціонування;
 - 6.2. аналіз статистичних даних;
 - 6.3. дослідження архітектури штучних нейронних мереж та алгоритмів штучного інтелекту;
 - 6.4. визначення найкращого алгоритму для моделювання ціни біткоіна.

Науковий керівник: к.ф.-м.н., доцент Кравець Тетяна Вікторівна

Студент: Репецький Євгеній Олегович _____ 

(підпис)

Затверджено на засіданні кафедри економічної кібернетики
протокол № 3 від 12 жовтня 2021 р.

Календарний план виконання кваліфікаційної роботи магістра

Завдання за планом	Термін виконання	Відмітка керівника про виконання
1. Вибір теми кваліфікаційної роботи магістра.	01.09.2021-15.09.2021	
2. Розробка та затвердження завдання кваліфікаційної роботи магістра.	16.09.2021-24.09.2021	
3. Ознайомлення з науково-інформаційними джерелами за обраним напрямом досліджень, виявлення наукової проблематики.	25.09.2021 - 25.11.2021	
4. Представлення обґрунтування актуальності, мети, завдання, предмету та об'єкту дослідження, I розділу роботи науковому керівникові.	26.11.2021-11.01.2022	
5. Представлення II розділу роботи науковому керівникові.	12.01.2022-11.02.2022	
6. Представлення III розділу роботи науковому керівникові.	12.02.2022-11.04.2022	
7. Оформлення магістерської роботи згідно з вимогами.	12.04.2022-30.04.2022	
8. Доопрацювання та усунення зауважень наукового керівника.	01.05.2022-10.05.2022	
9. Підготовка та отримання документів (відгук керівника, довідка про унікальність).	11.05.2022-19.05.2022	
10. Подання роботи в електронному вигляді.	20.05.2022	
11. Підготовка презентації та захист роботи в ДЕК.	21.05.2022-25.05.2022	

Науковий керівник: к.ф.-м.н., доцент Кравець Тетяна Вікторівна

Студент: Репецький Євгеній Олегович