

ЛУТЮК ЛЕВ

Хмельницький національний університет

<https://orcid.org/0009-0004-7497-3427>e-mail: lev_lutiuk@ukr.net

ГНАТЧУК ЄЛИЗАВЕТА

Хмельницький національний університет

<https://orcid.org/0000-0003-2989-3183>e-mail: liza_veta@ukr.net

ПОНОЧОВНА ОЛЕНА

Полтавський державний аграрний університет

<https://orcid.org/0000-0002-4377-0633>e-mail: olena.ponochovna@pdau.edu.ua

ІНФОРМАЦІЙНІ ТЕХНОЛОГІЇ ПРОГНОЗУВАННЯ ФІНАНСОВИХ РИНКІВ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ

Прогнозування фінансових ринків давно стало однією з найважливіших задач для інвесторів та трейдерів. Динамічність та складність ринків, численні фактори впливу, такі як економічні новини, геополітичні події та поведінкові аспекти учасників ринку, роблять цю сферу надзвичайно складною для аналізу за допомогою традиційних методів. З появою технологій штучного інтелекту, а саме нейронних мереж, з'явилася можливість ефективніше аналізувати великі обсяги даних і знаходити приховані закономірності, які неможливо виявити іншими способами.

Нейронні мережі стали однією з ключових технологій у сучасному фінансовому аналізі завдяки їхній здатності обробляти нелінійні залежності та працювати з великими наборами даних. Ці моделі імітують роботу людського мозку, що дозволяє їм виявляти навіть найскладніші взаємозв'язки у фінансових часових рядах, таких як зміни цін активів, коливання валютних курсів чи аналіз ринкових ризиків. Завдяки гнучкості, адаптивності та можливості самооптимізації, нейронні мережі стали надійним інструментом для передбачення ринкових трендів.

У цій статті розглянуто, як нейронні мережі застосовуються для прогнозування фінансових ринків, які типи архітектур найбільш ефективні для фінансового аналізу, та з якими викликами стикаються дослідники та практики під час їх впровадження. Нейронні мережі подано як основу для розроблення інформаційних технологій прогнозування фінансових ринків.

Ключові слова: інформаційні технології, нейронні мережі, фінансові часові ряди, проблема відставання, гібридні моделі, нейронні мовні моделі.

LUTIUK LEV, HNATCHUK YELYZAVETA

Khmelnitskyi National University

PONOCHOVNA OLENA

Poltava State Agrarian University

INFORMATION TECHNOLOGIES FOR FORECASTING FINANCIAL MARKETS WITH NEURAL NETWORKS

Forecasting financial markets has long been one of the most important tasks for investors and traders. The dynamism and complexity of markets, numerous influencing factors such as economic news, geopolitical events and behavioral aspects of market participants, make this area extremely difficult to analyze using traditional methods. With the advent of artificial intelligence technologies, namely neural networks, it has become possible to more effectively analyze large volumes of data and find hidden patterns that cannot be detected by other methods.

Neural networks have become one of the key technologies in modern financial analysis due to their ability to process nonlinear dependencies and work with large data sets. These models imitate the work of the human brain, which allows them to detect even the most complex relationships in financial time series, such as changes in asset prices, currency fluctuations or market risk analysis. Different types of architectures, such as recurrent neural networks, convolutional neural networks, temporal convolutional models, and transformers, allow for efficient solutions to time series analysis, pattern detection, and textual information analysis. In particular, recurrent networks, such as LSTM and GRU, are effective for modeling long-term dependencies, while CNNs can detect local patterns in price charts. Transformers and language models, such as GPT and BERT, provide the ability to process textual information, which allows for news analysis and market impact assessment. Due to their flexibility, adaptability and ability to self-optimize, neural networks have become a reliable tool for predicting market trends.

In this article, we will take a detailed look at how neural networks are used to predict financial markets, what types of architectures are most effective for financial analysis, and what challenges researchers and practitioners face when implementing them.

Keywords: neural networks, financial time series, lag problem, hybrid models, neural language models.

Постановка проблеми

Прогнозування фінансових ринків є складною задачею через низку факторів, які впливають на їх поведінку. Основна проблема полягає у високій волатильності ринків, що спричиняється численними економічними, політичними та соціальними чинниками. Крім того, ринки є нелінійними системами, де взаємозв'язки між змінними часто приховані та складно піддаються аналізу традиційними статистичними методами.

Існують наступні ключові виклики при прогнозуванні фінансових ринків:

- Нелінійність та хаотичність даних. Ціни активів можуть змінюватися під впливом багатьох факторів, включаючи новини, настрої інвесторів, макроекономічні події та навіть погодні умови. Це ускладнює побудову моделей, які точно відображають ці залежності.

- Шум у даних. Фінансові дані містять багато шуму, який може приховувати корисні сигнали. Наприклад, короткострокові коливання цін можуть бути випадковими та не мати значущих причин.

- Високий рівень складності. Фінансові ринки є складними системами, в яких взаємодіють численні учасники, кожен з яких може мати різні стратегії, мотиви та реакції на одні й ті ж самі події.
- Часова залежність. Для точного прогнозування необхідно враховувати часові залежності даних, такі як тенденції, сезонність або довгострокові закономірності.
- Ризик перенавчання. Моделі, що добре працюють на історичних даних, можуть виявитися неефективними для прогнозування нових даних через зміну ринкових умов або недостатню генералізацію.

Рішення цих проблем вимагає застосування сучасних підходів і технологій, таких як нейронні мережі, які здатні аналізувати великі обсяги даних, знаходити приховані взаємозв'язки та адаптуватися до змінних умов ринку.

Аналіз досліджень та публікацій

Дослідження [1-3] знайомлять із використанням машинного навчання у сфері фінансового прогнозування, планування та аналізу (FP&A). Завдяки здатності автоматично обробляти великі обсяги даних, машинне навчання стає незамінним інструментом для вдосконалення FP&A. Однак класичні підходи до машинного навчання переважно орієнтовані на прогнозування, що вимагає особливої ретельності у їх застосуванні для задач, пов'язаних із плануванням і розподілом ресурсів, аби уникнути можливих недоліків. Хоча стандартні алгоритми часто виявляються неефективними, новітня методика подвійного машинного навчання здатна розв'язувати важливі причинно-наслідкові задачі. У статтях [4,5] детально розглядається сучасний стан досліджень нейронних мереж, а також аналізується їх роль у прогнозуванні фінансових ринків та оптимізації інвестиційних портфелів.

Прогнозування фінансових часових рядів із високою точністю має велике значення для успішної роботи фінансових ринків. Водночас для часових рядів із незначними коливаннями виникає нетипове явище: прогнозовані значення часто виявляються запізненими порівняно з реальними даними. Це явище ми визначаємо як проблему відставання. Дослідження [6,7] пропонує нові заходи для вирішення проблеми відставання. Експериментальні результати показують, що всі популярні рекурентні моделі мереж страждають від проблеми затримки. Ця проблема спричинена невдачею нелінійної функції в моделі прогнозування та подальшим лінійним виродженням моделі прогнозування, що призводить до придушення здатності нелінійної підгонки.

Фінансова індустрія швидко розвивається. Зокрема, значну увагу приділено прогнозуванню прибутковості акцій. Вибір найбільш багатообіцяючої моделі для прогнозування прибутковості акцій завжди був важливим завданням у літературі [8]. Кілька досліджень [9-11] повідомили про здатність прогнозувати моделі рекурентних нейронних мереж (RNN), тоді як лише кілька досліджень [12,13] ретельно оцінювали ефективність прогнозування часових згорткових мереж (TCN) для налаштувань прогнозування доходності акцій. Крім того, незважаючи на те, що більшість досліджень зосереджено на порівнянні продуктивності моделей глибокого навчання при прогнозуванні з одним горизонтом, багатогоризонтне прогнозування доходності акцій вивчалось лише обмежено [14-17]. У цьому дослідженні ми прагнемо оцінити ефективність прогнозування найсучасніших моделей глибокого навчання на багатогоризонтних шляхах прогнозування в задачах прогнозування доходності акцій. Зокрема, ми розглянемо TCN, RNN, LSTM, гібридні моделі та нейронні мовні моделі з точки зору ефективності прогнозування та їх специфіки.

Метою роботи є систематизація основних видів нейронних мереж, що використовуються у фінансовому прогнозуванні, виявлення їх сильних сторін та обґрунтування їх використання при розробленні інформаційних технологій, а також розкриття основних принципів їх роботи.

Виклад основного матеріалу

Нейронні мережі — це математичні моделі, створені за аналогією з принципами функціонування біологічного мозку, які знаходять застосування у вирішенні широкого спектра завдань. Вони складаються з великої кількості взаємопов'язаних штучних нейронів, організованих у шари. Кожен нейрон приймає на вхід дані, обробляє їх, використовуючи вагові коефіцієнти та функцію активації, і передає результат до наступного рівня. Така архітектура дозволяє знаходити складні нелінійні залежності у даних, які традиційні статистичні методи можуть не виявити. Завдяки сучасним обчислювальним потужностям, нейронні мережі здатні обробляти великі обсяги даних у реальному часі. Це особливо важливо для задач, які потребують швидкого реагування, наприклад, у сфері фінансових ринків. Крім того, якщо модель регулярно навчати на оновлених даних, вона може динамічно адаптуватися до змін умов, наприклад, до нових ринкових трендів чи поведінкових змін учасників фондового ринку.

Проте, попри значні переваги, використання нейронних мереж супроводжується низкою викликів та обмежень. Одним із головних є висока обчислювальна складність, яка залежить від розміру моделі, кількості даних і складності завдання. Це потребує значних обчислювальних ресурсів та енергозатрат. Ризик перенавчання та складність інтерпретації результатів також залишаються актуальними питаннями які вимагають подальших досліджень та вдосконалення методів роботи.

Для прогнозування фінансових ринків за допомогою нейронних мереж використовуються різні типи архітектур залежно від задачі, характеру даних та необхідного рівня точності. Серед основних типів мереж, що використовуються в даній сфері можна виділити - рекурентні нейронні мережі (RNN), конволюційні нейронні мережі (CNN), гібридні моделі, тимчасові згорткові мережі (TCN) та нейронні мовні моделі. Кожна з цих архітектур має свої переваги й обмеження, тому вибір залежить від специфіки завдання, доступних даних і технічних вимог.

Рекурентні нейронні мережі (RNN) спеціалізуються на аналізі часових рядів, що робить їх особливо ефективними для роботи з фінансовими ринками. Оскільки фінансові дані зазвичай мають послідовний характер, де поточні зміни залежать від попередніх, рекурентні мережі можуть враховувати цю часову залежність і використовувати її для прогнозування майбутніх значень. Зокрема, вони є ідеальним інструментом для аналізу таких фінансових індикаторів, як ціни акцій, валютні курси, індекси та обсяги торгів, оскільки можуть моделювати динаміку змін у часі. Основною особливістю рекурентних нейронних мереж є здатність до обробки послідовних даних, при цьому кожен нейрон на виході залежить не лише від поточного вхідного сигналу, але й від попередніх станів. Це дозволяє мережам моделювати складні залежності і виявляти тренди, що розвиваються з часом. Проте стандартні RNN мають обмеження, пов'язані з затуханням градієнта, що ускладнює навчання моделей на довгих послідовностях, де важливо враховувати залежності на великих відрізках часу. Для подолання цієї проблеми були розроблені LSTM (Long Short-Term Memory) та GRU (Gated Recurrent Unit) — розширення рекурентних мереж, які значно покращують їх здатність зберігати інформацію про довгострокові залежності.

Основною проблемою рекурентних нейромереж у прогнозуванні фінансових ринків є проблема відставання. Вона виникає, коли прогнозне значення моделі відстає від істинного значення на певному часовому відрізку. Це означає, що рекурентні нейронні мережі (RNN) або інші моделі, які використовуються для прогнозування фінансових даних, не можуть точно відобразити зміни в ринкових умовах у реальному часі. Це явище особливо очевидне на ринках, де відбуваються маленькі коливання або незначні зміни цін, що може призвести до того, що модель не встигає реагувати на ці зміни вчасно. Одна з основних причин проблеми відставання полягає в тому, що рекурентні нейронні мережі не завжди здатні швидко адаптуватися до нових умов, особливо коли зміни на ринку є поступовими або незначними. У таких умовах модель може не виявляти важливі сигнали в даних, що призводить до затримок у прогнозах. Це може статися через обмежену пам'ять мережі, яка не завжди в змозі зберігати достатньо інформації про минулі події або короткострокові коливання. Проблема відставання може серйозно вплинути на точність фінансових прогнозів, оскільки трейдери та інвестори часто покладаються на реальний час для прийняття рішень. Якщо модель не може точно передбачити короткострокові зміни або упускає важливі сигнали, то це може призвести до неправильних торгових рішень, що в свою чергу може викликати збитки на ринку. Для моделей, які використовуються в високочастотному трейдингу або для швидких транзакцій, це може бути особливо критичним.

Для зменшення або усунення проблеми відставання важливо використовувати стратегії вдосконалення моделей. Наприклад, можна застосовувати гібридні моделі, що поєднують рекурентні нейронні мережі з іншими архітектурами, такими як конволюційні нейронні мережі (CNN) або тимчасові згорткові мережі (TCN), які можуть швидше реагувати на короткострокові зміни в даних. Також важливо використовувати більш потужні методи оптимізації, такі як адаптивні алгоритми навчання, щоб гарантувати швидке оновлення вагів мережі при незначних змінах у часових рядах. Також може бути корисним використання моделей, які дозволяють якісно передбачати короткострокові коливання ринку, наприклад, моделі на основі трансформерів або моделі з механізмами уваги, які можуть зберігати більше контексту з попередніх періодів і більш точно реагувати на зміни в даних. Зокрема, моделі на основі самоуваги (self-attention), як у трансформерах, дозволяють моделі більш ефективно зважати на важливі моменти з історії часового ряду, що допомагає зменшити затримку в прогнозах.

LSTM може ефективно моделювати складні тимчасові залежності, що зберігаються протягом тривалого періоду часу, що особливо корисно для аналізу довгострокових трендів на фінансових ринках. Наприклад, LSTM підходить для прогнозування змін на ринку акцій або валют на кілька місяців або років вперед, оскільки здатна враховувати далекі кореляції між подіями, що сталися в минулому. Це робить LSTM особливо корисними для інвестиційних стратегій, орієнтованих на довгостроковий період. GRU (Gated Recurrent Unit) є спрощеною альтернативою LSTM, яка також покращує обробку довгострокових залежностей, але з меншими обчислювальними витратами. Це дозволяє значно знизити складність моделі, що робить GRU швидшими для навчання та менш вимогливими до обчислювальних ресурсів порівняно з LSTM. Завдяки своїй простоті GRU дуже добре підходять для задач, де необхідно балансувати між ефективністю та витратами на обчислювання.

Конволюційні нейронні мережі (CNN) традиційно використовуються в задачах, що пов'язані з обробкою зображень, таких як розпізнавання об'єктів, класифікація та сегментація зображень. Однак, завдяки своїй здатності виявляти локальні патерни і шаблони, у фінансовому контексті CNN можуть бути використані для виявлення закономірних шаблонів у графіках цін акцій або валют, що відображаються у вигляді різноманітних чартів (лінійних графіків, свічкових графіків тощо). Такі патерни можуть включати як короткострокові тенденції (наприклад, тренди за день чи тиждень), так і більш складні закономірності, що виникають через взаємодію різних ринкових факторів. Перевага CNN полягає в їх здатності ефективно обробляти просторову інформацію, що дозволяє їм виявляти локальні патерни в даних, навіть якщо вони не очевидні на перший погляд. Наприклад, при роботі з графіками цін акцій CNN можуть виявляти такі візуальні патерни, як "голова і плечі", "подвійне дно" або "висхідні/низхідні канали", які є важливими для трейдерів та інвесторів, оскільки ці патерни часто сигналізують про можливі зміни тренду. Використання CNN для прогнозування фінансових ринків може забезпечити виявлення таких патернів на різних часових інтервалах, що дозволяє робити більш точні прогнози про майбутнє напрямку ринку. Ще однією важливою особливістю CNN є їх здатність до **перевірки та виділення** найбільш значущих характеристик з великих обсягів даних,

що дозволяє зменшити обсяг вхідної інформації перед подальшою обробкою. Це особливо корисно при роботі з фінансовими ринками, де дані часто мають високу варіативність і шумність. Мережі можуть фокусуватися лише на найбільш важливих паттернах, ігноруючи менш значущі коливання цін, що дозволяє підвищити точність прогнозів.

Конволюційні нейронні мережі можуть бути також ефективні у поєднанні з іншими методами аналізу, такими як **рекурентні нейронні мережі (RNN)** або **LSTM**, для побудови гібридних моделей, які спочатку використовують CNN для виявлення локальних паттернів, а потім передають отримані ознаки до рекурентних мереж для аналізу більш глобальних трендів та залежностей у часі.

Гібридні моделі нейронних мереж є потужним інструментом, що поєднують кілька різних архітектур для досягнення кращих результатів у вирішенні складних задач. Такі моделі дозволяють комбінувати сильні сторони різних типів нейронних мереж, що дозволяє адаптувати підхід до специфічних вимог поставленої задачі. Одним з прикладів таких гібридних моделей є поєднання RNN та CNN. Так, їх кооперація дозволяє вирішувати складніші задачі, де потрібно одночасно враховувати як просторові, так і часові патерни. Наприклад, в задачах прогнозування фінансових ринків, де важливо враховувати не тільки короткострокові закономірності у графіках цін, але й довгострокові тренди, що виникають на основі комплексних взаємодій між фундаментальними економічними факторами та історичними даними.

Тимчасові згорткові мережі (TCN) — це потужна архітектура, яка поєднує переваги традиційних згорткових нейронних мереж (CNN) з можливістю ефективного аналізу часових рядів. Завдяки цьому TCN стають ідеальним інструментом для задач прогнозування, де важливо враховувати як часові залежності, так і локальні патерни в даних, що змінюються в часі. Основною перевагою TCN є їх здатність моделювати складні часові залежності без типових обмежень традиційних рекурентних мереж. Однією з ключових відмінностей TCN від класичних рекурентних нейронних мереж (RNN) є використання розширених та каузальних згортки. Розширені згортки дозволяють зберігати просторову інформацію на різних рівнях часу, що покращує здатність мережі знаходити більш комплексні зв'язки в даних. Водночас, каузальні згортки забезпечують, що мережа використовує лише минулі значення для прогнозування поточних або майбутніх даних, що критично важливо для задач, де майбутнє не може залежати від майбутніх значень, як у випадку прогнозування на фінансових ринках. Традиційні рекурентні мережі можуть мати проблеми з обробкою довгих послідовностей через затухання градієнтів, що призводить до втрати важливої інформації з часом.

Нейронні мовні моделі стали важливим інструментом для аналізу текстових даних і набули широкого застосування у фінансових ринках завдяки своїй здатності ефективно обробляти великі обсяги текстової інформації. Ці моделі використовують архітектуру трансформерів, яка дозволяє враховувати контекст і взаємозв'язки в текстах на різних рівнях, що робить їх особливо корисними для аналізу новин, публікацій у соціальних мережах, фінансових звітів компаній та інших текстових джерел. Завдяки таким можливостям, мовні моделі можуть передбачати тенденції на фінансових ринках, аналізуючи текстову інформацію, що є важливою складовою для прийняття рішень. До основних типів нейронних мовних моделей відносяться GPT (Generative Pre-trained Transformer) та BERT (Bidirectional Encoder Representations from Transformers). GPT є генеративною моделлю, яка здатна створювати текст на основі попередньо навченої інформації. Вона часто використовується для генерування тексту, який може бути використаний для створення коротких викладок новин. BERT, на відміну від GPT, фокусується на двосторонньому (bidirectional) розумінні контексту, що дозволяє їй краще захоплювати взаємозв'язки між словами в тексті. Завдяки цьому BERT використовується для розв'язання задач, які потребують глибокого розуміння значення текстів, таких як класифікація настроїв у новинах або витягування ключової інформації з фінансових звітів. Моделі GPT та BERT можуть бути використані для оцінки тону публікацій — чи є вони позитивними, негативними або нейтральними. Це дає змогу виявляти реакцію ринку на новини, аналітичні статті чи публікації в соціальних мережах в реальному часі. Наприклад, при публікації оглядових аналітичних статей про ту чи іншу компанію, позитивний або негативний тон таких текстів може вказувати на ймовірні рухи цін акцій. Моделі можуть швидко аналізувати такі тексти і давати рекомендації для прийняття інвестиційних рішень. Для досягнення високої точності прогнозування, нейронні мовні моделі часто поєднуються з іншими типами моделей, такими як LSTM або CNN. В цьому випадку мовні моделі відповідають за аналіз текстових даних, в той час як LSTM або CNN можуть бути використані для обробки числових даних. Використання нейронних мовних моделей дозволяє здійснювати миттєвий аналіз інформації, що є особливо важливим для трейдерів, які займаються високочастотним трейдингом або хочуть швидко реагувати на новини. Зокрема, за допомогою таких моделей можна прогнозувати реакцію ринку на новини в перші секунди після їх публікації, що дає можливість здійснити вигідні транзакції до того, як ринок встигне адаптуватися до нової інформації.

Прогнозування з використанням нейронних мереж є багатоступеневим процесом, який включає кілька важливих етапів. Першим кроком є збір вхідних даних, які слугуватимуть основою для аналізу. Наприклад, у разі прогнозування фінансових ринків, вхідними даними можуть бути історичні ціни акцій за обраний період, обсяги торгів, макроекономічні індикатори (такі як облікова ставка, рівень безробіття, інфляція), новинні стрічки, інформація про компанії (наприклад, звіти про прибутки) та інші релевантні показники. Ці дані повинні бути достатньо повними та різноманітними, щоб модель змогла враховувати широкий спектр факторів, що впливають на ринок.

Другим етапом є попередня обробка даних, яка має критичне значення для коректної роботи нейронної мережі. Це включає видалення зайвої або нерелевантної інформації, оскільки деякі фактори,

наприклад короткострокові коливання цін, можуть не бути значущими для довгострокового прогнозування. Фінансові часові ряди часто є ненормалізованими, тому для покращення навчання нейронної мережі їх необхідно нормалізувати або стандартизувати. Окрім цього, доцільно зменшувати шум у даних, використовувати техніки згладжування або обчислювати нові показники, наприклад ковзаючі середні чи індекси. Основна обробка інформації здійснюється всередині самої моделі за допомогою функцій активації та вагових коефіцієнтів. Ваги нейронів налаштовуються під час навчання для виявлення значущих залежностей у даних.

На наступному етапі проводиться навчання моделі. Вхідні дані розділяються на кілька вибірок: навчальну, валідаційну та тестову. Навчальна вибірка використовується для налаштування параметрів моделі, валідаційна – для перевірки її узагальнювальної здатності, а тестова – для остаточної оцінки якості прогнозів. Під час навчання використовуються різні алгоритми оптимізації, найпопулярнішим з яких є градієнтний спуск. Метою є мінімізація функції втрат, яка вимірює помилку прогнозу. Для запобігання перенавчанню можуть застосовуватися такі техніки, як регуляризація або метод Dropout.

Після навчання модель проходить етап оцінки. Її точність перевіряється на тестовій вибірці за допомогою метрик оцінки якості, таких як середньоквадратична похибка, середня абсолютна похибка або коефіцієнт детермінації. Ці метрики дозволяють визначити, наскільки добре модель може узагальнювати інформацію та передбачати дані, що не входили до навчальної вибірки.

Останнім етапом є застосування моделі для прогнозування на нових даних. Це може включати передбачення майбутніх цін акцій, трендів ринку, оцінка ризиків або інших показників. У реальних умовах модель повинна періодично оновлюватися і перенавчатися, щоб враховувати останні зміни в ринкових реаліях і зберігати свою актуальність.

Висновки

Нейронні мережі є потужним інструментом аналізу та прогнозування, що дозволяє знаходити складні закономірності в даних, які часто не піддаються виявленню традиційними статистичними методами. Завдяки здатності обробляти великі обсяги інформації та адаптуватися до змін у даних, вони стали невід'ємною частиною сучасного прогнозування фінансових ринків. Різні типи архітектур, такі як рекурентні нейронні мережі, конволюційні нейронні мережі, тимчасові згорткові моделі та трансформери, дозволяють ефективно вирішувати задачі аналізу часових рядів, виявлення патернів у даних та аналізу текстової інформації. Зокрема, рекурентні мережі, зокрема LSTM та GRU, є ефективними для моделювання довгострокових залежностей, тоді як CNN можуть виявляти локальні патерни у графіках цін. Трансформери та мовні моделі, такі як GPT і BERT, забезпечують можливість обробки текстової інформації, що дозволяє аналізувати новини та оцінювати їхній вплив на ринок. Однак використання нейронних мереж супроводжується викликами, такими як висока обчислювальна складність, ризик перенавчання та складність інтерпретації результатів. Крім того, проблема відставання в прогнозах може впливати на точність моделей, особливо у високочастотному трейдингу. Для підвищення ефективності прогнозування важливо використовувати гібридні моделі, які комбінують сильні сторони різних підходів, а також впроваджувати сучасні методи оптимізації та адаптивного навчання.

Таким чином, нейронні мережі мають значний потенціал для покращення процесів прийняття рішень на фінансових ринках, але для досягнення найкращих результатів необхідно враховувати їхні обмеження та постійно вдосконалювати підходи до їхнього використання.

Література

1. Castilho, D., Souza, T.T., Kang, S.M., Gama, J. and de Carvalho, A.C., 2024. Forecasting financial market structure from network features using machine learning. *Knowledge and Information Systems*, pp.1-29.
2. Behera, S., Nayak, S.C. and Kumar, A.P., 2023. A comprehensive survey on higher order neural networks and evolutionary optimization learning algorithms in financial time series forecasting. *Archives of Computational Methods in Engineering*, 30(7), pp.4401-4448.
3. Zhang, D., Lin, R., Wei, T., Ling, L. and Huang, J., 2023. A novel deep transfer learning framework with adversarial domain adaptation: application to financial time-series forecasting. *Neural Computing and Applications*, 35(34), pp.24037-24054.
4. Gupta, A., Joshi, K., Patel, M. and Pratap, V., 2024. Visualization and forecasting of stock's closing price using machine learning. *Multimedia Tools and Applications*, pp.1-19.
5. Lin, R., Zhang, D., Ling, L., Huang, J. and Cai, G., 2022, November. Transfer Learning Based Long Short-Term Memory Network for Financial Time Series Forecasting. In *International Conference on Neural Information Processing* (pp. 3-13). Singapore: Springer Nature Singapore.
6. Pratas, T.E., Ramos, F.R. and Rubio, L., 2023. Forecasting bitcoin volatility: exploring the potential of deep learning. *Eurasian Economic Review*, 13(2), pp.285-305.
7. Li, J., Song, L., Wu, D., Shui, J. and Wang, T., 2023. Lagging problem in financial time series forecasting. *Neural Computing and Applications*, 35(28), pp.20819-20839.
8. Ben Ameer, H., Boubaker, S., Ftiti, Z., Louhichi, W. and Tissaoui, K., 2024. Forecasting commodity prices: empirical evidence using deep learning tools. *Annals of Operations Research*, 339(1), pp.349-367.
9. Kumar, B.R.A., Katiyar, S., Lingada, P., Mattaparathi, K., Krishna, R., Prakash, G., Vuppalahadham, D., Darapaneni, N. and Paduri, A.R., 2023, June. Evaluating the Performance of Diverse Machine Learning Approaches

in Stock Market Forecasting. In International Conference on Multi-disciplinary Trends in Artificial Intelligence (pp. 255-264). Cham: Springer Nature Switzerland.

10. Saleti, S., Panchumarthi, L.Y., Kallam, Y.R., Parchuri, L. and Jitte, S., 2024. Enhancing Forecasting Accuracy with a Moving Average-Integrated Hybrid ARIMA-LSTM Model. *SN Computer Science*, 5(6), p.704.

11. Yadav, A., Kumar, V., Singh, S. and Mishra, A.K., 2024. A Novel Approach for Forecasting Price of Stock Market using Machine Learning Techniques. *SN Computer Science*, 5(6), p.686.

12. Foroutan, P. and Lahmiri, S., 2024. Deep learning systems for forecasting the prices of crude oil and precious metals. *Financial Innovation*, 10(1), p.111.

13. Hortúa, H.J. and Mora-Valencia, A., 2024. Forecasting VIX using Bayesian deep learning. *International Journal of Data Science and Analytics*, pp.1-22.

14. Nayak, P., Srinivasa Nihal, K., Tagore Ashish, Y., Sai Bhargav, M. and Saketh Kumar, K., 2023. Predicting Stock Market Price Using Machine Learning Techniques. In *Proceedings of Data Analytics and Management: ICDAM 2022* (pp. 687-696). Singapore: Springer Nature Singapore.

15. Verma, S., Sahu, S.P. and Sahu, T.P., 2024. Two-stage hybrid feature selection approach using levy's flight based chicken swarm optimization for stock market forecasting. *Computational Economics*, 63(6), pp.2193-2224.

16. Sharma, G., Vidalis, S., Mankar, P., Anand, N., Minakshi and Kumar, S., 2024. Automated passive income from stock market using machine learning and big data analytics with security aspects. *Multimedia Tools and Applications*, pp.1-28.

17. Mejia, P.S.M. and Lemarroy, P.M., 2022. Financial technologies in the emerging markets. In *Data Analytics Applications in Emerging Markets* (pp. 1-22). Singapore: Springer Nature Singapore.

References

1. Castilho, D., Souza, T.T., Kang, S.M., Gama, J. and de Carvalho, A.C., 2024. Forecasting financial market structure from network features using machine learning. *Knowledge and Information Systems*, pp.1-29.

2. Behera, S., Nayak, S.C. and Kumar, A.P., 2023. A comprehensive survey on higher order neural networks and evolutionary optimization learning algorithms in financial time series forecasting. *Archives of Computational Methods in Engineering*, 30(7), pp.4401-4448.

3. Zhang, D., Lin, R., Wei, T., Ling, L. and Huang, J., 2023. A novel deep transfer learning framework with adversarial domain adaptation: application to financial time-series forecasting. *Neural Computing and Applications*, 35(34), pp.24037-24054.

4. Gupta, A., Joshi, K., Patel, M. and Pratap, V., 2024. Visualization and forecasting of stock's closing price using machine learning. *Multimedia Tools and Applications*, pp.1-19.

5. Lin, R., Zhang, D., Ling, L., Huang, J. and Cai, G., 2022, November. Transfer Learning Based Long Short-Term Memory Network for Financial Time Series Forecasting. In *International Conference on Neural Information Processing* (pp. 3-13). Singapore: Springer Nature Singapore.

6. Pratas, T.E., Ramos, F.R. and Rubio, L., 2023. Forecasting bitcoin volatility: exploring the potential of deep learning. *Eurasian Economic Review*, 13(2), pp.285-305.

7. Li, J., Song, L., Wu, D., Shui, J. and Wang, T., 2023. Lagging problem in financial time series forecasting. *Neural Computing and Applications*, 35(28), pp.20819-20839.

8. Ben Ameer, H., Boubaker, S., Fiti, Z., Louhichi, W. and Tissaoui, K., 2024. Forecasting commodity prices: empirical evidence using deep learning tools. *Annals of Operations Research*, 339(1), pp.349-367.

9. Kumar, B.R.A., Katiyar, S., Lingada, P., Mattaparthi, K., Krishna, R., Prakash, G., Vuppalahadham, D., Darapaneni, N. and Paduri, A.R., 2023, June. Evaluating the Performance of Diverse Machine Learning Approaches in Stock Market Forecasting. In *International Conference on Multi-disciplinary Trends in Artificial Intelligence* (pp. 255-264). Cham: Springer Nature Switzerland.

10. Saleti, S., Panchumarthi, L.Y., Kallam, Y.R., Parchuri, L. and Jitte, S., 2024. Enhancing Forecasting Accuracy with a Moving Average-Integrated Hybrid ARIMA-LSTM Model. *SN Computer Science*, 5(6), p.704.

11. Yadav, A., Kumar, V., Singh, S. and Mishra, A.K., 2024. A Novel Approach for Forecasting Price of Stock Market using Machine Learning Techniques. *SN Computer Science*, 5(6), p.686.

12. Foroutan, P. and Lahmiri, S., 2024. Deep learning systems for forecasting the prices of crude oil and precious metals. *Financial Innovation*, 10(1), p.111.

13. Hortúa, H.J. and Mora-Valencia, A., 2024. Forecasting VIX using Bayesian deep learning. *International Journal of Data Science and Analytics*, pp.1-22.

14. Nayak, P., Srinivasa Nihal, K., Tagore Ashish, Y., Sai Bhargav, M. and Saketh Kumar, K., 2023. Predicting Stock Market Price Using Machine Learning Techniques. In *Proceedings of Data Analytics and Management: ICDAM 2022* (pp. 687-696). Singapore: Springer Nature Singapore.

15. Verma, S., Sahu, S.P. and Sahu, T.P., 2024. Two-stage hybrid feature selection approach using levy's flight based chicken swarm optimization for stock market forecasting. *Computational Economics*, 63(6), pp.2193-2224.

16. Sharma, G., Vidalis, S., Mankar, P., Anand, N., Minakshi and Kumar, S., 2024. Automated passive income from stock market using machine learning and big data analytics with security aspects. *Multimedia Tools and Applications*, pp.1-28.

17. Mejia, P.S.M. and Lemarroy, P.M., 2022. Financial technologies in the emerging markets. In *Data Analytics Applications in Emerging Markets* (pp. 1-22). Singapore: Springer Nature Singapore.