

DOI: <https://doi.org/10.36910/6775-2524-0560-2024-56-33>

УДК 004.942:519.216.3

**Радченко Костянтин Олександрович**, ст. викладач

<https://orcid.org/0000-0002-1282-6307>

**Романенко Марія Володимирівна**, студентка

<https://orcid.org/0009-0007-9440-5795>

Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського», м. Київ, Україна

## ПРОГНОЗУВАННЯ ЦІН АКЦІЙ З ВИКОРИСТАННЯМ ВЕЙВЛЕТ-ПЕРЕТВОРЕННЯ ТА НЕЙРОННИХ МЕРЕЖ

**Радченко К. О., Романенко М.В.,** Прогнозування цін акцій з використанням вейвлет-перетворення та нейронних мереж. У статті розглянуто методи прогнозування цін акцій за допомогою вейвлет-перетворення та гібридних нейронних мереж, зокрема моделей CNN+LSTM. Дослідження показало, що вейвлет-перетворення, зокрема вейвлетів Добеші, ефективно виділяє ключові тренди в фінансових часових рядах, видаляючи шуми та короткотривалі коливання. Застосування CNN дозволяє виділити локальні патерни, тоді як LSTM враховує довготривалі залежності, що забезпечує високу точність прогнозування. Гібридна модель CNN+LSTM дозволяє інтегрувати ці підходи, підвищуючи ефективність аналізу складних фінансових даних. Це сприяло поліпшенню якості вхідних даних для моделі та, як наслідок, підвищенню точності прогнозів. Результати дослідження свідчать про значне покращення точності прогнозування порівняно з традиційними методами і відкривають нові перспективи для подальших досліджень у сфері застосування гібридних моделей нейронних мереж у фінансовому прогнозуванні. Зокрема, можливе дослідження інших комбінацій нейронних мереж та методів попередньої обробки даних. Впровадження цього підходу може бути корисним для фінансових аналітиків та інвесторів, сприяючи прийняттю більш обґрунтованих інвестиційних рішень і зменшенню ризиків на фінансових ринках. Отримані результати можуть бути використані фінансовими аналітиками та інвесторами для підвищення точності прогнозів, що допоможе приймати обґрунтовані інвестиційні рішення. Дослідження підтвердило, що гібридні моделі, які поєднують різні типи нейронних мереж, є ефективними для складних завдань, таких як прогнозування фінансових часових рядів.

**Ключові слова:** прогнозування цін акцій, вейвлет-перетворення, вейвлети Добеші, нейронні мережі, CNN, LSTM, фінансовий аналіз.

**Radchenko K., Romanenko M. Stock Price Prediction Using Wavelet Transform and Neural Networks.** The study investigates the use of hybrid CNN+LSTM models for stock price prediction. The article examines methods for stock price prediction using wavelet transform and hybrid neural networks, specifically CNN+LSTM models. The study demonstrates that wavelet transform, specifically Daubechies wavelets, effectively extracts key trends in financial time series by removing noise and short-term fluctuations. CNN is utilized to identify local patterns, while LSTM captures long-term dependencies, ensuring high prediction accuracy. The hybrid CNN+LSTM model integrates these approaches, enhancing the analysis of complex financial data. This improved the quality of the input data for the model. The findings indicate a significant improvement in prediction accuracy compared to traditional methods. The research results open perspectives for further studies in the application of hybrid neural network models in financial forecasting. In particular, exploring other combinations of neural networks and data preprocessing methods is possible. Implementing this approach can be beneficial for financial analysts and investors, aiding in more informed investment decisions and reducing risks in financial markets. The study confirmed that hybrid models combining different types of neural networks are effective for complex tasks, such as financial time series forecasting.

**Keywords:** stock price prediction, wavelet transform, Daubechies wavelets, neural networks, CNN, LSTM, financial analysis.

**Постановка наукової проблеми.** Прогнозування цін акцій є важливим завданням, що потребує вдосконалених методів для аналізу нестационарних даних та виявлення основних трендів серед шумів.

**Аналіз досліджень.** У сучасному фінансовому аналізі прогнозування цін акцій є складним завданням, що вимагає застосування вдосконалених методів для обробки нестационарних та шумових часових рядів. Традиційні підходи, такі як статистичний аналіз та регресійні моделі, мають обмежені можливості через високу волатильність ринкових даних та наявність короткотривалих коливань, що можуть затушовувати основні тренди. Це обумовлює необхідність використання новітніх технологій, зокрема застосування вейвлет-перетворень та нейронних мереж.

Вейвлет-перетворення [1], яке дозволяє аналізувати часові ряди одночасно в часовій та частотній областях, стало популярним інструментом в багатьох аспектах моделювання, в тому числі у фінансовому прогнозуванні. Дослідження [8, 9] показали, що цей метод ефективно розділяє дані на компоненти, виділяючи ключові тренди та очищуючи дані від шумів. Використання вейвлетів Добеші для декомпозиції часових рядів дозволяє [7] зберегти основні тренди, що покращує точність подальшого прогнозування.

Багато досліджень [10, 12, 13] використовували вейвлет-перетворення для виявлення основних трендів і оцінки волатильності на фінансових ринках. Наприклад, роботи [5, 14] дослідників показали, що вейвлет-перетворення може ефективно розкласти часові ряди акцій на компоненти, що відповідають за тренди і циклічні коливання, що дозволяє отримати більш точні прогнози.

Інші дослідження [6] зосереджувалися на використанні вейвлетів для очищення фінансових даних від шумів. Видалення високочастотних компонент, які можуть бути пов'язані з ринковими шумами, дозволяє покращити якість даних для подальшого аналізу та прогнозування. Це зокрема демонструє дослідження [3], де вейвлети використовуються для попередньої обробки даних перед застосуванням традиційних методів прогнозування.

Деякі дослідження [2, 12] поєднували вейвлет-перетворення з іншими методами, такими як нейронні мережі та машинне навчання, для підвищення точності прогнозів. Наприклад, у роботі [4], де використовуються вейвлет-перетворення разом із нейронними мережами LSTM, показано, що така комбінація може значно покращити точність прогнозування цін акцій порівняно з використанням лише одного з методів.

Нейронні мережі, зокрема рекурентні моделі (RNN), такі як LSTM, також активно використовуються для прогнозування фінансових даних [11]. Завдяки здатності зберігати довготривалі залежності в даних, LSTM стали одним з основних інструментів для обробки часових рядів. Однак, самостійне використання LSTM може бути обмеженим через неможливість ефективно обробляти локальні патерни в даних [9].

Комбінація CNN та LSTM у вигляді гібридних моделей відкриває нові можливості для прогнозування. CNN дозволяють виділити локальні особливості у часових рядах, тоді як LSTM забезпечують обробку довготривалих залежностей. Цей підхід виявився ефективним у ряді досліджень [6, 10], що підтверджують значне підвищення точності прогнозування цін акцій у порівнянні з традиційними методами.

Таким чином в результаті проведеного аналізу науково-практичних робіт можливо стверджувати, що сучасні підходи до прогнозування фінансових даних значно підвищують рівень аналітики, дозволяючи більш точно передбачати майбутні зміни на фінансових ринках.

**Мета дослідження.** Метою цього дослідження є покращення точності прогнозування цін акцій шляхом інтеграції вейвлет-перетворення та гібридної нейронної мережі CNN+LSTM.

**Виклад основного матеріалу й обґрунтування отриманих результатів дослідження.** Історично рекурентні нейронні мережі (RNN) були одним з основних підходів до прогнозування часових рядів, в тому числі цін на акції. Вони здатні враховувати часову залежність даних завдяки своїй рекурентній структурі. Однак традиційні RNN мають обмеження у вигляді проблеми зникання градієнта. Тому більшого поширення набули Long Short-Term Memory (LSTM), як покращена версія RNN, що вирішує проблему зникаючого градієнта. Вони здатні запам'ятовувати довготривалі залежності в даних, що робить їх ефективними для прогнозування фінансових часових рядів. LSTM часто використовуються для аналізу та прогнозування складних фінансових патернів.

Хоча конволюційні нейронні мережі (CNN) зазвичай використовуються для аналізу зображень, вони також можуть бути ефективними для обробки часових рядів. CNN здатні виділяти локальні патерни в даних, що може бути корисним для прогнозування цін акцій після попередньої обробки, такої як вейвлет-перетворення.

Гібридні моделі, які поєднують CNN та LSTM, використовують переваги обох підходів. CNN виділяють локальні патерни, а LSTM враховують довготривалі залежності. Такі моделі показали високу ефективність у прогнозуванні складних фінансових часових рядів. Вони використовуються для прогнозування фінансових часових рядів завдяки своїй здатності моделювати складні взаємозв'язки.

Вейвлет-перетворення як математичний метод для аналізу часових рядів дозволяє представити такий ряд у вигляді сукупності компонент з різними масштабами (частотами) та позиціями у часі. Це надає можливість одночасно аналізувати локальні властивості ряду у часовій та частотній областях. Вейвлет – це функція з обмеженою довжиною, яка має середнє значення, що дорівнює нулю. Вейвлети  $\psi(t)$  використовуються для розкладання часових рядів на компоненти, оскільки мають такі характерні особливості як масштабування (scaling) та зсув (translation).

Масштабування, тобто зміна масштабу вейвлету, дозволяє аналізувати часовий ряд на різних рівнях деталізації. А зсув вейвлету вздовж осі часу дозволяє аналізувати ряд у різних точках часу  $t$ .

Вейвлети Добеші — це сімейство ортогональних вейвлетів, розроблених Інґрід Добеші. Вони є одним з найпопулярніших типів вейвлетів для аналізу та обробки часових рядів [7]:

$$\psi(t) = \sqrt{2} \sum_{k=0}^{N-1} h_k \varphi(2t - k),$$

де  $h_k$  — ортогональні нормовані коефіцієнти Добеші,  $\varphi$  — масштабуюча функція,  $N$  — довжина фільтра, яка визначає порядок вейвлетів Добеші.

Нагадаємо властивості вейвлетів Добеші, які дозволяють ефективно взаємодіяти з часовими рядами. Вони мають компакту підтримку, тобто вони нульові поза певним інтервалом, — це дозволяє локалізувати аналіз часового ряду. Вони утворюють ортогональний базис, що забезпечує стабільність і ефективність розкладання та реконструкції даних. Також вони мають моменти нульового порядку, що робить їх чутливими до змін у часовому ряді і дозволяє ефективно виділяти їх особливості.

Нейронні мережі складаються з шарів штучних нейронів, які обробляють вхідні дані та передають оброблену інформацію через мережу для отримання кінцевого результату. Кожен нейрон обробляє зважену суму своїх входів, додає зміщення та застосовує нелінійну активаційну функцію. Нейронні мережі навчаються шляхом мінімізації функції втрат за допомогою алгоритму зворотного поширення помилки.

Конволюційні нейронні мережі призначені для обробки даних з високою локальною кореляцією, таких як зображення або часові ряди. Вони містять такі основні компоненти:

- конволюційні шари, які виконують згортку вхідних даних за допомогою фільтрів (ядра згортки), виділяючи локальні патерни.
- пулінг (pooling) шари, які зменшують розмірність даних, об'єднуючи значення (наприклад, max-pooling), що знижує обчислювальні витрати і допомагає уникнути перенавчання.
- повноз'язні (Fully Connected) шари, які з'єднують всі нейрони попереднього шару з кожним нейроном наступного шару, забезпечуючи глобальну обробку даних.

Рекурентні нейронні мережі з довготривалою пам'яттю (LSTM) призначені для роботи з послідовними даними і можуть зберігати довготривалі залежності завдяки спеціальній архітектурі. Вони визначаються такими компонентами як:

- осередки пам'яті (memory cells), що зберігають інформацію протягом тривалого часу.
- гейти (gates), що регулюють потік інформації через осередки пам'яті. Існують три типи гейтів: вхідний, вихідний та забуття.

Гібридна модель CNN+LSTM поєднує переваги конволюційних нейронних мереж та рекурентних нейронних мереж з довготривалою пам'яттю, що робить її ефективною для обробки та аналізу складних часових рядів.




Рис. 1. Схема гібридної моделі CNN+LSTM

Розглянемо більш детально архітектуру такої гібридної моделі (рис. 1). Архітектура моделі складається з:

- конволюційних шарів (CNN), що містять фільтри для виділення локальних патернів у даних та пулінг шари об'єднання. Фільтри допомагають виявити короткотривалі залежності та локальні особливості у часових рядах. Пулінг шари об'єднання (наприклад, max-pooling) зменшують розмірність вихідних даних, що дозволяє зменшити обчислювальні витрати і видалити шуми.

- рекурентні шари (LSTM) з пам'яттю та гейтами. Пам'ять LSTM шарів полягає в обробці вихідних даних з CNN, зберігаючи інформацію про довготривалі залежності. Це дозволяє моделі враховувати контекст попередніх значень для більш точного прогнозування. Гейти в LSTM контролюють потік інформації через нейронну мережу, забезпечуючи ефективно зберігання та оновлення пам'яті.
- повнозв'язні (Fully Connected) шари приймають дані від LSTM і обробляють їх для отримання кінцевого прогнозу. Ці шари виконують функцію остаточної обробки та узагальнення інформації.

Для дослідження було використано історичні дані цін акцій кількох провідних компаній, завантажені з Yahoo Finance [15]. Набір даних включає щоденні дані про ціни акцій за період з 2019 по 2023 рік. Обрані компанії представляють різні сектори економіки, що дозволяє створити більш узагальнену та стійку модель прогнозування. До набору даних увійшли компанії Apple Inc. (AAPL), Microsoft Corporation (MSFT), Alphabet Inc. (GOOGL), Amazon.com Inc. (AMZN), Meta Platforms, Inc. (META).

Набір даних містить наступні параметри:

- Date – дата торгового дня.
- Open – ціна відкриття акції на початок торгового дня.
- High – найвища ціна акції протягом торгового дня.
- Low – найнижча ціна акції протягом торгового дня.
- Close – ціна закриття акції на кінець торгового дня.
- Volume – обсяг торгівлі акціями протягом дня.
- Adj Close – скоригована ціна закриття, яка враховує всі корпоративні дії та дивіденди.

Для попередньої обробки даних з усього набору завантажених даних про ціни акцій виділяються скориговані ціни закриття (Adj Close), які будуть використовуватися для прогнозування.

Потім дані нормалізуються до діапазону [0, 1] за допомогою методу Min-Max. Це допомагає привести всі значення до одного масштабу, що сприяє стабільному навчанню нейронної мережі:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

де  $x$  – вихідне значення, яке потрібно нормалізувати,  $x_{min}$  – мінімальне значення в наборі даних,  $x_{max}$  – максимальне значення в наборі даних.

Після цього створюються послідовності. Для навчання нейронної мережі дані перетворюються на послідовності фіксованої довжини (тривалістю 50 днів). Кожна послідовність використовується для прогнозування наступного дня.

Нарешті дані розбиваються на навчальні (80%) і тестові (20%) набори для оцінки продуктивності моделі.

Розклад часового ряду на набір компонент з різними частотами та часовими масштабами досягається шляхом застосування вейвлет-функцій до часового ряду (рис. 2), що дозволяє виявити як локальні, так і глобальні патерни у даних. Процес декомпозиції включає в себе кілька рівнів, де кожен рівень відповідає за різні частотні компоненти. Причому високочастотні компоненти відповідають за деталі та короткотривалі коливання у часовому ряді, а низькочастотні компоненти відповідають за основні тренди та довготривалі залежності.

Високочастотні компоненти часто містять шуми, які можуть спотворювати часовий ряд і ускладнювати прогнозування. Видалення шумів здійснюється шляхом обнулення або зменшення високочастотних компонент, які не несуть корисної інформації. Це дозволяє зберегти основні патерни та тренди часового ряду знижуючи вплив випадкових коливань.

У даному дослідженні використовується вейвлет Добеші для декомпозиції часових рядів цін акцій. Після декомпозиції високочастотні компоненти, які переважно містять шум, обнуляються, а залишок часового ряду реконструюється. Цей очищений часовий ряд використовується для подальшого аналізу та прогнозування.

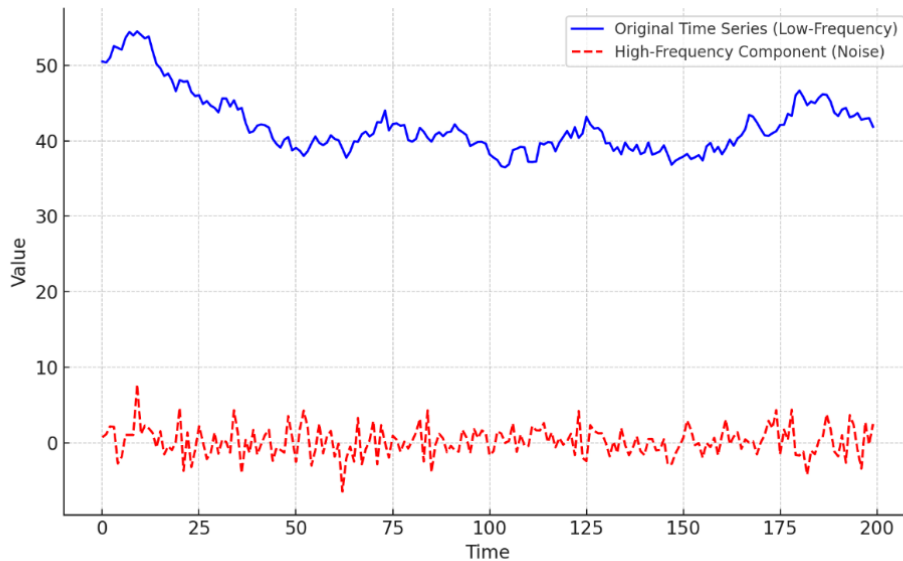


Рис. 2. Вейвлет-перетворення часових рядів цін акцій з високо- і низькочастотними компонентами

Гібридна модель CNN+LSTM у цьому дослідженні включає кілька ключових компонентів:

- вхідний шар приймає послідовності нормалізованих цін закриття акцій довжиною `sequence\_length`.
- перший LSTM шар містить 50 одиниць з `return\_sequences=True`, що означає повернення повної послідовності вихідних значень для кожного кроку часу. Dropout: використовується для запобігання перенавчанню, з коефіцієнтом 0.2.
- другий LSTM шар містить 50 одиниць, обробляє вхідні дані з попереднього LSTM шару. Dropout: знову застосовується для регуляризації з тим же коефіцієнтом.
- повнозв'язний шар (Dense) у останньому шарі містить один нейрон для передбачення наступної ціни акцій.
- вихідний шар виводить прогнозовану ціну акцій.

Вибору гіперпараметрів та їхньому налаштуванню приділялася теж значна увага. Було вибрано 50 одиниць для кожного LSTM шару, що забезпечує достатню ємність для запам'ятовування довготривалих залежностей. Dropout застосовувався з коефіцієнтом 0.2 для запобігання перенавчанню. Модель тренувалася протягом 20 епох, що визначено на основі експериментального досвіду та можливостей обчислювальних ресурсів. Було вибрано розмір батчу 32 для навчання, що забезпечує баланс між швидкістю обробки та стабільністю оновлення ваг. В якості оптимізатора використовувався `adam` для швидкої та ефективної оптимізації.

Модель навчалася на навчальних даних (`X\_train`, `y\_train`) та оцінювалася на тестових даних (`X\_test`, `y\_test`). Прогнозовані ціни акцій денормалізувалися для порівняння з фактичними значеннями, що дозволило оцінити точність моделі за допомогою метрики середньої абсолютної помилки (MAE), яка вимірює середню величину різниці між фактичними значеннями і прогнозованими значеннями моделі:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{act}^{(i)} - y_{pred}^{(i)}|,$$

де  $n$  – кількість прикладів у тестовій вибірці,  $y_{act}^{(i)}$  – фактичне значення для  $i$ -го прикладу,  $y_{pred}^{(i)}$  – прогнозоване значення для  $i$ -го прикладу.

В реалізованій моделі MAE дорівнює 12 – тобто в середньому модель помиляється на 12 доларів для ціни акцій.

Також прогноз оцінювався через середньо-відсоткову абсолютну похибку (MAPE), яка показує середній відсоток, на який прогнозовані значення відрізняються від фактичних:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_{act}^{(i)} - y_{pred}^{(i)}|}{y_{act}^{(i)}} 100\%.$$

Середній відсоток помилки прогнозу моделі при перевірці через MAPE становить 8 – 10 %.

Процес навчання моделі можна описати схематично наступним чином:

- завантаження даних цін закриття акцій кількох компаній за період з 2010 по 2023 рік.
- нормалізація даних до діапазону  $[0; 1]$  за допомогою Min-Max нормалізації.
- 80% даних були виділені для навчання, а 20% – для тестування. Це розподілення дозволяє оцінити модель на невідомих їй даних для перевірки узагальнювальної здатності.
- дані були перетворені на послідовності фіксованої довжини (50 днів) для підготовки вхідних даних для моделі. Кожна послідовність ('X') відповідає прогнозу ('y') наступного значення.
- у якості архітектури моделі використовувалася гібридна модель CNN+LSTM, яка включала LSTM шари для обробки послідовних даних і повнозв'язний шар для остаточного прогнозу.
- модель навчалася на навчальних даних ('X\_train', 'y\_train') протягом 20 епох з використанням розміру батчу 32. Оптимізатор 'adam' використовувався для мінімізації функції втрат 'mean\_squared\_error'.
- використовувалася регуляризація для запобігання перенавчанню – застосовувався Dropout з коефіцієнтом 0,2.
- після навчання модель була перевірена на тестових даних ('X\_test', 'y\_test') для оцінки її точності (рис. 3). Прогнозовані значення були денормалізовані та порівняні з фактичними цінами для оцінки якості моделі.




Рис. 3. Графік порівняння прогнозу та реальних даних

Таким чином у дослідженні було запропоновано модифікований метод прогнозування цін акцій, який поєднує вейвлет-перетворення з гібридною моделлю CNN+LSTM. Це дозволяє зменшити вплив шумів, врахувати складні взаємозв'язки у даних і, як наслідок, покращити точність прогнозування.

Отримані результати можуть бути використані фінансовими аналітиками та інвесторами для підвищення точності своїх прогнозів, що допоможе приймати обґрунтовані інвестиційні рішення і зменшити ризики.

Результати дослідження відкривають нові перспективи для подальших досліджень у сфері застосування гібридних моделей нейронних мереж у фінансовому прогнозуванні. Зокрема, можливе дослідження інших комбінацій нейронних мереж та методів попередньої обробки даних.

**Висновки.** Дослідження зробило значний внесок у наукову область прогнозування цін акцій, запропонувавши ефективний метод, який поєднує вейвлет-перетворення та гібридну модель CNN+LSTM. Це не лише значно підвищує точність прогнозування, але й відкриває нові можливості



для подальших досліджень у цій галузі. Виділення локальних патернів за допомогою CNN та врахування довготривалих залежностей через LSTM забезпечило комплексний аналіз часових рядів у фінансовому прогнозуванні.

Застосування вейвлет-перетворення, зокрема вейвлетів Добеші, дозволило ефективно виконати декомпозицію часових рядів, видаливши шуми та зберігши важливі тренди. Це сприяло поліпшенню якості вхідних даних для моделі та, як наслідок, підвищенню точності прогнозів.

Дослідження підтвердило, що гібридні моделі, які поєднують різні типи нейронних мереж, є ефективними для складних завдань прогнозування, таких як фінансові часові ряди. Комбінація CNN та LSTM є перспективною і дозволяє враховувати як короткотривалі, так і довготривалі патерни у даних.

#### Список бібліографічного опису

1. Білоус, М. Г. (2022). Вейвлет-перетворення як інструмент фінансового аналізу: переваги та виклики // *Фінанси України*. – 2022. – №1. – С. 22-30.
2. Григор'єв, І. А., Сорокін, В. О. (2020). Гібридні моделі для прогнозування цін акцій на фондовому ринку // *Вісник Харківського національного університету*. – 2020. – №2. – С. 45-53.
3. Карпова, Л. В. (2018). Нейронні мережі у фінансовому аналізі: теорія та практика застосування // *Вісник Київського національного університету. Економіка*. – 2018. – №4. – С. 90-98.
4. Козаченко, О. В., Романюк, О. А. (2020). Прогнозування цін акцій на основі моделей машинного навчання // *Економіка та прогнозування*. – 2020. – №2. – С. 75-88.
5. Кравченко, Д. В. (2021). Статистичні методи та машинне навчання у фінансових дослідженнях // *Фінансовий ринок України*. – 2021. – №3. – С. 67-73.
6. Литвин, О. І., Синиця, А. В. (2018). Впровадження нейронних мереж у фінансове прогнозування: досвід та перспективи // *Економіка та управління підприємством*. – 2018. – №5. – С. 88-96.
7. Радченко К.О. (2021). Застосування дискретних вейвлет-перетворень для прогнозування рівня навантаження на вебсервер комп'ютерних мереж загального призначення // *Комп'ютерно-інтегровані технології: освіта, наука, виробництво*. – 2021. – № 45. – С. 90 – 96. <https://doi.org/10.3691/0/6775-2524-0560-2021-45-13>
8. Радченко К.О. (2020). Концептуальна модель забезпечення ефективності прогнозування навантаження на вебсервер // *Вчені записки Таврійського національного університету імені В.І. Вернадського. Серія: Технічні науки*. 2020. – Т. 31 (70). – № 6. – С. 135 – 141. <https://doi.org/10.3283/8/TNU-2663-5941/2020.6-1/23>
9. Радченко К.О. (2022). Особливості прогнозування рівня вебтрафіку у комп'ютерних мережах загального призначення // *Проблеми інформатизації та управління*. – 2022. – № 3(71). – С. 41 – 50. <https://doi.org/10.18372/2073-4751.71.17002>
10. Федоренко, А. С., Литвиненко, В. П. (2021). Використання глибокого навчання для прогнозування ринку акцій // *Інформаційні технології в управлінні*. – 2021. – Т. 3. – С. 56-64.
11. Шелест, О. В. (2019). Прогнозування фінансових часових рядів за допомогою рекурентних нейронних мереж // *Сучасні інформаційні технології та інноваційні методи в управлінні*. – 2019. – №2. – С. 34-42.
12. Althelaya, K. A., Mohammed, S. A., & El-Alfy, E. S. M. (2021). Combining deep learning and multiresolution analysis for stock market forecasting. *IEEE Access*, 9, 13099-13111. Article 9324831. <https://doi.org/10.1109/ACCESS.2021.3051872>
13. Rhif, M., Abbes, A. B., Farah, I. R., Martínez, B., & Sang, Y. (2019). Wavelet transform application for/in non-stationary time-series analysis: A review. *Applied Sciences*, 9(7), 1345. <https://doi.org/10.3390/app9071345>
14. Verma, S., Sahu, S. P., & Sahu, T. P. (2023). Discrete wavelet transform-based feature engineering for stock market prediction. *International Journal of Information Technology*, 15(6), 1-10. <https://doi.org/10.1007/s41870-023-01157-2>
15. Yahoo Finance. Режим доступу <https://finance.yahoo.com/watchlists/>

#### References

1. Bilous, M. G. (2022). Wavelet Transform as a Tool for Financial Analysis: Advantages and Challenges // *Finance of Ukraine*. – 2022. – No.1. – P. 22-30.
2. Hryhoriev, I. A., Sorokin, V. O. (2020). Hybrid Models for Stock Price Prediction in the Stock Market // *Bulletin of Kharkiv National University*. – 2020. – No.2. – P. 45-53.
3. Karpova, L. V. (2018). Neural Networks in Financial Analysis: Theory and Practice // *Bulletin of Kyiv National University. Economics*. – 2018. – No.4. – P. 90-98.
4. Kozachenko, O. V., Romanyuk, O. A. (2020). Stock Price Prediction Based on Machine Learning Models // *Economy and Forecasting*. – 2020. – No.2. – P. 75-88.
5. Kravchenko, D. V. (2021). Statistical Methods and Machine Learning in Financial Research // *Financial Market of Ukraine*. – 2021. – No.3. – P. 67-73.
6. Lytvyn, O. I., Synytsia, A. V. (2018). Implementation of Neural Networks in Financial Forecasting: Experience and Prospects // *Economics and Enterprise Management*. – 2018. – No.5. – P. 88-96.
7. Radchenko K.O. (2021). Application of discrete wavelet transformations for forecasting the level of load on the web server of general purpose computer networks // *Computer-integrated technologies: education, science, production*. – 2021. – No. 45. – P. 90-96. <https://doi.org/10.3691/0/6775-2524-0560-2021-45-13>
8. Radchenko K.O. (2020). Conceptual model for ensuring the effectiveness of web server load forecasting // *Scientific notes of the Tavri National University named after V.I. Vernadsky. Series: Technical sciences*. – 2020. – Vol. 31 (70). – No. 6. P. 135-141. <https://doi.org/10.3283/8/TNU-2663-5941/2020.6-1/23>

9. Radchenko K.O. (2022). Peculiarities of predicting the level of web traffic in general purpose computer networks // Problems of informatization and management. – 2022. – No. 3(71). – P. 41-50. <https://doi.org/10.18372/2073-4751.71.17002>.
10. Fedorenko, A. S., Lytvynenko, V. P. (2021). Deep Learning for Stock Market Prediction // Information Technologies in Management. – 2021. – Vol. 3. – P. 56-64.
11. Shelest, O. V. (2019). Forecasting Financial Time Series Using Recurrent Neural Networks // Modern Information Technologies and Innovative Methods in Management. – 2019. – No.2. – P. 34-42.
12. Althelaya, K. A., Mohammed, S. A., & El-Alfy, E. S. M. (2021). Combining deep learning and multiresolution analysis for stock market forecasting. *IEEE Access*, 9, 13099-13111. Article 9324831. <https://doi.org/10.1109/ACCESS.2021.3051872>
13. Rhif, M., Abbes, A. B., Farah, I. R., Martinez, B., & Sang, Y. (2019). Wavelet transform application for/in non-stationary time-series analysis: A review. *Applied Sciences*, 9(7), 1345. <https://doi.org/10.3390/app9071345>
14. Verma, S., Sahu, S. P., & Sahu, T. P. (2023). Discrete wavelet transform-based feature engineering for stock market prediction. *International Journal of Information Technology*, 15(6), 1-10. <https://doi.org/10.1007/s41870-023-01157-2>
15. Yahoo Finance. Access mode <https://finance.yahoo.com/watchlists/>