

УДК 004.8

DOI: 10.20998/2411-0558.2022.02.11

К. М. МІЛОВСЬКА, магістр, ОНУ ім. І.І. Мечникова, Одеса,
В. В. МОРОЗ, канд. техн. наук, доц., ОНУ ім. І.І. Мечникова, Одеса

ВЕЙВЛЕТНИЙ АНАЛІЗ ТА ПРОГНОЗУВАННЯ ФІНАНСОВИХ ЧАСОВИХ РЯДІВ

В роботі розглянуті моделі та методи прогнозування фінансових часових рядів. Проаналізовано основні переваги та недоліки традиційних моделей та нейронних мереж для прогнозування без попередньої обробки даних. Застосовано вейвлетний аналіз та рекурентна нейронна мережа з довгою короткостроковою пам'яттю (LSTM) для прогнозування курсу криптовалюти. Отримані результати порівнюються з результатами існуючих підходів, доведено ефективність запропонованого рішення. Іл.: 6. Табл.: 2. Бібліогр.: 13 назв.

Ключові слова: фінансові часові ряди, нейронні мережі, прогнозування, попередня обробка даних, вейвлетний аналіз, рекурентна нейромережа з довгою короткостроковою пам'яттю, курс криптовалюти.

Постановка проблеми. Протягом останніх десятиліть у світі активно зростає увага до криптовалютних торгів, які являють собою постійно зростаючий і перспективний фінансовий ринок. Для того, щоб заробити на криптовалютному трейдингу необхідно вміти правильно прогнозувати майбутній рух цін, що потенційно може привести до високого прибутку. Таким чином, розробка точного інструменту прогнозування має важливе значення. Традиційні моделі добре працюють для рядів з трендом, з сезонною компонентою [3], а фінансові ряди є результатом нелінійних нестационарних процесів. Унаслідок чого з'являється необхідність у використанні моделей на основі нейронних мереж з попереднім обробленням даних, що мало би дати більш точний прогноз.

Аналіз останніх досліджень. Проблема прогнозування розвитку фондового або страхового ринків, на сьогодні є достатньо вивченою. Натомість прогнозування на ринку криптовалют є актуальною та цікавою задачею з точки зору його високої волатильності, невизначеності та сильними коливаннями цін з часом, а самі криптовалюти знаходяться на перехідній стадії, через що є нестабільними. На ринку присутні розв'язання задачі прогнозування курсу криптовалют, проте зазвичай вони представлені у вигляді комерційного сервісу і не розкривають деталі реалізації. Серед факторів, що впливають на курс криптовалют, дослідники відмітили розповсюдження самої цифрової валюти. Останнім часом біткоїн отримав

масові реклами у всіх світових засобах масової інформації, що безумовно сприяло зростанню курсу. Крім того, у роботі [7] встановлено, що існує вплив коментарів користувачів на онлайн-платформах на коливання цін криптовалют, а саме BTC особливо корелює з числом позитивних коментарів у соціальних мережах.

Розглядаючи прогнозування курсу криптовалют з боку прогнозування часових рядів, зазначимо, що існують різні підходи. Наприклад, у дослідженні [1] описуються результати використання традиційної моделі ARIMA для прогнозування цін криптовалют. Експеримент повторили для щоденних, щотижневих та щомісячних наборів даних шляхом застосування ARIMA з різними параметрами. У статті було зазначено, що побудова такої моделі вимагає великих витрат ресурсів і часу, крім того, така модель є неадаптивною. До того ж, традиційні моделі спираються на припущення щодо лінійного характеру залежності між показниками та пристосовані для даних, в яких можна виділити тенденції, сезонність та шум, а криптовалюти характеризуються низькою сезонністю.

Таким чином, перспективним і потужним підходом до прогнозування стають методи обчислювального інтелекту, до яких, в першу чергу, відносяться нейронні мережі. У роботі [9] порівнюються LSTM і ARIMA моделі для прогнозування протягом одного, семи, тридцяти та дев'яноста днів. З результатів видно, що моделі машинного навчання (LSTM) потребують більше часу для прогнозування через складні розрахунки, ніж традиційні моделі. Але розрахунки помилки RMSE показали, що LSTM перевершує ARIMA. Отже, доведено, що моделі, розроблені з використанням LSTM, мають більшу точність, ніж традиційні моделі, тому вони є досить ефективним інструментом для прогнозування курсу біткоїнів.

Разом з тим досить часто почали використовувати вейвлет-аналіз, щоб покращити вхідні дані, тобто з метою усунення шумів і декомпозиції даних, що у комбінуванні з нейронними мережами значно підвищує точність і зменшує величину помилок прогнозу. У сфері прогнозування курсу криптовалют застосувалося емпіричне перетворення вейвлетів (EWT) [2], вперше запропоноване у 2013 році [5], яке полягає у вилученні різних внутрішніх режимів часового ряду шляхом створення адаптивних вейвлетів. Алгоритм поєднав EWT з LSTM для прогнозування ціни криптовалюти та Cisco Search (CS) для оптимізації навчання LSTM. Ця робота показує, що вейвлет-декомпозиція в емпіричних вейвлетах призвела до значного зменшення величин помилок прогнозу. У роботі [12] використане швидке вейвлет-перетворення, яке застосовує вейвлети Добеші для прогнозування цін на криптовалюти. Вищезазначені роботи показують, що вейвлети є ефективним методом усунення шумів і

декомпозиції даних, а їх застосування у фінансових даних різко підвищило точність і зменшило величину помилок прогнозу навчених моделей. Автори статті [10] досліджували кілька глобальних ринків у пошуках предиктора прибутку BTC. У зв'язку з цим, запропонували часові ряди цін на золото, нафту, SP500, ETH, XRP і BTC, а також часові ряди VIX і USDI як потенційні предиктори для дослідження їх прогностичної сили в прогнозуванні ціни BTC на крок вперед. По-перше, було застосовано DWT з фільтром db3, щоб усунути шум часового ряду. Далі була створена модель прогнозування на основі нейронних мереж LSTM і спрогнозовано BTC на крок вперед, використовуючи обидва підходи однофакторної регресії та багатофакторної регресії.

Мета роботи. Дослідження прогнозування курсу криптовалют за допомогою вейвлет-аналізу та нейронної мережі, порівняння отриманих результатів з прогнозом без попередньої обробки даних (за допомогою вейвлет-перетворення) і визначення ефективності створеного рішення.

Прогнозування часових рядів. Популярність використання вейвлетних технологій в економіці та фінансах зумовлена тим, що вейвлет-аналіз не вимагає припущення стаціонарності даних, а також надає інформацію як у часовій, так і в частотній областях. Тому у даній роботі було використано вейвлет-аналіз для попередньої обробки даних, а саме дискретне вейвлет-перетворення та його модифікацію – дискретне вейвлет-перетворення максимального перекриття.

Насамперед розглянемо набір даних, який використовувався у даній роботі. Це дані Intraday data – OHLCV, які характеризуються тим, що показують котирування на момент відкриття (open) торгового дня (початок дня), найвищий (high) рівень цін досягнутий за день, найменший (low) рівень цін досягнутий за день, рівень цін на момент закриття (close) торгового дня (на кінець дня), а також обсяг торгів (volume) за день. Дані були зібрані з біржі криптовалют, у період з 1 червня 2022 року 00:15 по 16 червня 2022 року 00:00, тобто у нас є дані про курс біткоїна за 2 тижні з відліком 15 хвилин. Зауважимо, що аналіз був зосереджений лише на інформації про ціни, залишаючи осторонь будь-який фактор, який може вплинути на курс. Для поставленої мети нас цікавить стовпець Close. Нижче наведено графік (див. рис. 1), який ілюструє зміну ціни біткоїна протягом обраного періоду.




Рис. 1. Зміна курсу Bitcoin протягом 2 тижнів червня 2022 року

Перш ніж перейти до побудови рекурентної мережі LSTM, необхідно попередньо обробити вхідні дані. Спочатку було проведено їх нормування, метою якого є зміна значень числових стовпців у наборі даних до загальної шкали, не спотворюючи відмінностей в діапазонах значень. Також важливо центрування даних — наявність у даних середнього значення і середньоквадратичного відхилення, тобто треба обчислити і застосувати до вибірки ці параметри. Далі дані були розділені на тренувальний та тестовий набори, у відношенні 85% та 15% відповідно.

Після підготовки даних, настав час побудови моделі. Параметри моделі LSTM наведено у табл. 1.

Таблиця 1

Параметри моделі LSTM

Кількість шарів LSTM	4
Кількість блоків шару LSTM (units)	50
Кількість повнозв'язних шарів (Dense)	1
Оптимізатор	Adam
Функція втрат	Mean Squared Error
Batch-size	32
Кількість епох	100

На рис. 2. наведений графік порівняння тестових даних та прогнозу, зробленого за допомогою цієї мережі. Прогноз був зроблений на 1 крок вперед, використовуючи при цьому 20 попередніх часових кроків для прогнозування наступного. Така модель називається одноетапною моделлю прогнозування.




Рис. 2. Порівняння тестових даних та створеного прогнозу

Дивлячись на вищенаведений графік, можемо зробити висновок, що створений прогноз не є точним. Тому необхідно скористатися запропонованою схемою: спочатку застосувати вейвлет-декомпозицію та реконструкцію для попередньої обробки фінансового часового ряду, потім зробити прогноз за допомогою LSTM.

Прогнозування DWT+LSTM. У роботі було використано дискретне вейвлет-перетворення (ДВП) та його модифікацію (MODWT). Такий вибір зумовлено тим, що дискретне вейвлет-перетворення є економним по числу операцій і необхідній пам'яті, разом з тим забезпечуючи достатньо інформації як для аналізу ряду, так і для його синтезу. Крім того, вейвлет-аналіз не вимагає припущення стаціонарності даних, а також надає інформацію як у часовій, так і в частотній областях.

ДВП запропоноване угорським математиком Альфредом Хааром. Він знайшов ортогональну систему функцій, яка сьогодні відома як найпростіший базис сімейства вейвлетів і названий на його честь вейвлетом Хаара [6]. Вейвлети Хаара ортогональні, мають компактний носій, добре локалізовані в просторі, але не є гладкими. Згодом Інґрід Добеші почала розвивати теорію ортогональних вейвлетів і запропонувала використовувати функції, що обчислюються ітераційним шляхом, які відомі як вейвлети Добеші [4]. Вейвлет-перетворення Добеші та Хаара визначені шляхом обчислення змінних середніх і різниць через скалярні

добутки з масштабуючими сигналами й вейвлетами, але між ними є різниця у тому, як ці масштабуючі функції та вейвлети визначені. Для вейвлет-перетворень Добеші масштабування сигналів (часових рядів) і вейвлети виробляють середні значення і різниці, використовуючи лише кілька додаткових значень з сигналу, тобто їх бази довші й саме ця зміна забезпечує величезне поліпшення можливостей цих нових перетворень.

Дослідження проводилися з застосуванням у якості материнського вейвлету (функції перетворення) вейвлетів Хаара (рис. 3) і Добеші порядку 2 (рис. 4).




Рис. 3. Порівняння тестових даних та створеного прогнозу (вейвлет Хаара)




Рис. 4. Порівняння тестових даних та створеного прогнозу (вейвлет Добеші)

Після цього використаємо модифіковане дискретне вейвлет-перетворення – ДВП максимального перекриття (MODWT), який є одним з найсучасніших методів попередньої обробки саме фінансових часових

рядів [11]. Одним з обмежень ДВП є вимога, щоб довжина набору даних була діадичною. По-друге, вихідні дані, створені ДВП, сильно залежать від походження ряду, що аналізується. Невеликий зсув може впливати на генеровані результати, через це важко узгодити перетворені сигнали з часом. Щоб подолати два вищезазначені обмеження, використовується модифікація. Зазначимо, що вибраний рівень декомпозиції залежить від кількості доступних точок даних. Згідно з [13], уся прихована інформація в даних виявляється, коли рівень декомпозиції дорівнює 6. Однак зі збільшенням рівня декомпозиції, дані згладжуються більшою мірою, що може призвести до втрати інформації [8]. Таким чином, рівень декомпозиції, обраний для експериментів, дорівнює 1 та 2. Графіки порівняння реальних даних та прогнозу для кожного з рівнів наведено відповідно на рис. 5 і 6.




Рис. 5. Порівняння тестових даних та створеного прогнозу (MODWT, рівень 1)

Для оцінки ефективності прогнозування за допомогою запропонованого підходу використовуються наступні показники: коефіцієнт детермінації R^2 , середня абсолютна похибка (MAE), відсоткова похибка (MAPE), корінь з середньоквадратичної похибки (RMSE) та метрику Dynamic Time Warping (DTW), яка найбільше підходить для часових рядів. Отримані результати зведено у табл. 2. Зазначимо, що значення MAE та RMSE розраховуються в тих самих одиницях, в яких представлені вхідні дані (у нашому випадку, USD). Наприклад, у контексті ціни Bitcoin, MAE 125 означає, що прогнозована ціна становить ± 125 доларів США від фактичної ціни. Найкращим вважається випадок з найнижчими значеннями MAE, MAPE, RMSE, DTW та найвищим значенням R^2 . Таким чином, моделі слід оцінювати за всіма показниками.




Рис. 6. Порівняння тестових даних та створеного прогнозу (MODWT, рівень 2)

Отримані результати дають змогу дійти висновку, що попередня обробка даних за допомогою вейвлет-перетворень значно покращує точність прогнозування, а використання MODWT з рівнем розкладання 2 найкраще підходить для роботи на основі запропонованих даних. Варто зазначити, що добрий результат було отримано і з вейвлетом Добеші, і з MODWT з рівнем розкладання 1.

Таблиця 2

Оцінка точності прогнозування

Модель	R^2	MAE	$MAPE$ (%)	$RMSE$	DTW
LSTM без вейвлету	0.66	361.29	17	446.16	2459.79
LSTM+вейвлет Хаара	0.67	355.92	16	444.42	3150.45
LSTM + вейвлет Добеші	0.90	195.20	9	244.58	2432.62
LSTM + MODWT (рівень 1)	0.88	200.16	9	262.14	2337.39
LSTM + MODWT (рівень 2)	0.91	175.11	8	226.15	2160.28

Висновки. Проведені дослідження доводять ефективність використання обраного підходу. Запропонована модель є корисною для прогнозування курсу, оскільки вона базується на декомпозиції часового фінансового ряду. Це допомагає розкласти часовий ряд на різні частотні (масштабні) компоненти. Окремі компоненти легше передбачити, ніж

нестационарні та нелінійні вхідні дані в цілому. Найкращі результати показало використання дискретного вейвлет-перетворення максимального перекриття з рівнем декомпозиції 2 для прогнозу на основі використаних даних. Разом з тим, було виявлено, що різні материнські вейвлети, які застосовуються для аналізу того ж часового ряду, дають різні результати. Унаслідок чого, існує складність у використанні такого підходу, яка полягає у правильному виборі вейвлет-перетворення, самого материнського вейвлету та рівня розкладання.

Оскільки в роботі використовувалася тільки інформація про ціну криптовалюти, без урахування факторів, які можуть впливати на зміну курсу, в майбутніх дослідженнях планується побудова точнішої моделі з використанням зовнішніх факторів, що впливають на курс.

Список літератури:

1. *Alahmari S. Using Machine Learning ARIMA to Predict the Price of Cryptocurrencies / S. Alahmari – 2019.*
2. *Box G. Time Series Analysis: Forecasting And Control / G. Box, G. Jenkins, G. Reinsel, G. Ljung. – 5th ed. John Wiley & Sons. Inc. – 2016.*
3. *Kim Y. Predicting Fluctuations in Cryptocurrency Transactions Based on User Comments and Replies / Y. Kim, J. Kim, W. Kim et al. – 2016.*
4. *Mudassir M. Time-series forecasting of Bitcoin prices using high-dimensional features: a machine learning approach / M. Mudassir, S. Bennbaia, D. Unal, M. Hammoudeh. – 2020.*
5. *Altan A. Digital currency forecasting with chaotic meta-heuristic bio-inspired signal processing techniques / A. Altan, S. Karasu, S. Bekiros. – 2019.*
6. *Gilles J. Empirical wavelet transform / J. Gilles – 2013.*
7. *Stocchi M. Fast wavelet transform assisted predictors of streaming time series / M. Stocchi, M. Marchesi – 2018.*
8. *Parvini N. Forecasting Bitcoin returns with long short-term memory networks and wavelet decomposition: A comparison of several market determinants / N. Parvini, M. Abdollahi, S. Seifollahi, D. Ahmadian. — 2022.*
9. *Haar A. Zur Theorie der orthogonalen Funktionensysteme / A. Haar // Math. Ann. 69, 1910. – P. 331–371.*
10. *Daubechies I. Orthonormal bases of compactly supported wavelets / I. Daubechies – 1988.*
11. *Percival D. Wavelet Methods for Time Series Analysis Cambridge Series in Statistical and Probabilistic Mathematics / D. Percival, A. Walden – 2000.*
12. *Tsai D.-M. Automatic band selection for wavelet reconstruction in the application of defect detection. Image and Vision Computing / D.-M. Tsai, C.-H. Chiang – 2003.*
13. *Lahmiri S. Wavelet low- and high-frequency components as features for predicting stock prices with backpropagation neural networks / S. Lahmiri // Journal of King Saud University - Computer and Information Sciences, Vol. 26, Issue 2. – 2014. – P. 218-227.*

References:

1. Alahmari, S. (2019). *Using Machine Learning ARIMA to Predict the Price of Cryptocurrencies.*
2. Altan, A., Karasu, S. and Bekiros, S. (2019). *Digital currency forecasting with chaotic meta-heuristic bio-inspired signal processing techniques.*

3. Box, G., Jenkins, G., Reinsel, G. and Ljung, G. (2016). *Time Series Analysis: Forecasting And Control, 5th ed. John Wiley & Sons. Inc.*
4. Daubechies, I. (1988). *Orthonormal bases of compactly supported wavelets.*
5. Gilles, J. (2013). *Empirical wavelet transform.*
6. Haar, A. (1910). "Zur Theorie der orthogonalen Funktionensysteme". *Math. Ann.* 69, pp. 331–371.
7. Kim, Y., Kim, J., Kim, W., Im, J., Kim, T., Kang, S. and Kim, C. (2016). *Predicting Fluctuations in Cryptocurrency Transactions Based on User Comments and Replies.*
8. Lahmiri, S. (2014). "Wavelet low- and high-frequency components as features for predicting stock prices with backpropagation neural networks", *Journal of King Saud University - Computer and Information Sciences*, Vol. 26, Issue 2, pp. 218-227.
9. Mudassir, M., Bennbaia, S., Unal, D. and Hammoudeh, M. (2020). *Time-series forecasting of Bitcoin prices using high-dimensional features: a machine learning approach.*
10. Parvini, N., Abdollahi, M., Seifollahi, S. and Ahmadian, D. (2022). *Forecasting Bitcoin returns with long short-term memory networks and wavelet decomposition: A comparison of several market determinants.*
11. Percival, D. and Walden, A. (2000). *Wavelet Methods for Time Series Analysis Cambridge Series in Statistical and Probabilistic Mathematics.*
12. Stocchi, M. and Marchesi, M. (2018). *Fast wavelet transform assisted predictors of streaming time series.*
13. Tsai, D.-M. and Chiang, C.-H. (2003). *Automatic band selection for wavelet reconstruction in the application of defect detection. Image and Vision Computing.*

Статтю представив д-р ф.-м. наук, доцент О.Д. Кічмаренко.

Надійшла (received) 10.11.2022

Milovska Karyna, master
Odesa I.I.Mechnikov National University
Str. Kosmonavtiv, 62, Odesa, Ukraine, 65078
Tel.: (093) 794-34-37, email: karina-milovskaya@stud.onu.edu.ua
ORCID ID:0000-0002-2156-8231

Moroz Volodymyr, PhD, Associate Professor
Odesa I.I.Mechnikov National University
Str. Dvorianska, 2, Odesa, Ukraine, 65082
Tel.: (093) 273-45-55, email: v.moroz@onu.edu.ua
ORCID ID:[0000-0002-3240-4590](https://orcid.org/0000-0002-3240-4590)

УДК 004.932

Вейвлетний аналіз та прогнозування фінансових часових рядів / Міловська К.М., Мороз В.В. // Вісник НТУ "ХПІ". Серія: Інформатика та моделювання. – Харків: НТУ "ХПІ". – 2022. – № 1 – 2 (7 – 8). – С. 117 – 127.

В роботі розглянуто моделі та методи прогнозування фінансових часових рядів. Проаналізовано основні переваги та недоліки традиційних моделей та нейронних мереж для прогнозування без попередньої обробки даних. Застосовано вейвлетний аналіз та рекурентна нейромережа з довгою короткостроковою пам'яттю (LSTM) для прогнозування курсу криптовалюти. Отримані результати порівнюються з результатами існуючих підходів, визначено ефективність запропоновано рішення. Іл.: 6. Табл.: 2. Бібліогр.: 13 назв.

Ключові слова: фінансові часові ряди; нейронні мережі; прогнозування; попередня обробка даних; вейвлетний аналіз; рекурентна нейромережа з довгою короткостроковою пам'яттю; курс криптовалюти.

УДК 004.932

Wavelet analysis and forecasting of financial time series / Milovska K.M., Moroz V.V. // Herald of the National Technical University "KhPI". Series of "Informatics and Modeling". – Kharkov: NTU "KhPI". – 2022. – № 1 – 2 (7 – 8). – P. 117 – 127.

Models and methods of forecasting financial time series are considered in the work. The main advantages and disadvantages of traditional models and neural networks for forecasting without data preprocessing are analyzed. Wavelet analysis and a recurrent neural network with long short-term memory (LSTM) were applied to predict the exchange rate of cryptocurrency. The obtained results are compared with the results of existing approaches, the efficiency is determined and a solution is proposed. Figs.: 6. Tabl.: 2. Refs.: 13 titles.

Keywords: financial time series; neural networks; forecasting; data preprocessing; wavelet analysis; recurrent neural network with long short-term memory; cryptocurrency exchange rate.