

МІЖНАРОДНІ ЕКОНОМІЧНІ ВІДНОСИНИ

УДК 004.942:[336.743]:519.868

DOI:10.32680/2409-9260-2020-3-4-276-277-153-163

МОДЕЛЮВАННЯ КОРОТКОСТРОКОВОЇ ДИНАМІКИ ВАЛЮТНИХ КУРСІВ З ВИКОРИСТАННЯМ ГЛИБОКИХ НЕЙРОННИХ МЕРЕЖ

Дербенцев В. Дж., кандидат економічних наук, професор кафедри інформатики та системології, Київський національний економічний університет імені Вадима Гетьмана, м. Київ, Україна

e-mail derbv@kneu.edu.ua

ORCID 0000-0002-8988-2526

Безкоровайний В. С., асистент кафедри інформатики та системології, Київський національний економічний університет імені Вадима Гетьмана, м. Київ, Україна

e-mail retal.vs@kneu.edu.ua

ORCID 0000-0002-4998-8385

Овчаренко А. А., старший викладач кафедри інформатики та системології, Київський національний економічний університет імені Вадима Гетьмана, м. Київ, Україна

e-mail ov_andrei@i.ua

ORCID 0000-0002-0729-4369

***Анотація.** Робота присвячена питанням короткострокового прогнозування валютних курсів за допомогою моделей глибокого навчання. З цією метою було побудовано модель глибокого навчання на основі синтезу нейронних мереж загорткового (CNN) та рекурентного (RNN) типу. Згорткова мережа виконує функцію вилучення ознак, а рекурентна мережа на основі моделі «довготривалої короткочасної пам'яті» (LSTM) здійснює безпосередньо прогноз. Проведено прогнозні розрахунки динаміки котирувань для валютних пар євро/долар (EUR/USD) та британського фунту (GBP/USD), а також для двох найбільш капіталізованих криптовалют (біткоїна – BTC/USD та ефіріума – ETH/USD) з використанням щоденних та чотиригодинних спостережень. Проведені комп'ютерні експерименти підтвердили перспективність застосування моделей глибокого навчання для задач короткострокового прогнозування часових рядів як фіатних, так і криптовалют.*

***Ключові слова:** глибоке навчання, нейронні мережі, короткострокове прогнозування, часові ряди валютних котирувань, криптовалюти.*

MODELING OF SHORT-TERM DYNAMICS OF FOREIGN EXCHANGE RATES USING DEEP NEURAL NETWORKS

Vasily Derbentsev, PhD in Economics, Associate Professor at the Department of Informatics and Systemology, Kyiv National Economic University named after Vadym Hetman, Kyiv, Ukraine

e-mail derbv@kneu.edu.ua

ORCID 0000-0002-8988-2526

Vitalii Bezkorovainyi, assistant professor at Informatics and Systemology, Kyiv National Economic University named after Vadym Hetman, Kyiv, Ukraine

e-mail retal.vs@kneu.edu.ua

ORCID 0000-0002-4998-8385

Andrey Ovcharenko, senior lecturer at the Department of Informatics and Systemology, Kyiv National Economic University named after Vadym Hetman, Kyiv, Ukraine

e-mail ov_andrei@i.ua

ORCID 0000-0002-0729-4369

Abstract. *This paper is devoted to the short-term predicting of exchange rates using Deep Learning approaches (DL). The undeniable advantage of using deep networks is their ability to find hidden complex nonlinear patterns in the data, as well as to identify influential factors (carry out automatic feature extraction). For this purpose, the DL models were built on the basis of Convolutional (CNN) and Recurrent (RNN) Neural Networks. The CNN block performs the function of feature extraction, and the RNN which based on the Long-term Short-term Memory (LSTM) performs the forecast. For parameters estimating and testing the models we used daily and four hourly observations of currencies Euro/Dollar, British pound/Dollar, and cryptocurrencies (Bitcoin and Ethereum) for the period from 02/01/2015 to 12/31/2020 according to the service Yahoo Finance. As input data, we used open prices (Open), minimum (Low), maximum (High), and close prices (Close) for the corresponding timeframe. In the experimental section we compared the performance of the designed models using both daily and four-hour data sets. The accuracy of the forecasting performance was assessed by the values of the Mean Absolute Percentage Error (MAPE), which allows comparing forecast errors for different assets and models. In addition, the Mean Square Error (MSE) and the Root Mean Square Error (RMSE) were also calculated. The highest accuracy (in the sense of the MAPE metrics) was for the EUR/USD – about 0.4% for both daily and for-hour data sets. More volatile GBP/USD quotes show a larger error on both daily and four-hour quotes. But in general, an increase in the number of observations in four-hour time series reduces the model error for EUR/USD and GBP/USD. The results of the cryptocurrencies forecast turned out to be less accurate: 5.9% and 8.5%, respectively. Our study showed the prospects of using DL networks such as CNN and LSTM to predicting the short-term exchange rates. According to obtained results proposed models provide an efficient forecast for both fiat and cryptocurrencies.*

Keywords: *deep learning, neural networks, short-term forecasting, time series of currency quotes, cryptocurrencies.*

JEL Classification: G170

Постановка проблеми у загальному вигляді та її зв'язок з важливими науковими чи практичними завданнями. Глобалізація і лібералізація світової економіки, найбільш помітно проявляється у фінансовій сфері, супроводжується зростанням міграції капіталу між країнами і різними сегментами фінансового ринку. Ці процеси об'єктивно посилюють невизначеність щодо динаміки валютних курсів і призводять до зростання валютних ризиків.

Проте процес глобалізації та інтеграції у світовій економіці супроводжується помітним зростанням нестабільності міжнародного валютного ринку, діяльність на якому для вітчизняних підприємств і організацій є супутньою при здійсненні зовнішньоторговельних угод у вигляді фінансових зобов'язань і валютних операцій. Крім того, операції на валютному ринку відчутно впливають на структуру доходів інституційних інвесторів.

Нестійкість валютних курсів привнесла в діяльність українських банків і компаній значну невизначеність оцінки майбутніх грошових потоків, що підсилює ризик великих збитків і навіть банкрутства. Для підвищення ефективності операцій, що проводяться в іноземній валюті особливої актуальності набувають завдання щодо отримання достовірних прогнозів валютного курсу і зниження валютного ризику, принаймні на короткотермінову перспективу.

Тому, незважаючи на велике різноманіття існуючих методів та моделей прогнозування валютних курсів [1], питання розроблення та вдосконалення прогностичного інстру-

ментарію, зокрема, із використанням сучасних методів і підходів машинного та глибокого навчання, є актуальними як з теоретичної, так і з прикладної точки зору.

Аналіз останніх досліджень і публікацій з даної теми, виділення невирішених раніше частин загальної проблеми, котрим присвячується означена стаття. Прогнозуванню фінансових часових рядів, зокрема, валютних курсів та криптовалют, із використанням методів машинного навчання присвячено роботи [2-6]. Головний висновок авторів цих робіт полягає в тому, що моделі машинного навчання, перш за все нейронні мережі, показують більшу точність, ніж моделі часових рядів.

Детальний огляд останніх публікацій в галузі застосування моделей глибокого навчання для прогнозування фінансових часових рядів проведено в роботі [7].

В роботах [8-10] наведено результати застосування глибоких нейронних мереж до прогнозування зміни напрямів трендів валютних курсів (задача класифікації).

В роботі [9] точність класифікації валютної пари з використанням глибокої мережі типу LSTM Євро/Долар для щоденних значень становила близько 70%, а для криптовалюти Біткоїн – 72 %.

Згідно з результатами роботи [10], моделі типу LSTM показали кращу точність класифікації для напряму зміни тренду криптовалюти ефіріум, ніж глибокі моделі на основі багатоварового перцептронну (похибка класифікації для добових даних в термінах метрики MAPE близько 4 %).

Автори дослідження [11] застосували ансамблі моделей глибоких мереж рекурентної та загортової архітектури, а також їх ансамблі як для задачі прогнозу цін криптовалют (BTC, ETH, XRP) на наступну годину (регресія), так і для прогнозу зміни напряму руху ціни (класифікація). Кращі з розроблених авторами архітектур показали точність класифікації у межах 52-55 %.

Виділення невирішених раніше частин загальної проблеми, котрим присвячується стаття. Протягом тривалого часу найбільш поширеними підходами до прогнозування валютних курсів було застосування економетричних моделей та апарату часових рядів. Але внаслідок стохастичності та нелінійної природи фінансових часових рядів, в тому числі і валютних курсів, останнім часом все більшою популярністю для задач прогнозування користуються непараметричні методи та моделі машинного навчання, зокрема, нейронні мережі.

Останні роки для прогнозування валютних курсів почали використовувати глибокі нейронні мережі рекурентного типу, зокрема, «довгострокової короткочасної пам'яті» (LSTM). Значно менше уваги в задачах прогнозу часових рядів було приділено застосуванню глибоких мереж іншої архітектури – згорткових, які довели свою ефективність при обробці зображень. На наш погляд, перспективним підходом до прогнозування валютних курсів є поєднання в моделі сильних рис мереж обох типів.

Формулювання мети статті (постановка завдання). Метою нашої роботи є побудова моделі короткострокового прогнозування валютних курсів (фіатних та криптовалют) із застосуванням стекингу глибоких нейронних мереж рекурентного та загорткового типу, проведення комп'ютерних експериментів з метою оцінки ефективності та точності побудованих моделей.

Викладення основного матеріалу дослідження з повним обґрунтуванням отриманих наукових результатів. Методи машинного навчання широко і успішно застосовуються для таких задач, як кластеризація, класифікація і розпізнавання об'єктів. Дослідники давно прагнули використовувати потенціал штучних нейронних мереж для передбачення.

Рекурентні нейронні мережі (RNN) стають все більш популярними для моделювання часових рядів і природної мови і досягають передових результатів на популярних наборах даних. У той час як мережі прямого поширення (наприклад, багатошаровий перцептрон) враховують фіксовану кількість часових даних для прогнозування наступного спостереження, рекурентні нейронні мережі можуть враховувати всі попередні часові кроки.

Але звичайні RNN не можуть моделювати довготривалі часові залежності через проблеми зникаючого градієнта. Ця проблема вирішується такими різновидами RNN-архітектури, як Long Short-Term Memory (LSTM) та модель Gated Recurrent Neural Networks (GRU), що є модифікацією моделі LSTM. Вони складаються із декількох повнозв'язних компонентів, які вловлюють просторово-часові залежності в даних. Це дозволяє враховувати при моделюванні часових рядів не тільки короткочасні залежності, але і довготривалі.

Моделі глибоких мереж на основі цих архітектур довели перспективність їх застосування до задач прогнозування фінансових часових рядів, у тому числі і валютних курсів [7-12].

Згорткові нейронні мережі (CNN) є основним інструментом для роботи з даними, що мають просторову структуру. Вони успішно застосовуються для вилучення просторових властивостей графічних зображень та потокового відео або аудіо.

Останнім часом здійснюються спроби поєднання мереж CNN та RNN (стекинг) з метою одержання більш ефективного інструменту для прогнозу часових рядів (див., наприклад, [7, 11-12]).

Блок CNN і блок LSTM сприймають однакові введення часових рядів у двох різних уявленнях. CNN розглядає часовий ряд як одновимірний часовий ряд із безліччю часових кроків. Якщо існує часовий ряд довжиною L , блок CNN отримує дані через L часових кроків.

На відміну від цього, блок LSTM отримує введені часові ряди як багатовимірні часові ряди з одним часовим кроком. Це досягається шаром перемішування розмірів, який транспонує часовий вимір часового ряду. Одновимірний часовий ряд довжиною L , після перетворення, буде розглядатися як багатовимірний часовий ряд (що має L змінних) з одним кроком часу.

Без перемішування розмірів продуктивність блоку LSTM значно знижується через швидке перенавчання малих наборів даних валютних котирувань з короткою послідовністю та невміння вивчати довгострокові залежності у більших наборах даних валютних котирувань з довгою послідовністю.

Розмірне переміщення покращує ефективність LSTM моделі, вимагаючи на порядок менше часу на тренування. Коли в наборі даних із L часових кроків та N змінних використовується LSTM без перемішування розмірів, LSTM вимагає L часових кроків для обробки партії N змінних. На відміну від цього, застосування вимірювання розмірів до входних даних дозволить моделі LSTM обробляти партію L змінних за N часових кроків. Це свідчить про те, що до тих пір, поки кількість змінних N значно менша за кількість часових кроків L , перемішування розмірів значно покращить швидкість навчання. Оскільки кожен з наборів даних валютних котирувань є одноваріантним, компоненту LSTM цієї моделі буде потрібно лише 1 часовий крок для обробки партії L змінних [12].

Використання LSTM зводиться до обробки одного параметру часових даних котирувань валюти одночасно. Кожні дані котирувань валюти відокремлюються та обробляються незалежно, а потім оброблені дані з кожного котирування валюти об'єднуються та

обробляються для оцінки остаточного прогнозу. Обґрунтування запропонованого підходу полягає у розробці навчальної моделі, яка може самостійно витягувати корисну інформацію з різних даних котирувань валюти та згодом обробляти цю інформацію для досягнення точних та надійних прогнозів.

Припустимо, що ми маємо дані котирувань валюти: ціна відкриття (Open), мінімум (Low), максимум (High), ціна закриття (Close) за відповідний таймфрейм. Кожні дані котирування валюти використовуються як вхідні дані в унікальний згортковий шар, за яким слідує рівень LSTM та рівень об'єднання. Запропонований підхід фокусується на використанні здатності згорткових шарів для вилучення корисних знань шляхом вивчення внутрішнього представлення кожного набору даних котирувань валюти незалежно, а також ефективності рівнів LSTM для виявлення короткострокових та довгострокових залежностей. Потім вихідні вектори всіх шарів LSTM об'єднуються об'єднаним шаром. Цей шар супроводжується низкою шарів, які становлять класичну структуру нейронної мережі глибокого навчання, тобто щільний (повнозв'язний) шар, шари пакетної нормалізації, шар відсіву, повнозв'язний шар і кінцевий вихідний шар з одного нейрона. Архітектуру такої моделі наведено на рис. 1.

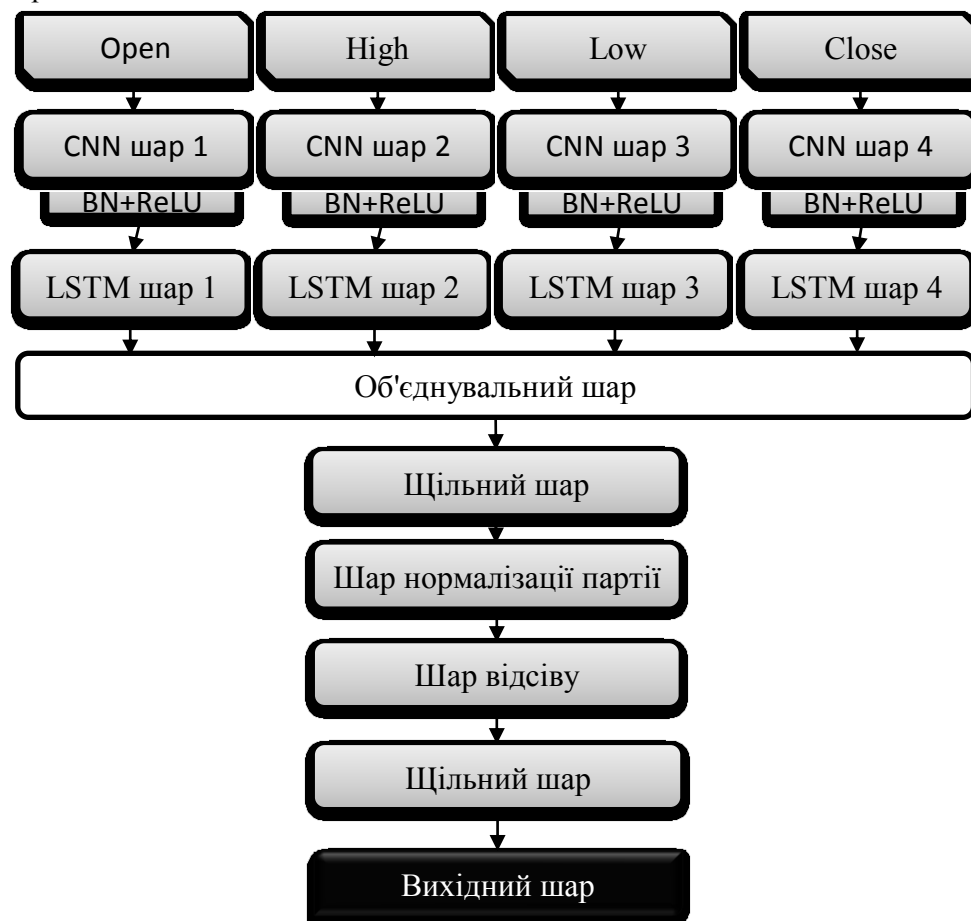


Рис. 1. Архітектура моделі глибоких нейронних мереж з декількома входами
Джерело: побудовано авторами

Традиційна модель глибокої нейронної мережі здатна аналізувати та кодувати будь-яку складну функцію, згортковість її навчального процесу може погіршуватися через кількість ваг, яка експоненційно збільшується зі збільшенням кількості шарів та за рахунок проблеми зникаючого градієнта, яка зазвичай виникає у великих мережах. На відміну від

цього, суттєвими перевагами архітектури запропонованої моделі є те, що вона забезпечує більшу гнучкість та адаптивність [11].

Наведемо короткий опис основних елементів запропонованої моделі, тобто шарів згортки та об'єднання, повнозв'язні шари, шари пакетної нормалізації та шари відсіву:

– згортковий шар характеризується своєю чудовою здатністю засвоювати внутрішнє представлення своїх входів. Це виконується шляхом застосування згорткових операцій між вхідними даними та використанням ядер згортки, званих «фільтрами», для виявлення нових значень властивостей [10];

– об'єднувальний шар використовується для зменшення просторових розмірів з метою зменшення кількості операцій, необхідних для всіх наступних шарів. Менша просторова інформація означає меншу вагу, тому менше шансів перенавчити модель. Ці шари використовуються для зменшення вибірки результатів попереднього згорткового шару, намагаючись передати лише дійсну та корисну інформацію [7];

– щільний шар призначений для складання прихованого шару глибокої нейронної мережі [9]. Зокрема, кожен щільний шар складається з нейронів, які зв'язані з усіма нейронами попереднього шару. Як правило, щільні шари додають властивість нелінійності, і теоретично нейронна мережа, складена щільними шарами, здатна моделювати будь-яку математичну функцію [12];

– шар нормалізації партії – методика навчання глибоких нейронних мереж, яка фокусується на стабілізації процесу навчання шляхом стандартизації входів наступного рівня для кожної міні-партії. Нормалізація пакетів збільшує координацію оновлень у інших шарах і прискорює навчання, зменшуючи кількість епох [10];

– шар відсіву – метод регулювання для запобігання перенавчання нейронних мереж, який додається між існуючими шарами моделі нейронної мережі. Він застосовується до виходів попереднього рівня і тимчасово встановлює довільний набір виходів до нуля з заздалегідь визначеною ймовірністю, які подаються на наступний рівень [7].

Після формування архітектури моделі CNN-LSTM необхідно перейти до навчання такої моделі за допомогою моделі градієнтного спуску.

У набір даних, який використовується для оцінки моделі, було включено денні (D1) валютні котирування EUR/USD (євро до долару США), GBP/USD (британської фунту до долару США) та криптовалюти BTC/USD (Біткоїн до Долару США), ETH/USD (ефіріум до долару США) за період з 01.01.2015 по 31.12.2019. Тестування моделі було проведено на часових рядах відповідних валютних котирувань з 01.01.2020 по 01.12.2020.

Вхідні часові дані зазвичай нормалізуються при використанні глибоких нейронних мереж в діапазон (0, 1), адже це безпосередньо впливає на функції активації, саме тому дослідженні значення валютних котирувань були переведено в діапазон (0, 1) за допомогою мінімаксної нормалізації:

$$x_{\text{норм}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

Нормалізовані дані були надані як вхідні дані в мережу з вікном для навчання – 7 днів, прогнозування здійснюється на наступну добу. Для тренування моделі використовується 70% часового ряду, для валідації – 30%.

Наявність у моделі глибокої нейронної мережі декількох входів та додаткових шарів призводить до більш швидкого навчання та істотного зменшення похибки на перших ітераціях (епохах). Так для валютних котирувань до 20 епохи спостерігається поступове

зменшення похибки відповідно до прогресу навчання моделі (рис. 2).

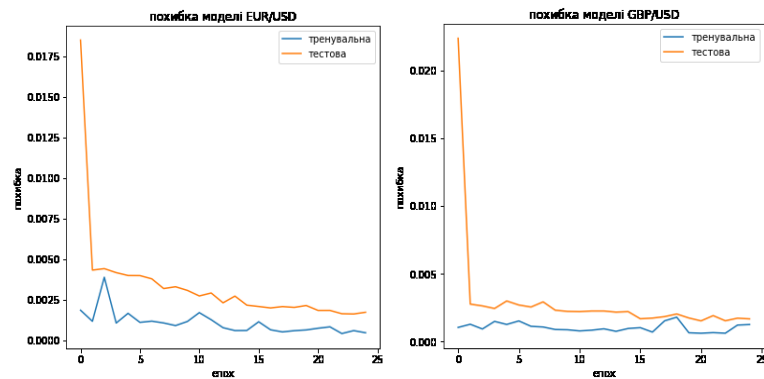


Рис. 2. Похибка моделей прогнозування валютних котирувань EUR/USD та GBP/USD

Джерело: побудовано авторами

Похибка моделі для криптовалют має декілька сплесків, вони пов'язані з відповідними «сплесками» котирувань та, відповідно, мають стрімкі зростання та падіння і у тренувальному наборі даних (рис. 3). Після 20 епохи модель приймає стабільний стан, відповідно її тепер можна застосовувати для прогнозування валютних котирувань.




Рис. 3. Похибка моделей прогнозування котирувань криптовалют BTC/USD та ETH/USD

Джерело: побудовано авторами

Розподілення тестової та прогнозованої вибірки валютних котирувань наведено на рис. 4. На графіку EUR/USD спостерігається низька дисперсія та мінімальні відхилення від вісі, що підтверджує ефективність моделі. Низьке значення R^2 та великий розкид на графіку GBP/USD пов'язано з великою волатильністю у 2020 році внаслідок Brexit та перемовин щодо угоди про подальшу співпрацю.




Рис. 4. Співвідношення реальних та прогнозованих валютних котирувань EUR/USD та GBP/USD

Джерело: побудовано авторами

Друга половина 2020 року ознаменувалася стрімким зростанням ринку криптовалют. Відповідно рис. 5 котирування BTC/USD до позначки 20 000\$ мають нормальне розподілення, а у момент стрімкого росту прогнозовані значення відстають від реальних. Подібна ситуація спостерігається і для котирувань ETH/USD після відмітки у 500\$.




Рис. 5. Співвідношення реальних та прогнозованих котирувань криптовалют BTC/USD та ETH/USD

Джерело: побудовано авторами

Для розширення набору даних оцінки ефективності моделі було додано чотиригодинні котирування (H4 – 6 котирувань на добу), це дозволяє збільшити набір даних в тренувальній та тестовій вибірках, за той самий проміжок часу. Таким чином вікно для навчання моделі складає 42 періоди (7 днів), горизонт прогнозування 6 періодів (1 день).

Точність прогнозування валютних котирувань було оцінено за значеннями середньої абсолютної похибки у відсотках (MAPE), яка дозволяє порівнювати похибки прогнозу як для різних активів, так і моделей. Окрім цього, було також розраховано середньоквадратичну похибку (MSE), та корінь із середньоквадратичної помилки (RMSE). Формули для розрахунку цих показників наведено нижче:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - y_i^{predicted})^2,$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y_i^{predicted})^2},$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - y_i^{predicted}}{y_i} \right|.$$

Тут $y_i, y_i^{predicted}$ – фактичні та прогнозовані значення часового ряду відповідно, N – кількість спостережень.

Остаточні результати точності прогнозу побудованих моделей наведено у таблиці 1.

Таблиця 1

Кількісна оцінка ефективності запропонованої моделі

Показники	Котирування			
	EUR/USD	GBP/USD	BTC/USD	ETH/USD
	D1			
MSE	0,000041	0,000420	505420,41	526,23
RMSE	0,006442	0,020493	710,92	22,93

MAPE	0,434%	1,280%	3,745%	6,919%
	H4			
MSE	0,000036	0,000119	766065,11	612,46
RMSE	0,005963	0,010888	875,25	24,74
MAPE	0,408%	0,624%	5,890%	8,525%

Джерело: побудовано авторами

Таким чином, аналіз даних табл. 1 свідчить, що краща точність (у сенсі показників MAPE) виявилась для EUR/USD – близько 0,4% як для щоденних, так і для чотиригодинних наборів даних. Більш волатильні котирування GBP/USD демонструють більшу помилку як на щоденних, так і для чотиригодинних даних. Але в цілому, збільшення кількості спостережень у чотиригодинних часових рядах зменшує похибку моделі для EUR/USD та GBP/USD.

Результати прогнозу криптовалют виявились менш точними: 5,9% та 8,5% відповідно, що можна пояснити більш високою волатильністю досліджуваних часових рядів.

Висновки з даного дослідження і перспективи подальших розробок за даним напрямом. Проведене дослідження дозволяє зробити висновок, що в цілому моделі показали вищу точність при використанні часових рядів фіатних валют, ніж для криптовалют. Більш волатильні котирування GBP/USD показують більшу похибку як на денних так і на чотиригодинних котируваннях. Але загалом збільшення кількості котирувань чотиригодинних часових рядів призводить до зменшення похибки моделі для EUR/USD та GBP/USD. Інша ситуація спостерігається при використанні часових рядів криптовалют, збільшення набору часових котирувань призводить до збільшення похибки через, як було відмічено вище, відставання прогнозованих котирувань від реальних.

Перевагою запропонованої моделі є поєднання позитивних рис нейронних мереж обох типів: згорткові нейронні мережі дозволяють побудувати новий простір ознак, а рекурентні мережі – виявити приховані паттерни в динаміці валютних котирувань.

Варто зазначити, що оскільки кожний з компонентів глибокого навчання ініціалізується з різними ваговими станами, то це призводить до того, що модель фокусується на різних виявлених закономірностях. Отже, поєднання згорткових та рекурентних нейромереж через стекінгову архітектуру призводить до більш стабільної та надійної моделі прогнозування.

Список літератури:

1. Международная практика прогнозирования мировых цен на финансовых рынках (сырье, акции, курсы валют) / под ред. Я.М. Миркина. Москва: Магистр, 2014. 456 с.
2. Persio, L., Honchar, O. Multitask machine learning for financial forecasting. International Journal of Circuits, Systems and Signal Processing. 2018. Vol. 12. P. 444–451.
3. В.Д. Дербенцев, Г.І. Великоіваненко, Н.В. Даценко. Застосування методів машинного навчання до прогнозування часових рядів криптовалют. Нейро-нечіткі технології моделювання в економіці. 2019. № 8. С. 65-93.
4. Hamid, S.A., Habib, A. Financial forecasting with neural networks. Academy of Accounting and Financial Studies Journal. 2014. Vol. 18(4). P. 37-55.
5. Hitam, N.A., Ismail, A.R. Comparative Performance of Machine Learning Algorithms for Cryptocurrency Forecasting. 2018. URL: <https://www.researchgate.net/publication/327415267> (дата звернення: 01.12.2020).

6. Bahrammirzaee, A. A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. *Neural Comput. Appl.* 2010. Vol. 19(8), P. 1165–1195.
7. Sezer O.B., Gudelek M.U., Ozbayoglu A.M. Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*. 2020. Vol. 90. Article number 106181.
8. Дербенцев В.Д., Безкоровайний В.С., Луняк І.В. Застосування методів глибокого навчання до прогнозування зміни короткострокових трендів валютних курсів. *Науковий вісник Мукачівського державного університету. Секція: економіка*. 2020. № 7(2). С. 75-86.
9. Kumar, D., Rath, S.K.: Predicting the Trends of Price for Ethereum Using Deep Learning Technique, in: *Artif. Intell. Evol. Comput. Eng. Syst.*, pp. 103–114, Springer (2020)
10. Saxena, A., Sukumar, T. Predicting bitcoin price using LSTM and compare its predictability with ARIMA model. *International Journal of Pure and Applied Mathematics*. 2018. Vol. 119(17). P. 2591-2600.
11. Livieris, I.E., Pintelas, E., Stavroyiannis, S., & Pintelas, P. Ensemble deep learning models for forecasting cryptocurrency time-series. *Algorithms*. 2020. Vol. 13(5), article number 121.
12. Bao W, Yue J, Rao Y A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLoS ONE*. 2017. Vol. 12(7): e0180944. doi: <https://doi.org/10.1371/journal.pone.0180944>

References:

1. Mirkina, Ja.M. (2014) *Mezhdunarodnaja praktika prognozirovanija mirovyh cen na finansovyh rynkah (syr'e, akcii, kursy valjut)*. Moscow: Magistr [in Russian].
2. Persio, L., Honchar, O. (2018) Multitask machine learning for financial forecasting. *International Journal of Circuits, Systems and Signal Processing*. Vol. 12. 444–451.
3. Derbentsev, V.D., Velykoivanenko, H.I. & Datsenko N.V. (2019) Zastosuvannia metodiv mashynnoho navchannia do prohnozuvannia chasovykh riadiv kryptovaliut. *Neiro-nechitki tekhnologii modeliuvannia v ekonomitsi*. 8, 65-93 [in Ukrainian]
4. Hamid, S.A., Habib, A. (2014) Financial forecasting with neural networks. *Academy of Accounting and Financial Studies Journal*. Vol. 18(4). 37-55.
5. Hitam, N.A., Ismail, A.R. (2018) Comparative Performance of Machine Learning Algorithms for Cryptocurrency Forecasting. Retrieved from <https://www.researchgate.net/publication/327415267>.
6. Bahrammirzaee, A. (2010) A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. *Neural Comput. Appl.* Vol. 19(8), 1165–1195.
7. Sezer O.B., Gudelek M.U., Ozbayoglu A.M. (2020) Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*. Vol. 90. Article number 106181.
8. Derbentsev, V.D., Bezkorovainyi, V.S. & Luniak I.V. (2020) Zastosuvannia metodiv hlybokoho navchannia do prohnozuvannia zminy korotkostrokovykh trendiv valiutnykh kursiv. *Naukovi visnyk Mukachivskoho derzhavnoho universytetu. Sektsiia: ekonomika*. 7(2), 67-81 [in Ukrainian].
9. Kumar, D., Rath, S.K. (2020) Predicting the Trends of Price for Ethereum Using Deep Learning Technique, in: *Artif. Intell. Evol. Comput. Eng. Syst.*, 103–114, Springer.

10. Saxena, A., Sukumar, T. (2018) Predicting bitcoin price using LSTM and compare its predictability with ARIMA model. *International Journal of Pure and Applied Mathematics*. Vol. 119(17), 2591-2600.

11. Livieris, I.E., Pintelas, E., Stavroyiannis, S., & Pintelas, P. (2020) Ensemble deep learning models for forecasting cryptocurrency time-series. *Algorithms*. Vol. 13(5), article number 121.

12. Bao W, Yue J, Rao Y (2017) A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLoS ONE*. Vol. 12(7): e0180944. doi: <https://doi.org/10.1371/journal.pone.0180944>