

3. N. V. Thakor, J. G. Webster and W. J. Tompkins, "Estimation of QRS complex power spectra for design of a QRS filter", IEEE Transactions on Biomedical Engineering, vol. BME-31, no. 11, pp. 702-706, Nov., 1986.
4. B. Bradie, "Wavelet packet based compression of single lead ECG", IEEE Transactions on Biomedical Engineering, vol. 43, no. 5, pp. 493-501, May, 1996.
5. G. Ramakrishna and S. Saha, "ECG coding by wavelet based linear prediction", IEEE Transactions on Biomedical Engineering, vol. 44, no. 12, pp. 1253-1261, Dec., 1997.
6. M. L. Hilton, "Wavelet and wavelet packet compression of electrocardiograms", IEEE Transactions on Biomedical Engineering, vol. 43, no. 5, pp. 493-501, May, 1996.
7. I. Baklan, A. Oliynyk, I. Mukha, K. Lishchuk, O. Gavrilenko, S. Reutska, A. Tsitsyliuk, Y. Oliynyk, "ECG signal processing based on linguistic chain fuzzy set // Computational Linguistics and Intelligent Systems (CoLins2021)", 2021. – 11 c.
8. Baklan, I., Mukha, I., Oliynyk, Y., Lishchuk, K., Nedashkivsky, E., & Gavrilenko, O. (2019, January). Anomalies Detection Approach in Electrocardiogram Analysis Using Linguistic Modeling. In International Conference on Computer Science, Engineering and Education Applications (pp. 513-522). Springer, Cham.
9. Baklan, I., Oliynyk, Y., Mukha, I., Lishchuk, K., Gavrilenko, O., Ocheretianyi, O., & Tsitsyliuk, A. (2020). Adaptive Multistage Method of Anomalies Detection in ECG Time Series. *COLINS*.

УДК 004.032.26

НАГУЛЯК А.С.

ВИКОРИСТАННЯ МОДЕЛІ CLSTM ДЛЯ ПРОГНОЗУВАННЯ КУРСУ АКЦІЙ ФОНДОВОГО РИНКУ

Оскільки в сучасному суспільстві управління інвестиційним капіталом стало основним напрямком сучасної епохи, все більше вчених розробляють методи прогнозування фондового ринку. Дані про ціни на акції мають характеристики часових рядів. Відповідно до особливостей фінансових часових рядів, ця стаття пропонує нову модель для досягнення більш точного прогнозу ціни акцій, яка поєднує нейронну мережу згортки (CNN) і нейронну мережу довгострокової пам'яті (LSTM). Запропонована модель використовує здатність згорткових шарів для отримання корисних характеристик даних, а також ефективність шарів довготривалої пам'яті (LSTM) для визначення короткострокових і довгострокових залежностей. Згідно з результатами експерименту, Convolutional LSTM може забезпечити значний приріст у підвищенні ефективності прогнозування у порівнянні з сучасними моделями глибокого навчання та машинного навчання. Цей метод прогнозування надає нову дослідницьку ідею для прогнозування курсу акцій використовуючи для навчання фінансові часові ряди.

КЛЮЧОВІ СЛОВА: Передбачення фондового ринку, нейронні мережі, часові ряди, глибоке навчання, згорткова мережа, мережа довгострокової пам'яті.

As investment capital management has become the focus of the modern era in modern society, more and more scientists are developing methods for forecasting the stock market. We can evaluate stock market data as a time series. According to the peculiarities of financial time series, this article proposes a new model for achieving a more accurate stock price forecast, which combines a neural network of convolution (CNN) and a neural network of long-term memory. (LSTM). The proposed model uses the ability of convolutional layers to obtain useful data characteristics, as well as the efficiency of long-term memory layers (LSTM) to determine short-term and long-term dependencies. According to the results of the experiment, Convolutional LSTM can provide a significant increase in improving the efficiency of forecasting compared to modern models of deep learning and machine learning. This method give us a new idea for prediction using stock markets financial time series.

KEYWORDS: Stock market prediction, neural networks, time series, deep learning, convolutional network, long short memory network

1. Вступ

Прогнозування майбутніх цін акцій має важливе значення, оскільки воно може зменшити ризик прийняття рішень шляхом належного визначення майбутнього руху інвестиційного активу. На основі статистики та теорії ймовірності деякі вчені використовують моделі лінійного прогнозування часових рядів, такі як : векторна авторегресія (VAR), байєсовська векторна авторегресія (BVAR), авторегресійний інтегрований режим ковзного середнього (ARIMA) та узагальнена авторегресивна умовна модель гетероскедастичності (GARCH) [1]. Однак точність використання лише моделі часового ряду піддається сумніву через невизначеність та високі шумові характеристики фінансових часових рядів, а зв'язок між незалежними змінними та залежними змінними схильний до динамічних змін у часі, що обмежує подальше застосування та розширення. Є певні обмеження для прогнозування тенденції курсу акцій використовуючи тільки одиночні моделі прогнозування лінійного часового ряду або тільки одиночні моделі нейронної мережі. В даний час поєднання переваг різних методів та використання різних найкращих алгоритмів для створення гібридного методу є тенденцією розвитку глибокого навчання фінансових часових рядів [2]. Тому, щоб найкраще використовувати характеристики часових рядів, глибоко вивчити особливості даних і підвищити точність прогнозування ціни акцій, у цій статті пропонується метод прогнозування ціни акцій на основі метода Convolutional LSTM. Поєднання переваг згорткової нейронної мережі (CNN), яка може витягувати релевантні характеристики з даних, і мережі довгострокової пам'яті (LSTM), яка може знайти взаємозалежність даних часових рядів та автоматично визначити найкращий режим для відповідних даних, створює новий метод який може ефективно підвищити точність прогнозування ціни акцій.

2. Огляд існуючих досліджень

Наразі фінансовий ринок є шумною, непараметричною динамічною системою і існує два основних види методів прогнозування курсу акцій: традиційний метод аналізу та метод машинного навчання.

Традиційні економетричні методи або рівняння з параметрами не підходять для аналізу складних, масивних і шумних даних фінансових рядів. В останні роки нейронна мережа стала “гарячим” напрямком досліджень у сфері прогнозування, оскільки вона може витягувати характеристики із великої кількості високочастотних необроблених даних, не покладаючись на попередні знання. У 1988 році Х. Уайт використав нейронну мережу для прогнозування акцій IBM, але експериментальні результати були не точним [3]. У 2003 році Л. Чжан використовував нейронну мережу та авторегресивну інтегровану модель ковзного середнього (ARIMA) для прогнозування акцій. Експериментальні результати показують, що нейронна мережа має очевидні переваги в нелінійному прогнозуванні даних, але точність ще потребує підвищення [4]. У 2005 році В. Сан запропонував метод прогнозування часових рядів на основі нейронної мережі. Цей метод поєднує в собі оптимальний алгоритм розподілу (OPA) і радіальну базисну функцію (RBF) нейронної мережі, хоча результат все ще не був достатньо точним [5]. У 2014 році М. Адкіхкарі. запропонував метод, що поєднує випадкове блукання (RW) і штучну нейронну мережу (ANN) для прогнозування чотирьох фінансових часових рядів, і результати показали, що точність прогнозування мала певне покращення [6]. У 2018 році Л. Чжан запропонував мережеву структуру прогнозування курсу акцій на основі нейронної мережі LM-BP, яка покращила недоліки традиційного алгоритму навчання нейронної мережі BP – повільну швидкість навчання та низьку точність [7]. У 2018 році результати експериментів М. Ху. показують, що згортка нейронна мережа може передбачати часові ряди, а глибоке навчання більше підходить для вирішення проблеми часових рядів. Однак, оскільки CNN частіше використовується для розпізнавання зображень і виділення ознак, точність прогнозування лише CNN є відносно низькою [8]. У 2020 році Хуан. створив високоточну модель короткострокового прогнозування часових рядів фінансового ринку на основі глибокої нейронної мережі LSTM та порівняв з нейронною мережею BP, традиційною RNN

та вдосконаленою глибокою нейронною мережею LSTM. Результати показали, що глибока нейронна мережа LSTM має високу точність прогнозування і може ефективно передбачати часові ряди фондового ринку.

З огляду на існуючі дослідження, було виявлено, що найкращим методом для передбачення часових рядів з високою точністю є LSTM, а поєднавши її зі згортковою мережею CNN для отримання взаємозв'язка між характеристиками даних, можна отримати новий метод, який значно підвищить точність передбачення курсу акцій.

3. CLSTM

CNN - потужний інструмент машинного навчання, запропонований Яном Лекуном, націлений на ефективне розпізнавання та класифікацію, в першу чергу, зображень [9]. Однак ефективність скорочення розмірності дозволяє використовувати їх також для покращення часових рядів. Обчислення згорткових нейронних мереж засноване на роботі з тензорами. Під тензором розуміється багатовимірний масив чисел (не елемент тензорного простору). Оперування тензорами, а не матрицями дозволяє не втрачати інформацію при переході до меншої розмірності. В даному дослідженні мережа використовується для обробки вхідних даних для покращення остаточного результату, шляхом агрегування кількох змінних (історичних даних, провідних показників), щоб потім передати їх до мережі LSTM




Рис. 1 – блок LSTM

LSTM - тип рекурентної нейронної мережі, здатний вчитися довгостроковим залежностям. Він широко використовується в розпізнаванні мовлення, емоційному аналізі та аналізі тексту, оскільки має власну пам'ять

і може робити відносно точне прогнозування [10]. Останніми роками він також був прийнятий у сфері прогнозування фондового ринку. Комірка пам'яті LSTM складається з трьох частин: гейта забуття, вхідного гейта та вихідного гейта, як показано на рисунку 1.

Процес обчислення LSTM виглядає наступним чином:

На першому етапі LSTM потрібно вирішити, яку інформацію ми збираємось викинути зі стану комірки. Це рішення приймається сигмовидним шаром, званим шаром гейту виходу. Він отримує на вхід h і x і видає число від 0 до 1 для кожного номера в стані комірки C . 1 означає "повністю зберегти", а 0 - "повністю видалити". Формула сигмовидного шару:

$$f_t = \sigma(W_t | h_{t-1}, x_t | + b_f) \quad (1)$$

де діапазон значень f дорівнює $(0,1)$, W - вага гейта забуття, а b_f - зміщення гейта забуття, x - це вхідне значення поточного часу, а h - це вихідне значення останнього моменту

На наступному етапі необхідно вирішити, яку нову інформацію зберегти в стані комірки. Розіб'ємо процес на дві частини. Спочатку сигмоїдний шар, званий шаром гейту входу, вирішує, які значення потрібно оновити за формулою 2. Потім шар $\tanh$ створює вектор нових значень-кандидатів S , які додаються до стану за формулою 3.

$$i_t = \sigma(W_i | h_{t-1}, x_t | + b_i) \quad (2)$$

$$S_t = \tanh(W_c | h_{t-1}, x_t | + b_c) \quad (3)$$

де діапазон значень $(0,1)$, W_i - вага вхідного кандидата, b_i - зміщення вхідного гейта, W_c - вага кандидата вхідного гейта, а b_c - зміщення даних кандидата вхідного гейта.

Оновлення поточного стану клітинки відбувається за формулою 4.

$$C_t = f_t * C_{t-1} + i_t * S_t \quad (4)$$

де діапазон значень $C_t = (0,1)$

Зрештою, треба вирішити, що хочемо отримати на виході. Результат буде відфільтрованим станом комірки. Спочатку запускаємо сигмоїдний шар, який вирішує, які частини стану осередку виводити.

$$\sigma_1 = \sigma W_o [h_{t-1}, x] + b_o \quad (5)$$

де діапазон значень σ $(0,1)$, W - вагою вихідного гейта, а b_o - зміщення виходу

Потім пропускаємо стан комірки через $\tanh$ (щоб розмістити всі значення в інтервалі $[-1,$

1)) та множимо його на вихідний сигнал сигмоподібного гейту.

$$h_t = o_t * \tanh(C_t) \quad (6)$$

Поєднавши мережу CNN та LSTM ми отримаємо новий метод CLSTM, який повинен покращити прогнозування часових рядів. Процес навчання та прогнозування CLSTM показаний на рисунку 2.




Рис. 2 – Діаграма діяльності процесу навчання та прогнозування CLSTM.

Основні кроки такі:

(1) Вхідні дані: дані, необхідні для навчання CLSTM.

(2) Стандартизація даних: оскільки існує великий пробіл у вхідних даних. Щоб краще тренувати модель, для стандартизації вхідних даних використовується метод стандартизації z-score, як показано в наступній формулі (7)

$$y_i = \frac{x_i - z}{s} \quad (7)$$

(3) Ініціалізація мережі: ініціалізація ваги та зміщення кожного рівня CLSTM.

(4) Обчислення CNN шару: вхідні дані послідовно пропускаються через шар згортки та шар об'єднання в шарі CNN, виконується вилучення ознак вхідних даних.

(5) Обчислення LSTM шару: вихідні дані шару CNN обчислюються через шар LSTM

(6) Обчислення вихідного шару: вихідні дані шару LSTM виводиться в загальний рівень для отримання фінального значення даних.

(7) Обчислення похибки: вихідне значення, отримане з вихідного шару, порівнюється з реальним значенням

(8) Перевірка на виконання умов: виконано попередньо визначену кількість циклів, рівень помилок прогнозування нижчий за певний поріг. Якщо одна з умов завершення буде не виконана, навчання буде не завершено, оновлюється вся мережа CLSTM і переходимо до кроку 9, інакше переходимо до кроку 10.

(9) Зворотне розповсюдження помилки: оновлення ваги та зміщення кожного шару та перехід до кроку 4, щоб продовжити навчання мережі.

(10) Збереження моделі: зберегти навчену модель для прогнозування.

(11) Вхідні дані: вхідні дані, необхідні для прогнозування.

(12) Стандартизація даних: вхідні дані стандартизуються за формулою (1).

(13) Процес прогнозування: вхід стандартизованих даних в навчену модель CLSTM, та отримання вихідного значення.

(14) Стандартизоване відновлення даних: вихідне значення, отримане за допомогою моделі CLSTM, є стандартизованим значенням, а стандартизоване значення відновлюється до вихідного значення. Як показано в наступній формулі (8).

$$x_i = y_i * s + z \quad (8)$$

де y_i – у стандартизоване значення, x_i – вхідні дані, z – середнє значення вхідних даних, s – стандартне відхилення вхідних даних.

(15) Вихід результату : вивести результати для завершення процесу прогнозування.

4. Перевірка на ефективність

Щоб довести ефективність CLSTM, було проведено порівняння з MLP, CNN, RNN, LSTM і CNN-RNN, використовуючи той самий навчальний набір і дані тестового набору в одному операційному середовищі.

Усі експерименти проводяться в робочому середовищі Intel i7-5500H, 18 GB RAM, 1 TBs жорсткого диска та Windows 10. Було включено такі фактори впливу, як ціна

відкриття, найвища ціна, найнижча ціна, ціна закриття, обсяг, оборот, підйоми та падіння, зміна за день.

У цьому експерименті в якості експериментальних даних вибрано Yahoo Finance Index. Щоденні торгові дані з 1 жовтня 2012 року по 20 грудня 2020 року. Кожна частина даних містить вісім пунктів, а саме: ціна відкриття, найвища ціна, найнижча ціна, ціна закриття, обсяг, оборот, підйоми та падіння та зміна за день. Приклад даних наведено в таблиці 1.

Для оцінки ефекту прогнозування CLSTM в якості критеріїв оцінки методів використовуються середня абсолютна помилка (MAE), середньоквадратична помилка (RMSE) і R-квадрат (R^2).

Формула розрахунку MAE виглядає так:

$$MAE = \frac{1}{n} \sum_{i=1}^n |g_i - ty_i| \quad (9)$$

де – g прогнозоване значення, y – справжнє значення. Чим менше значення MAE, тим краще прогнозування.

Формула розрахунку RMSE виглядає так:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (g_i - y_i)^2} \quad (10)$$

де – g прогнозоване значення, y – справжнє значення. Чим менше значення RMSE, тим краще прогнозування.

Формула розрахунку R^2 виглядає так:

$$R^2 = \frac{(\sum_{i=1}^n (g_i - y_i)^2) / n}{(\sum_{i=1}^n (z_i - tg_i)^2) / n} \quad (11)$$

де – g прогнозоване значення, – y справжнє значення, а z – середнє значення. Діапазон значень R^2 становить (0,1).

Чим ближче значення MAE і RMSE до 0, тим менша похибка між прогнозованим і реальним значенням, тим вище точність прогнозування. Чим ближче R^2 до 1, тим краще ступінь створення моделі.

Результати оцінки ефективності CLSTM порівняно з MLP, CNN, RNN, LSTM і CNN-RNN, наведено в таблиці 2. З отриманих результатів ми можемо побачити, що з точки зору точності прогнозування, критерій MAE для CLSTM становить 27,564, а критерій RMSE - 39,688, що є найбільш ефективним показником серед шести моделей прогнозування, а з точки зору ефективності прогнозування, критерій R^2 для CLSTM становить 0,9646, що також є найбільш ефективним показником серед всіх досліджуваних моделей. Це показує, що ефективність прогнозування LSTM можна ефективно покращити, витягуючи характеристики даних через CNN. Модель може добре передбачити ціну акцій та надати орієнтир для інвестицій інвесторів.

Табл. 1 Вибіркові дані

Дата	Ціна відкриття	Найвища ціна	Найнижча ціна	Ціна закриття	Оборот	Підйоми \ падіння	Зміна
2015/7/1	123.4	124.6	123.2	123.7	2759823	-0.4	-0.24%
2015/7/2	124.2	125.1	123.5	124.1	2524587	-0.6	+0.15%
2015/7/3	123.1	124.1	122.5	123.5	2959221	-0.2	-0.18%

Табл. 2 Результати експериментів різних методів

	MLP	CNN	RNN	LSTM	CNN-RNN	CLSTM
MAE	36.583	30.423	29.281	28.781	28.385	27.473
RMSE	49.729	42.429	42.419	41.003	40.529	40.102
R^2	0.9442	0.9562	0.9622	0.9621	0.9640	0.9646

Висновок

Аналізуючи фінансові часові ряди цін акцій фондового ринку, пропонується новий метод глибокого навчання (CLSTM) для прогнозування ціни активу. У цьому методі CNN використовується для видалення характеристик даних, а LSTM використовується для

прогнозування даних. Метод може повністю використовувати часову послідовність даних ціни акції для отримання більш надійного прогнозування.

Порівнявши критерії оцінки CLSTM з багатошаровим перцептроном (MLP), CNN, RNN, LSTM і CNN-RNN, доведено, що CLSTM має високу точність прогнозування і більше підходить для прогнозування курсу акцій.

Список літератури

1. J. H. Wang and J. Y. Leu, "Stock market trend prediction using ARIMA-based neural networks," in Proceedings of the IEEE International Conference on Neural Networks (ICNN), pp. 2160–2165, Washington, DC, USA, June 1999
2. S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural Computation, vol. 9, no. 8, pp. 1735–1780, 1997. [Online]. Available: <https://doi.org/10.1162/neco.1997.9.8.1735L>
3. Ho, W.-C. Kao, Y.-Y. Ou, and K.-L. Hua, "Using deep learning neural networks to predict stock market," 2019. [Online]. Available: <https://arxiv.org/abs/1903.12258>.
4. Krollner, B., Vanstone, B.J., Finnie, G.R.: Financial time series forecasting with machine learning techniques: a survey. In: ESANN, pp. 25–30 2010.
5. Bao, W., Yue, J., Rao, Y.: A deep learning framework for financial time series using stacked autoencoders and long-short term memory. PloS One 12(7), e0180944 2017.
6. Baba, N., Kozaki, M.: An intelligent forecasting system of stock price using neural networks. Int. Jt. Conf. Neural Netw. 1, 371–377 1992.
7. S. M. Madge, "Predicting stock price direction using support vectormachines," 2015.
8. Zhao, Z., Zhang, X., Zhou, H., Li, C., Gong, M., Wang, Y.: Hetnerec: Heterogeneous network embedding based recommendation. Knowl. Based Syst. 204, 106218 2020.
9. I. Virtanen and P. Yli-Olli, "Forecasting stock market prices in a thin security market," Omega, vol. 15, no. 2, pp. 145–155, 1987.
10. Armano, G., M. Marchesi, and A. Murru. "A hybrid genetic-neural architecture for stock indexes forecasting." Information Sciences, 2005

УДК 004.051

*АЛЕКСАНДРОВ В. С.,
СТЕЦЕНКО І. В.*

АНАЛІТИЧНА ОБРОБКА ДАНИХ РИНКУ ОРЕНДИ НЕРУХОМОСТІ З ВИКОРИСТАННЯМ OLAP-ТЕХНОЛОГІЇ

У даному науковому дослідженні здійснено огляд специфіки роботи з великими обсягами даних/Запропоновано використання OLAP-технології, що представляє інтуїтивно зрозумілу модель даних, організовуючи їх у вигляді багатомірних кубів. Зібрано перелік рекомендацій які слід мати на увазі під час налаштування та проектування OLAP-кубів, задля забезпечення високої продуктивності і функціональності. Представлено структуру OLAP-кубу для отримання аналітичних даних про ринок оренди нерухомості.

OLTP, OLAP ТЕХНОЛОГІЇ

This research examines the specifics of working with large amounts of data. The use of OLAP technology, which provides an intuitive data model, organizing them in the form of multidimensional cubes, is proposed. Developed a list of recommendations that should be followed when setting up and designing OLAP cubes to ensure high performance. The structure of the OLAP cube for obtaining analytical data on the real estate rental market is presented.

OLTP, OLAP TECHNOLOGY

1. Вступ

Прогрес у сфері обробки та аналізу даних призводить до постійно зростаючої потреби у розробці нових технологій для швидкого

доступу до значної кількості аналітичних даних. Це спричинило популярність досліджень у сфері сховищ даних, та, зокрема технології використання кубів у багатьох