

**В. В. МОСКАЛЕНКО, А. Р. САНТАЛОВА, Н. Г. ФОНТА**

## ДОСЛІДЖЕННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ ВАРТОСТІ АКЦІЙ КОМПАНІЙ У НЕСТАБІЛЬНІЙ ЕКОНОМІЦІ

Дані дослідження присвячені аналізу і вибору нейронних мереж різної архітектури та гібридних моделей, до яких включені нейронні мережі, для прогнозування ринкової вартості акцій на фондовому ринку країни, яка перебуває у процесі нестабільного розвитку. Аналіз та прогнозування таких фондових ринків не може бути проведено з використанням класичних методів. Актуальність теми дослідження зумовлена необхідністю розробки програмних систем, які реалізують алгоритмічне забезпечення прогнозування ринкової вартості акцій в Україні. Впровадження таких програмних систем до контуру прийняття інвестиційних рішень у компаніях, які зацікавлені у підвищенні інформаційної прозорості фондового ринку України, дасть можливість покращити прогнози щодо ринкової вартості акцій. Це у свою чергу сприятиме покращенню інвестиційного клімату та забезпечить зростання інвестування в українську економіку. Проведено аналіз результатів існуючих досліджень щодо використання нейронних мереж та інших методів обчислювального інтелекту для моделювання поведінки учасників фондового ринку та прогнозування ринку. У статті надано результати дослідження щодо використання нейронних мереж різної архітектури для прогнозування ринкової вартості акцій на фондових ринках України. Для прогнозування було обрано чотири акції Української фондової біржі: Центренерго (CEEN); Укртелеком (UTLM); Крюківський Вагонобудівний Завод ПАТ (KVBZ); Райффайзен Банк Аваль (BAVL). Для експериментального дослідження були обрані такі моделі: довга короткострокова пам'ять LSTM; згортоква нейронна мережа CNN; гібридна модель, яка поєднує дві нейронні мережі CNN і LSTM; гібридна модель, що складається з алгоритму декомпозиції варіаційного режиму та нейронної мережі довгострокової пам'яті (VMD-LSTM); гібридна модель VMD-CNN-LSTM глибокого навчання на основі варіаційного режиму (VMD) та двох нейронних мереж. Розраховано оцінки якості прогнозу за різними метриками. Зроблено висновок, що використання гібридної моделі VMD-CNN-LSTM дає мінімальну помилку прогнозування ринкової вартості акцій українських підприємств. Також доцільно використовувати модель VMD-LSTM для прогнозування на біржах країн з нестабільною економікою.

**Ключові слова:** прогнозування, інвестиції, нейронна мережа, довготривала пам'ять, згортоква нейронна мережа, гібридна модель, варіаційна декомпозиція, глибоке навчання.

**V. V. MOSKALENKO, A. R. SANTALOVA, N. G. FONTA**

## STUDY OF NEURAL NETWORKS FOR FORECASTING THE VALUE OF COMPANY SHARES IN AN UNSTABLE ECONOMY

These studies deal with analysis and selection of neural networks with various architectures and hybrid models, which include neural networks, to predict the market value of shares in the stock market of a country that is in the process of unstable development. Analysis and forecasting of such stock markets cannot be carried out using classical methods. The relevance of the research topic is due to the need to develop software systems that implement algorithmic support for predicting the market value of shares in Ukraine. The introduction of such software systems in the circuit of investment decision-making in companies that are interested in increasing the information transparency of the Ukrainian stock market will improve the forecasts of the market value of shares. This, in turn, will help improve the investment climate and ensure the growth of investment in the Ukrainian economy. The analysis of the results of existing studies on the use of neural networks and other methods of computational intelligence for modeling the behavior of stock market participants and market forecasting has been carried out. The article presents the results of a study for the using of neural networks with various architectures for predicting the market value of shares in the stock markets of Ukraine. Four shares of the Ukrainian Stock Exchange were chosen for forecasting: Centrenergo (CEEN); Ukrtelecom (UTLM); Kriukivskiy Vahonobudivnyi Zavod PAT (KVBZ); Raiffeisen Bank Aval (BAVL). The following models were chosen for the experimental study: long short-term memory LSTM; convolutional neural network CNN; a hybrid model combining two neural networks CNN and LSTM; a hybrid model consisting of a variational mode decomposition algorithm and a long-term memory neural network (VMD-LSTM); hybrid VMD-CNN-LSTM deep learning model based on variational mode (VMD) and two neural networks. Estimates of forecast quality based on various metrics were calculated. It is concluded that the use of the hybrid model VMD-CNN-LSTM gives the minimum error in predicting the market value of the shares of Ukrainian enterprises. It is also advisable to use the VMD-LSTM model to predict the stock exchanges of countries with an unstable economy.

**Keywords:** forecasting, investment, neural network, long-term memory, convolutional neural network, hybrid model, variational decomposition, deep learning.

**Вступ.** Важливою умовою стабільного розвитку будь-якої національної економіки є фондовий ринок. Наявність розвинутого фондового ринку надає корпораціям великі можливості для залучення акціонерного капіталу та створює умови для їх подальшого розвитку. Можливість передбачити рух фондового ринку є одним із факторів збільшення інвестицій. Інвестори починають використовувати акції як засіб отримання контролю над компанією, для збереження заощаджень та отримання інвестиційного доходу. Оскільки на функціонування фондового ринку впливає багато факторів, то учасникам ринку необхідно для ефективної роботи використовувати різні методи прогнозування ринкової

вартості цінних паперів та інших показників [1]. Основна ідея успішного прогнозу фондового ринку полягає у тому, щоб отримати швидко результати з найменшою помилкою, використовуючи вхідні дані, які постійно змінюються за важко визначеною тенденцією. Статистичні методи прогнозування дозволяють отримати прогнози для більш-менш стабільних ринків. Але в умовах нерівномірного зростання або спаду ринку, його функціонування за умов нестабільності національної економіки такі методи не дають адекватних прогнозів, тому необхідно використовувати нові підходи до прогнозування [2]. В останні десятиліття дуже активно почали розвиватися методи прогнозування з

© В. В. Москаленко, А. Р. Санталова, Н. Г. Фонта, 2022



**Дослідницька стаття:** Цю статтю опубліковано видавництвом *НТУ «ХПІ»* у збірнику «Вісник Національного технічного університету «ХПІ». Серія: Системний аналіз, управління та інформаційні технології». Ця стаття поширюється за міжнародною ліцензією [Creative Common Attribution \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/). **Конфлікт інтересів:** Автор/и заявив/или про відсутність конфлікту.



використанням штучних нейронних мереж (ШНМ), генетичних алгоритмів тощо [3]. Отже, пропонується для прогнозування вартості акцій у країнах, де фондові ринки перебувають у стадії становлення та розвитку, наприклад, в Україні, використовувати ШНМ та гібридні моделі, до складу яких включені нейронні мережі [3]

**Постановка та мета задачі дослідження.** Актуальність дослідження нейронних мереж для прогнозування вартості акцій компаній України обумовлена тим, що існуючі результати попередніх досліджень стосуються прогнозів на фондових ринках стабільних економік. Для того щоб використовувати вже існуючі методи прогнозування для фондових ринків країн, які перебувають у стадії становлення та розвитку, потрібно провести дослідження щодо особливостей та доцільності їх використання. При прогнозуванні вартості акцій на фондових ринках, які функціонують в умовах нестабільної економіки, тобто за умов постійних змін трендів статистичних даних, виникають дві основні задачі:

1. Задача отримання прийнятного рівня точності прогнозування. При використанні класичних статистичних методів прогнозування для ринків з слабо моделюваною динамікою виникає ризик неотримання прийнятного рівня точності прогнозів.

2. Обґрунтування та вибір методу прогнозування ринкової вартості акцій компаній, які функціонують в у нестабільній економіці. Наприклад, статистичні методи прогнозування, які засновані на аналізі часових рядів такими як ARIMA дозволяють отримати прогнози для стабільних ринків. Для нестабільних динамічних статистик використовують ШНМ, наприклад, мережа з довгою короткочасною пам'яттю (Long Short-Term Memory – LSTM) та згорткової нейронні мережі (CNN). Статистичні методи та нейронні мережі зазвичай використовуються для прогнозування часових рядів.

Отже, метою дослідження є вибір ШНМ для прогнозування ринкової вартості акцій на фондових ринках країн, які перебувають у процесі становлення та розвитку. У якості прикладу було взято акції, які представлені на Українській фондовій біржі.

**Аналіз попередніх досліджень.** Проведено аналіз використання ШНМ для прогнозування показників фінансового ринку у різних національних економіках. У роботі [3] надано огляд 148 досліджень із використанням нейронних і гібридних нейротехнічних методів для прогнозування фондових ринків у відносно стабільних умовах. Висновки підкреслюють, що методи штучного інтелекту можна успішно використовувати для вивчення та аналізу діяльності фондового ринку. Розглянемо детальніше деякі з цих методів.

У дослідженні [4] прогнозування фондового індексу здійснено за моделлю ATT-LSTM, яка заснована на механізмі уваги ATT та нейронної мережі LSTM. Вхідними характеристиками моделі є ціна закриття, ціна відкриття, максимальна ціна, мінімальна ціна, зростання/падіння ціни та обсяг торгів фондового індексу, а вихідними є прогнозована ціна закриття

наступного торгового дня. Кількість нейронів у вхідному і вихідному шарах становить 6 і 1 відповідно. Додано вхідні характеристики моделі: коефіцієнт оборотності окремих акцій, коефіцієнт обсягу, співвідношення ціни та прибутку, співвідношення ціни до балансу, ціна до коефіцієнт продажів і загальна ринкова вартість. Кількість нейронів у вхідному шарі та вихідному шарі становить 12 і 1 відповідно. При дослідженні фондового індексу та окремих акцій кількість нейронів у прихованому шарі становить 128. Результати моделювання та експерименту показують, що впровадження механізму уваги може призвести до меншої похибки прогнозу. Надано модель прогнозування ціни акцій у роботі [5]. Тут розглянуто, коли ціна перевищує ринковий індекс. На основі ШНМ із використанням глибокого навчання проведено аналіз та прогнозування високоволатильних моделей цін на акції. У дослідженні [6] запропоновано аналіз великих даних для прогнозу щоденної прибутковості SPDR S&P 500 ETF (тикер: SPY). Використано гібридні алгоритми машинного навчання для прогнозування 60 фінансових та економічних характеристик. Глибокі нейронні мережі DNN (deep neural network) і традиційні штучні нейронні мережі розгортаються на попередньо обробленому та нетрансформованому наборі даних. Також для передбачення щоденного напрямку змін майбутніх доходів фондового ринку використано два набори даних, які трансформовані за допомогою аналізу головних компонентів (PCA). Продемонстровано шаблон для точності класифікації DNN. Проведено експеримент щодо поступового збільшення прихованих шарів від 12 до 1000. Результати моделювання показують, що торгові стратегії, які керуються DNN на основі даних, представлених за PCA, працюють краще.

Метод прогнозування з використанням технології глибокого навчання, який об'єднує традиційні змінні фондового фінансового індексу та текстові функції соціальних мереж як вхідні дані моделі прогнозування, пропонується у дослідженні [7]. У цьому дослідженні використовується Doc2Vec для створення довгих текстових векторів ознак із соціальних медіа, а потім зменшує розміри векторів текстових функцій за допомогою стекового автоматичного кодувальника, щоб збалансувати розміри між змінними текстових функцій і змінними фондового фінансового індексу. На основі вейвлет-перетворення дані часових рядів ціни акцій розкладаються, щоб усунути випадковий шум, спричинений коливаннями фондового ринку. Це дослідження використовує модель довготривалої короткочасної пам'яті для прогнозування курсу акцій. У статті [8] використовується напівапараметричний метод, відомий як дерева прискореної регресії (BRT), для прогнозування прибутковості акцій і місячної волатильності. Результати показують, що розширення набору умовної інформації призводить до більшої точності позабіржового прогнозування порівняно зі стандартними моделями.

У статті [9] пропонується метод глибокого навчання на основі згорткової нейронної мережі для прогнозування руху курсів акцій на китайському

фондовому ринку. Ціна відкриття, максимальна ціна, мінімальна ціна, ціна закриття та обсяг акцій, отриманих з Інтернету, встановлюються як вхідні дані для побудови мережевої архітектури. Результати показали, що використання методу глибокого навчання на основі згорткової нейронної мережі для прогнозування руху цін на акції в Китаї є досить надійним.

Методика створення моделей прогнозування ринку з використанням мультіагентних і нечітких систем представлена в [10]. Агенти в системі представляють трейдерів, які виконують замовлення на купівлю та продаж на ринку. Нечіткі системи використовуються для моделювання правил, яких дотримуються трейдери для здійснення операції на реальному ринку, а нечітка логіка – для моделювання невизначеності їх рішень (інтуїція трейдерів). Експерименти показали, що така модель може бути застосована, але при певних умовах.

Модель довгострокової короткочасної пам'яті (LSTM) у глибокому навчанні (DL) і модель авторегресійного інтегрованого ковзного середнього (ARIMA) вибрано для прогнозування індексу Шанхайської фондової біржі 50 Index у роботі [11]. Результати дослідження пояснюють, що середньоквадратична помилка (RMSE) моделі LSTM нижча, а модель, заснована на методі DL, має сильнішу здатність прогнозувати індекс цін на акції, ніж традиційна модель прогнозування акцій у зростаючій економіці.

Отже, емпіричні результати показали, що ШНМ перевершують лінійну регресію, особливо у випадку більш складної поведінки залежних змінних, наприклад нелінійної, динамічної та хаотичної поведінки гравців ринку. Нейронні мережі є надійними для моделювання нелінійних динамічних ринкових прогнозів. ШНМ робить дуже мало припущень на відміну від припущень про нормальність вибірки, які зазвичай зустрічаються в статистичних методах. Нейронна мережа може виконувати прогнозування після вивчення основного зв'язку між вхідними змінними та виходами. З точки зору статистики, нейронні мережі є аналогом непараметричних, нелінійних регресійних моделей [12].

**Дослідження щодо використання ШНМ різної архітектури для прогнозування.** Для задачі прогнозування ринкової вартості акцій на фондових ринках країн, які знаходяться в процесі становлення та нестабільного розвитку було обрано такі нейронні мережі: LSTM; CNN; гібридна модель, яка поєднує дві ШНМ CNN і LSTM; гібридна модель, що складається з алгоритму декомпозиції варіаційного режиму та нейронної мережі довгострокової пам'яті (VMD-LSTM); гібридна модель VMD-CNN-LSTM.

У роботі [2] надано результати щодо прогнозів ринкової вартості акцій Української фондової біржі: Центренерго (CEEN); Укртелеком (UTLM); Крюківський Вагонобудівний Завод ПАТ (KVBZ); Райффайзен Банк Аваль (BAVL). У цій роботі наведемо результати формування даних, вибору структури ШНМ та гібридних моделей.

Моделі довгої короткострокової пам'яті (LSTM) найчастіше використовують для аналізу часових рядів та побудови прогнозів. Вони можуть робити прогнози на довільну кількість кроків. Типова мережа LSTM складається з блоків пам'яті, які називаються коміркою. Комірка LSTM зображена на рис. 1 [13]. Модуль (комірка) LSTM має п'ять основних компонентів. За допомогою цих компонент здійснюється моделювання довгострокових та короткострокових даних. У комірку передаються два стани: стан комірки та прихований стан. Стан комірки – це основний ланцюг потоку даних, який дозволяє даним протікати без змін. Однак можливі деякі лінійні перетворення. Дані можна додавати або видаляти зі стану комірки через сигмоподібний гейт (ворота). Гейти подібні до шару або серії матричних операцій, які містять різні індивідуальні ваги.

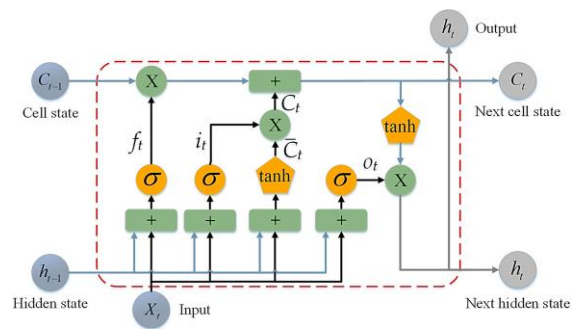


Рис. 1. Комірка LSTM

LSTM розроблено, щоб уникнути проблеми довгострокової залежності, оскільки мережа використовує гейт для керування процесом запам'ятовування. Першим кроком у побудові мережі LSTM є ідентифікація інформації, яка не потрібна та яка буде пропущена з комірки на цьому кроці [14]. Цей процес ідентифікації та виключення даних визначається сигмоїдною функцією  $\sigma$ , яка приймає вихід останнього блоку LSTM ( $h_{t-1}$ ) і момент часу  $t-1$  та поточний вхід ( $X_t$ ) у момент часу  $t$ . Сигмоїдна функція також визначає, яку частину з попереднього результату слід усунути. Ці гейти називаються гейтами забуття та позначаються як  $f_t$ :

$$f_t = s(W_f[h_{t-1}, X_t] + b_f),$$

де  $f_t$  – гейт забуття, який визначає, скільки інформації з поточного вводу та попереднього стану комірки перетікає у поточний стан комірки; це вектор зі значеннями у діапазоні від 0 до 1, що відповідає кожному числу в стані комірки  $C_{t-1}$ ;  $W_f$  та  $b_f$  – вагова матриця та зміщення, відповідно, гейта забуття.

Наступним кроком є прийняття рішення та збереження інформації з нового входу ( $X_t$ ) у стан комірки, а також оновлення стану комірки. Цей крок містить два рівні: сигмоподібний шар і другий шар  $\tanh$ . Сигмоподібний рівень вирішує, чи слід оновлювати нову інформацію чи ігнорувати (0 або 1), а подруге, функція  $\tanh$  надає вагу значенням, які пройшли

повз, вирішуючи рівень їх важливості (від  $-1$  до  $1$ ). Два значення множаться, щоб оновити новий стан комірки. Ця нова пам'ять потім додається до старої пам'яті  $C_{t-1}$ , що призводить до  $C_t$ :

$$i_t = \sigma(W_i[h_{t-1}, X_t] + b_i),$$

де  $i_t$  – вхідний вентилю, який визначає, скільки інформації надходить від поточного входу до стану комірки;

$$\bar{C}_t = \tanh(W_c[h_{t-1}, X_t] + b_c);$$

$$C_t = C_{t-1}f_t + \bar{C}_ti_t,$$

де  $W_i$ ,  $W_c$ ,  $b_i$ ,  $b_c$  – вагові матриці та зсув, відповідно, стану комірки;  $C_t$  – стан осередку – внутрішня пам'ять осередку, у якій зберігаються як короткострокова, так і довгострокова пам'ять в момент часу  $t$ .

На останньому кроці вихідні значення ( $h_t$ ) базуються на стані вихідної комірки ( $O_t$ ) але є відфільтрованою версією. Сигмоподібний шар вирішує, які частини стану комірки потрапляють на вихід. Далі вихідний сигнал сигмоїдного вентиля ( $O_t$ ) множиться на нові значення, створені шаром  $\tanh$  зі стану комірки ( $C_t$ ) зі значенням у діапазоні від  $-1$  до  $1$ .

$$O_t = \sigma(W_o[h_{t-1}, X_t] + b_o);$$

$$h_t = O_t \tanh(C_t),$$

де  $O_t$  – вихідний вентилю, який визначає, скільки переходить інформації з поточного до прихованого стану для того, щоб при потребі мережа могла вибирати тільки довгострокову пам'ять або короткострокову;  $h_t$  – прихований стан, який містить інформацію щодо стану виведення та розраховується щодо поточних вхідних даних і попереднього прихованого стану. Прихований стан може витягти лише короткострокову або довгострокову пам'ять, або обидві пам'яті, які зберігаються у стані комірки для передбачення;  $W_o$  і  $b_o$  – вагові матриці та зсув, відповідно, вихідного вентиля;  $\tanh$  – функція, яка виводить значення от  $-1$  до  $+1$  (масштабує значення комірки).

Для визначення оптимальної архітектури ШНМ (кількості прихованих шарів типу LSTM) для прогнозування ринкової вартості акції було реалізовано 5 різних варіантів, а саме: 2, 3, 4, 5 та 6 прихованих шарів. На рис. 2 представлено зниження точності прогнозів за метрикою MSE. Оскільки, мінімальне та найбільш стійке зниження значення помилки від епохи до епохи демонструє LSTM із двома прихованими шарами, тому використано саме таку архітектуру. Як базова кількість нейронів в одному шарі було взято 50 штук. Збільшення кількості юнітів у кожному шарі до 256 дозволило досягти значного приросту якості моделі (з 0.009235 до 0.005375 для двошарової мережі). Проте подальше збільшення кількості нейронів не вплинуло на показники якості прогнозу. Отже, при подальших експериментах було використано шари LSTM з 256 юнітами.

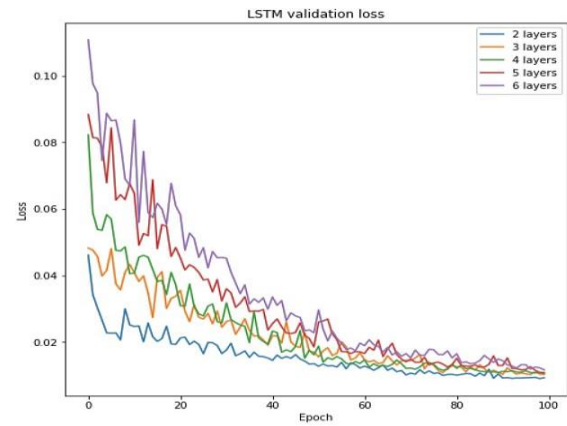


Рис. 2. Порівняння якості прогнозів LSTM з різною кількістю прихованих шарів (2, 3, 4, 5 та 6)

Згорткова нейронна мережа CNN включає шари фільтрів-згорток і підвибірки з додаванням повнозв'язкових шарів за необхідності. Двовимірність вхідних даних передбачає двовимірність згортки. Необхідно використовувати шари підвибірки зі збереженням країв через невеликий розмір початкової матриці ознак [15]. Реалізована архітектура згорткової нейронної мережі заснована на дослідженнях Ш. Чена (Sheng Chen) and та X. Хе (Hongxiang He). У роботі [16] обґрунтовується максимальна ефективність конфігурації мережі, яка наведена на рис. 3.

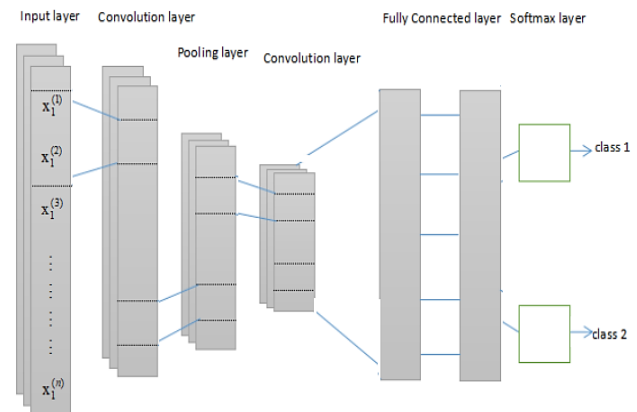


Рис. 3. Архітектура CNN

Модель CNN-LSTM будується послідовно як об'єднання модулів нейромереж CNN і LSTM. Після того, як вихідні дані проходять шари CNN, вони передаються до модуля LSTM. Далі формується чисельний прогноз за допомогою повнозв'язкового шару з одного нейрона. На основі експериментальних досліджень визначається послідовність та параметри шарів усередині модулів. Оскільки у кожній з нейронних мереж існує множина параметрів для оптимізації, вибір ідеальної комбінації їх може зайняти необмежений час. Тому для експериментальної реалізації гібридної моделі CNN-LSTM було обрано архітектуру, яка запропонована у дослідженні [17], оскільки вона має доведену ефективність (рис. 4). Кількість нейронів у LSTM та повнозв'язковому шарі реалізовано виходячи із значень для попередніх моделей – по 256.




Рис. 4. Архітектура CNN-LSTM

Гібридна модель VMD-LSTM складається з класичного алгоритму машинного навчання та нейронної мережі. У такій моделі Variational Mode Decomposition (VMD) приймається на вхід одновимірний часовий ряд і створює простір ознак подальшої обробки даних мережею LSTM. Оптимальна конфігурація LSTM визначається експериментально. VMD представляє моди як вузькосмугові сигнали з окремими смугами, які стиснуті навколо різних центральних частот. Метод VMD більш стійкий до шуму та помилок вибірки у порівнянні з методами, заснованими на EMD. EMD – це метод розкладання сигналу на набір з нульовим середнім та майже однаковою кількістю компонентів максимумів та мінімумів, він витягує режими рекурсивно, а VMD за допомогою ітеративної процедури робить це одночасно. З точки зору математичної реалізації VMD аналізує  $K$ -режими (сигнали), які одночасно здійснюють мінімізацію параметра. Зі збільшенням  $K$  збільшується складність задачі оптимізації, що уповільнює збіжність алгоритму. Отже, треба перед запуском алгоритму VMD правильно встановити значення  $K$ . Комбінація варіаційної модової декомпозиції (VMD) та LSTM реалізована на основі дослідження [18]. Параметри для модуля VMD-LSTM збігаються з простою LSTM (рис.5).

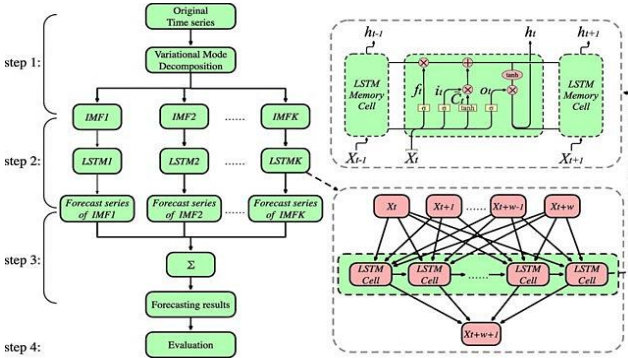


Рис. 5. Архітектура VMD-LSTM

Модель VMD-CNN-LSTM глибокого навчання на основі варіаційного режиму (VMD). VMD використовується для розкладання вихідного часового ряду на кілька підсигналів. Потім застосовується згорточна нейронна мережа (CNN) для вивчення шаблонів реконструкції розкладених субсигналів для отримання кількох реконструйованих субсигналів. Нарешті, мережа довгострокової пам'яті (LSTM) використовується для прогнозування часових рядів із розкладеними підсигналами та реконструйованими підсигналами як входи. Запропонований підхід VMD-CNN-LSTM походить від структури декомпозиції-реконструкції-

ансамбля та інноваційний шляхом вбудовування етапів реконструкції, єдиного прогнозування та ансамблю в уніфікований підхід глибокого навчання. Блок-схема реалізації моделі VMD-CNN-LSTM показана на рис. 6 [19].

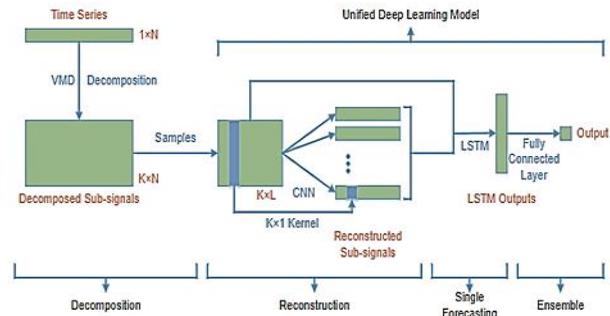


Рис. 6. Блок-схема реалізації моделі VMD-CNN-LSTM

Запропонований підхід VMD-CNN-LSTM в основному складається з чотирьох кроків:

1. VMD використовується для декомпозиції початкового часу. серії в  $K$  sub-сигналів.
2. CNN застосовується для вивчення шаблонів реконструкції розкладених підсигналів для отримання реконструйованих субсигналів (розмір ядра CNN дорівнює  $K$  на  $L$ , де  $L$  є довжиною вхідної послідовності, і ядро CNN можна розглядати як ваги реконструкції для розкладених субсигналів).
3. LSTM використовується для прогнозування розкладених підсигналів і реконструйованих підсигналів (розкладені підсигнали і реконструйовані підсигнали можна розглядати як багатовимірне представлення вихідного часового ряду).
4. Повністю пов'язаний рівень використовується для об'єднання результатів прогнозування LSTM для отримання кінцевих результатів прогнозування.

**Результати використання ШНМ для прогнозування ринкової вартості акцій фондового ринку країни з нестабільною економікою.** Оскільки якість прогнозів значною мірою залежить від вхідних даних, то було проведено підбір наборів даних для навчання і тестування. Вимоги до навчальної вибірки: вона не повинна бути меншою за рік, щоб врахувати сезонні зміни цін акцій, і не повинна бути занадто великою, щоб уникнути перенавчання моделей та великих витрат часових та обчислювальних ресурсів.

Отже, для експериментального тестування було обрано 4 варіанти: дані за 1 рік, 2 роки, 5 та 10 років. Результати порівняння якості прогнозу за різними метриками для часових періодів зведено у табл. 1. За даними табл. 1 можна дійти висновку, що дані за 10 років і 2 роки значно перевищують інші варіанти. При цьому навчальну вибірку за 2 роки можна вважати найкращою як за кількістю найкращих значень метрик, що підтверджують інші дослідження [2], так і більш зручною в процесі експлуатації.

Для оцінки якості прогнозу розраховані такі показники: RMSE (Root Mean Squared Error) – середньоквадратична помилка; MAPE (Mean Absolute Percentage Error) – середня абсолютна відсоткова помилка;

MDA (Mean Directional Accuracy) – середня абсолютна відсоткова помилка, забезпечує ймовірність того, що досліджуваний метод зможе визначити правильний напрямок часового ряду. У табл. 1 кольором позначені найкращі значення метрик помилок прогнозування за моделями (по строкам). При використанні метрики RMSE чим нижче значення, тим кращий прогноз за даною моделлю з використанням даних навчальної вибірки. Чим нижче значення MAPE, тим менша середня різниця між прогнозованим і фактичним значенням, отже, менше значення вважається найкращим. А для метрики MDA навпаки – найкращою буде вважатися модель, яка дає найбільше значення MDA.

Таблиця 1 – Порівняння якості прогнозу за роками

Модель	Помилка	Навчальна вибірка за роками			
		1	2	5	10
LSTM	RMSE	10.435	8.356	8.232	8.173
	MAPE	3.707	2.878	2.803	2.768
	MDA	0.514	0.517	0.510	0.503
CNN	RMSE	10.366	8.123	9.396	10.86
	MAPE	3.687	2.785	3.193	3.847
	MDA	0.503	0.507	0.510	0.517
CNN-LSTM	RMSE	13.695	14.401	10.752	8.790
	MAPE	5.185	5.514	3.829	3.083
	MDA	0.507	0.517	0.5	0.497
VMD-LSTM	RMSE	11.507	8.080	8.104	8.232
	MAPE	4.222	2.731	2.734	2.791
	MDA	0.517	0.517	0.517	0.503
VMD-CNN-LSTM	RMSE	20.531	5.884	7.278	9.431
	MAPE	4.432	1.286	2.897	2.489
	MDA	0.5	0.517	0.517	0.503

Крім обсягу вибірки, значну роль відіграє структура даних: передбачення ціни закриття акцій компанії може ґрунтуватися як виключно на цінах закриття попередніх днів, так і на додаткових даних, таких як ціна відкриття, максимальна та мінімальна за день, а також обсяг проданих за день акцій. У табл. 2 наведено результати розрахунків помилок прогнозування для одновимірних та багатовимірних даних для навчання НМ.

Таблиця 2 – Порівняння одновимірних та багатовимірних даних для навчання

Модель	Метрика	Кількість признаков	
		1	5
LSTM	RMSE	8.395	8.413
	MAPE	2.857	2.894
	MDA	0.507	0.520
CNN	RMSE	8.531	8.925
	MAPE	2.894	3.073
	MDA	0.507	0.510
CNN-LSTM	RMSE	19.947	10.336
	MAPE	8.227	3.680
	MDA	0.0	0.5

Хоча для LSTM та CNN значення метрик при одновимірних та багатовимірних тренувальних даних практично збігаються, у разі гібридної моделі CNN-LSTM додаткові ознаки дозволяють значно підвищити

якість прогнозування. Оскільки для порівняння прогностичної здатності різних моделей необхідний однаковий набір вхідних даних, далі для перерахованих вище моделей використовуються всі 5 ознак.

У випадку VMD-LSTM та VMD-CNN-LSTM простір ознакою генерується при обробці модулем VMD цін закриття акцій і є 5 мод для кожного запису, що збігається з форматом вхідних даних для інших моделей. Крім того, вплив на якість надає розмір рухомого вікна, відповідного кількості попередніх записів, необхідних для розрахунку прогнозованої ціни закриття. У більшості подібних статей розмір вікна відповідає 30 або 60 записам. Також варто перевірити значно менші та більші розміри: 10 та 90. У табл. 3 наведено помилки прогнозів для різних розмірів ковзного вікна.

Таблиця 3 – Порівняння якості прогнозів для різних розмірів ковзного вікна

Модель	Помилка	Значення помилки прогнозів в залежності від розміру рухомого вікна			
		10	30	60	90
LSTM	RMSE	16.684	17.728	8.458	4.781
	MAPE	6.119	6.446	2.923	1.678
	MDA	0.508	0.510	0.517	0.5
CNN	RMSE	16.154	17.036	8.480	4.681
	MAPE	5.920	6.206	2.932	1.662
	MDA	0.503	0.503	0.507	0.5
CNN-LSTM	RMSE	14.696	16.449	14.757	18.91
	MAPE	5.124	6.079	5.674	8.023
	MDA	0.0	0.0	0.514	0.0
VMD-LSTM	RMSE	16.369	17.171	8.154	6.639
	MAPE	6.008	6.255	2.761	2.435
	MDA	0.505	0.507	0.517	0.5
VMD-CNN-LSTM	RMSE	19.768	25.076	5.765	9.531
	MAPE	4.432	6.008	1.286	2.435
	MDA	0.505	0.517	0.517	0.5

У цьому випадку визначити оптимальне значення складніше, оскільки кількість найкращих показників для розмірів 60 та 90 практично збігається. При цьому MDA для всіх моделей краще при прогнозуванні за 60 попередніми значеннями, а це найважливіша на практиці метрика. Крім цього, 60 значень дозволяє скоротити витрати часу та обчислювальну потужність порівняно з 90.

**Аналіз результатів.** На підставі проведених експериментів підбрано оптимальні параметри для всіх моделей: навчальна вибірка складається із цін закриття акцій за 2 роки; у рухомому вікні 60 значень; усі значення попередньо нормуються у проміжок [0,1]; кожна з моделей реалізована в оптимальній конфігурації. Усі результати прогнозів ринкової вартості акцій наведені у роботі [2]. Зроблено висновок, що найбільш ефективною мережею для прогнозів ринкової вартості акцій українського фондового ринку є модель VMD-LSTM (рис. 7).

Як підсумок треба відзначити, що гібрид методу машинного навчання та нейромережі виявився ефективнішим за з'єднання двох різних типів нейронних мереж. При цьому як додавання VMD до CNN-LSTM

забезпечує приріст якості, так і VMD до LSTM. Не можна стверджувати існування залежності між складністю гібридної моделі (кількістю складових модулів) та її якістю, тому що в результаті експериментальних досліджень подвійна модель CNN-LSTM виявилася гіршою за одинарну CNN. Якісною моделлю для прогнозування цін акцій є гібридна модель VMD-CNN-LSTM, але і модель VMD-LSTM показує гарні результати.

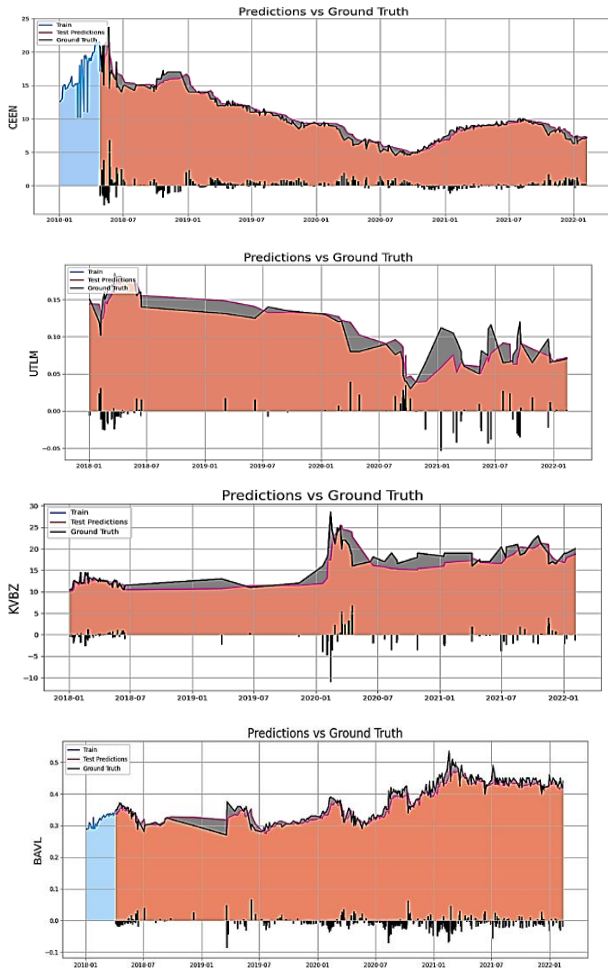


Рис. 7. Прогнози ринкової вартості акцій CEEN, UTLM, KVBZ та BAVL на основі моделі VMD-LSTM

**Висновки.** У цій статті проведено аналіз результатів існуючих досліджень щодо використання нейронних мереж та інших методів обчислювального інтелекту для моделювання поведінки учасників фондового ринку та прогнозування ринку. Надано результати дослідження щодо використання нейронних мереж різної архітектури для прогнозування ринкової вартості акцій на фондовому ринку України. Для прогнозування було обрано чотири акції Української фондової біржі: Центренерго (CEEN); Укртелеком (UTLM); Крюківський Вагонобудівний Завод ПАТ (КВБЗ); Райффайзен Банк Аваль (БАВЛ). Для експериментального дослідження були обрані такі моделі: LSTM; CNN; гібридна модель CNN і LSTM; гібридна модель VMD-LSTM; гібридна модель VMD-CNN-LSTM. Розраховано оцінки якості прогнозу. Зроблено висновок, що використання гібридної моделі VMD-CNN-LSTM

дає мінімальну помилку прогнозування ринкової вартості акцій українських підприємств. Також доцільно використовувати модель VMD-LSTM для прогнозування вартості акцій на біржах країн з нестабільною економікою. Результати цих досліджень будуть включені у підсистему прогнозування як складової модуля управління інвестиційною діяльністю системи управління ефективністю підприємства [20]. У наступних дослідженнях буде звернено увагу на прогнозування показників інвестиційного ринку країн з нестабільною економікою.

#### Список літератури

1. Moskalenko V., Fonta N., Nikulina O., Grinchenko M., Ershova S. Information technology of determination of the company's financial condition for the financial planning subsystem of the EPM system. *Radioelectronic and Computer Systems*. 2022. Vol. 2. P. 83–96.
2. Moskalenko V., Santalova A., Fonta N., Nikulina E. The value of shares prediction in an unstable economy using neural networks. *CEUR Workshop Proceedings*. 2022. Vol. 3171. P. 1202–1215.
3. Chopra R. G., Sharma D. Application of Artificial Intelligence in Stock Market Forecasting: A Critique, Review, and Research Agenda. *Journal of Risk and Financial Management*. 2021. Vol. 14(11).
4. Yan Y., Yang D. A Stock Trend Forecast Algorithm Based on Deep Neural Networks. *Wireless Communications and Mobile Computing*. 2021. Vol. 7. P. 1–10.
5. Oh J. Development of a stock trading system based on a neural network using highly volatile stock price patterns. *Peer J Computer Science*. 2022. URL: <https://doi.org/10.7717/peerj-cs.915>. (дата звернення: 20.11.2022).
6. Zhong X., Enke D. Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation*. 2019. Vol. 5(1). P. 1–20.
7. Ji X., Wang J., Yan Z. A stock price prediction method based on deep learning technology. *International Journal of Crowd Science*. 2021. Vol. 5 (1). P. 55–72.
8. Rossi A. G. *Predicting Stock Market Returns with Machine Learning*. 2022. URL: <https://neptune.ai/blog/predicting-stock-prices-using-machine-learning>. (дата звернення: 20.11.2022).
9. Chen S., He H. Stock prediction using convolutional neural network. *IOP Conference series: materials science and engineering*, 2018. Vol. 435. P. 012026.
10. Amaury H-Á., García-Valdez M., Merelo-Guervós J. J., Castañón-Puga M., López O. C. Using Fuzzy Inference Systems for the Creation of Forex Market Predictive Models. *IEEE Access*. 2021. Vol. 9. P. 69391–69404.
11. Ding Y., Sun N., Xu J., Li P., Wu J., Tang S. Research on Shanghai Stock Exchange 50 Index Forecast Based on Deep Learning. *Mathematical Problems in Engineering*. 2022. Vol. 2022. Article ID 1367920.
12. Narayana C., Naik P. J., Mythili G.Y., Vasu K., Rayalu M. G. Application of Neural Networks in Forecasting Methods. *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*. 2017. Vol. 5. P. 1926–1930.
13. Bui V., Le N.T., Nguyen V.H., Kim J., Jang Y.M. Multi-Behavior with Bottleneck Features LSTM for Load Forecasting in Building Energy Management System. *Electronics*. 2021. Vol. 10(9).
14. Le X.H., Ho H. V., Lee G., Jung S. Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. *Water*. 2019. Vol. 11 (7). DOI: 10.3390/w11071387
15. Yuan X., Li L., Wang Y. Nonlinear dynamic soft sensor modeling with supervised long short-term memory network. *IEEE transactions on industrial informatics*. 2019. Vol. 16. P. 3168–3176.
16. Chen S., He H. Stock prediction using convolutional neural network. *IOP Conference series: materials science and engineering*. IOP Publishing, 2018. Vol. 435 (1). P. 012–026.
17. Wu J. M. T. et al. A graph-based CNN-LSTM stock price prediction algorithm with leading indicators. *Multimedia Systems*. 2021. URL: <https://link.springer.com/article/10.1007/s00530-021-00758-w> (дата звернення: 20.11.2022).
18. Niu H., Xu K., Wang W. A hybrid stock price index forecasting model based on variational mode decomposition and LSTM network. *Applied Intelligence*. 2020. Vol. 50 (12). P. 4296–4309.

19. Zhang G., Ren T., Yang Y. A New Unified Deep Learning Approach with Decomposition-Reconstruction-Ensemble Framework for Time Series Forecasting. 2020. URL: <https://arxiv.org/abs/2002.09695>. (дата звернення: 20.11.2022)/
20. Moskalenko V., Fonta N. The method of constructing a development trajectory as the basis of an intelligent module for strategic planning of the EPM system. *CEUR Workshop Proceedings*. 2021. Vol. 2870. P. 1540–1550.

#### References (transliterated)

1. Moskalenko V., Fonta N., Nikulina O., Grinchenko M., Ershova S. Information technology of determination of the company's financial condition for the financial planning subsystem of the EPM system. *Radioelectronic and Computer Systems*. 2022, vol. 2, pp. 83–96.
2. Moskalenko V., Santalova A., Fonta N., Nikulina E. The value of shares prediction in an unstable economy using neural networks. *CEUR Workshop Proceedings*. 2022, vol. 3171, pp. 1202–1215.
3. Chopra R. G., Sharma D. Application of Artificial Intelligence in Stock Market Forecasting: A Critique, Review, and Research Agenda. *Journal of Risk and Financial Management*. 2021, vol. 14(11).
4. Yan Y., Yang D. A Stock Trend Forecast Algorithm Based on Deep Neural Networks. *Wireless Communications and Mobile Computing*. 2021, vol. 7, pp. 1–10.
5. Oh J. Development of a stock trading system based on a neural network using highly volatile stock price patterns. *Peer J Computer Science*. 2022. Available at: <https://doi.org/10.7717/peerj-cs.915>. (accessed 20.11.2022).
6. Zhong X., Enke D. Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation*. 2019, vol. 5(1), pp. 1–20.
7. Ji X., Wang J., Yan Z. A stock price prediction method based on deep learning technology. *International Journal of Crowd Science*. 2021, vol. 5 (1), pp. 55–72.
8. Rossi A. G. *Predicting Stock Market Returns with Machine Learning*. 2022. Available at: <https://neptune.ai/blog/predicting-stock-prices-using-machine-learning> (accessed 20.11.2022).
9. Chen S., He H. Stock prediction using convolutional neural network. *IOP Conference series: materials science and engineering*. 2018, vol. 435, pp. 012026.
10. Amaury H-Á., García-Valdez M., Merelo-Guervós J. J., Castañón-Puga M., López O. C. Using Fuzzy Inference Systems for the Creation of Forex Market Predictive Models, *IEEE Access*. 2021, vol. 9, pp. 69391–69404.
11. Ding Y., Sun N., Xu J., Li pp., Wu J., Tang S. Research on Shanghai Stock Exchange 50 Index Forecast Based on Deep Learning. *Mathematical Problems in Engineering*. 2022, vol. 2022, article ID 1367920.
12. Narayana C., Naik P. J., Mythili G.Y., Vasu K., Rayalu M. G. Application of Neural Networks in Forecasting Methods. *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*. 2017. vol. 5. pp. 1926 -1930.
13. Bui V., Le N.T, Nguyen V.H, Kim J, Jang Y.M. Multi-Behavior with Bottleneck Features LSTM for Load Forecasting in Building Energy Management System. *Electronics*. 2021, vol. 10(9).
14. Le X.H., Ho H. V., Lee G., Jung S. Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. *Water*. 2019. vol. 11 (7) DOI: 10.3390/w11071387.
15. Yuan X., Li L., Wang Y. Nonlinear dynamic soft sensor modeling with supervised long short-term memory network. *IEEE transactions on industrial informatics*. 2019, vol. 16, pp. 3168–3176.
16. Chen S., He H. Stock prediction using convolutional neural network. *IOP Conference series: materials science and engineering*. IOP Publishing, 2018, vol. 435 (1), pp. 012–026.
17. Wu J. M. T. et al. A graph-based CNN-LSTM stock price prediction algorithm with leading indicators. *Multimedia Systems*. 2021. Available at: <https://link.springer.com/article/10.1007/s00530-021-00758-w> (accessed 20.11.2022).
18. Niu H., Xu K., Wang W. A hybrid stock price index forecasting model based on variational mode decomposition and LSTM network. *Applied Intelligence*. 2020, vol. 50 (12), pp. 4296–4309.
19. Zhang G., Ren T., Yang Y. A New Unified Deep Learning Approach with Decomposition-Reconstruction-Ensemble Framework for Time Series Forecasting. 2020. Available at: <https://arxiv.org/abs/2002.09695>. (accessed 20.11.2022)/
20. Moskalenko V., Fonta N. The method of constructing a development trajectory as the basis of an intelligent module for strategic planning of the EPM system. *CEUR Workshop Proceedings*. 2021, vol. 2870, pp. 1540–1550

Надійшло (received) 05.09.2022

#### Відомості про авторів / About the Authors

**Москаленко Валентина Володимирівна** – доктор технічних наук, доцент, Національний технічний університет «Харківський політехнічний інститут», професор кафедри інформаційних систем та технологій; м. Харків, Україна; ORCID: <https://orcid.org/0000-0002-9994-5404>; e-mail: [valentinamosk17@gmail.com](mailto:valentinamosk17@gmail.com)

**Санталова Анастасія Романівна** – Національний технічний університет «Харківський політехнічний інститут», студентка; м. Харків, Україна; ORCID: <https://orcid.org/0000-0002-9949-4500>; e-mail: [nastia.santalova@gmail.com](mailto:nastia.santalova@gmail.com)

**Фонта Наталія Григорівна** – кандидат технічних наук, доцент, Національний технічний університет «Харківський політехнічний інститут», доцент кафедри програмної інженерії та інтелектуальних систем управління; м. Харків, Україна; ORCID: <https://orcid.org/0000-0001-5593-1409>; e-mail [natalia.fonta@dataart.com](mailto:natalia.fonta@dataart.com)

**Moskalenko Valentyna Volodymyrivna** – Doctor of Technical Sciences, Docent, National Technical University "Kharkiv Polytechnic Institute", Associate Professor at the Department of Information Systems and Technologies; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0002-9994-5404>; e-mail: [valentinamosk17@gmail.com](mailto:valentinamosk17@gmail.com)

**Santalova Anastasiya Romanivna** – National Technical University "Kharkiv Polytechnic Institute", Student; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0002-9949-4500>; e mail: [nastia.santalova@gmail.com](mailto:nastia.santalova@gmail.com)

**Fonta Nataliia** – Candidate of Technical Sciences (PhD), Docent, National Technical University "Kharkiv Polytechnic Institute", Associate Professor at the Department of Software Engineering and Management Intelligent Technologies; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0001-5593-1409>; e mail [natalia.fonta@dataart.com](mailto:natalia.fonta@dataart.com)