

ПОРІВНЯЛЬНИЙ АНАЛІЗ ТРАДИЦІЙНИХ СТАТИСТИЧНИХ МЕТОДІВ ТА НЕЙРОМЕРЕЖЕВОЇ МОДЕЛІ LSTM

Анотація. У статті здійснено порівняльний аналіз традиційних статистичних методів (ARIMA, SARIMA) та сучасного підходу на основі глибокого навчання (LSTM) для прогнозування часових рядів на фінансових ринках. Аналіз зосереджено на дослідженні ефективності кожної моделі у прогнозуванні ціни закриття акцій компанії Apple (NASDAQ: AAPL). Вибір моделей обумовлений їх широким застосуванням у фінансовому аналізі: ARIMA добре підходить для стаціонарних часових рядів, SARIMA дозволяє враховувати сезонні коливання, а LSTM здатна розпізнавати нелінійні залежності та довготривалі тренди.

Для дослідження використано історичні дані про ціну закриття акцій AAPL за період із 01.01.2023 по 20.01.2025, отримані через сервіс уfinance. Експериментальне моделювання проводилося з метою порівняння точності прогнозування на основі таких метрик, як середня абсолютна похибка (MAE), середньоквадратична похибка (MSE), корінь середньоквадратичної похибки (RMSE) та середня абсолютна відносна похибка (MAPE).

Результати аналізу показали, що модель LSTM забезпечує найкращу точність прогнозування завдяки здатності продуктивно моделювати складні патерни у часових рядах. SARIMA також продемонструвала високу ефективність у прогнозуванні, особливо для даних із вираженою сезонною складовою, перевершуючи ARIMA за точністю. Водночас ARIMA продемонструвала найгірші результати через обмежену здатність адаптуватися до сезонності та нелінійних залежностей.

Одержані висновки можуть бути корисними для аналітиків, інвесторів та дослідників, що займаються фінансовим прогнозуванням. Робота містить практичні рекомендації щодо вибору моделі залежно від характеристик даних і потреб прогнозування, а також висвітлює сильні та слабкі сторони кожного підходу.

Ключові слова: прогнозування часових рядів, ARIMA, SARIMA, LSTM, фінансові ринки, машинне навчання, нейронні мережі, оцінка точності, фондовий ринок, моделювання даних

Постановка проблеми. У сучасному світі аналіз та прогнозування даних стали важливою складовою багатьох галузей, від фінансів і маркетингу до медицини та енергетики. Традиційні статистичні методи та сучасні підходи на основі машинного навчання часто використовуються для аналізу часових рядів – одного з найпоширеніших

типів даних. Серед них виділяються ARIMA (авторегресійна інтегрована модель ковзного середнього), SARIMA (сезонна авторегресійна інтегрована модель ковзного середнього) та LSTM (довготривала короткочасна пам'ять), які демонструють різний підхід до прогнозування часових рядів.

У роботі розглянемо ключові особливості наведених моделей, їхні сильні та слабкі сторони, а також типові сценарії використання. ARIMA та SARIMA представляють класичні статистичні методи, які базуються на математичних залежностях у даних, тоді як LSTM, як частина нейронних мереж, використовує переваги глибокого навчання для роботи зі складними та нелінійними залежностями.

Мета дослідження. Провести аналіз придатності моделей ARIMA, SARIMA та LSTM для прогнозування часових рядів на ринку цінних паперів. Зокрема, дослідити точність та якість прогнозування, а саме оцінити, як кожна з моделей справляється з передбаченням на короткі та довгі періоди, у тому числі: при прогнозуванні цін на фондовому ринку. Планується визначити сильні та слабкі сторони представлених моделей, а саме: встановити переваги та обмеження кожної з них, з урахуванням складності даних, часових рамок для тренування і стійкості до шуму та аномалій. Окрім того, надати практичні рекомендації для дослідників і інженерів щодо вибору відповідної моделі, яка буде задовільняти вимогам поставленого завдання, враховувати специфічні дані та виконувати якісне прогнозування.

Аналіз останніх досліджень і публікацій. Питання прогнозування зміни ціни фінансових активів за допомогою технічних індикаторів здебільшого вивчається зарубіжними дослідниками, що пов'язано з доступністю інструментів і високим рівнем обізнаності у цій сфері. Серед праць українських авторів можна виділити наступні: Григор'єв І. А., Сорокін В. О., які в своїй роботі [1] розглядають поєднання статистичних методів і машинного навчання для моделювання цін акцій. Карпова Л. В. розглядає застосування нейронних мереж для аналізу фінансових даних та приклади їх використання в прогнозуванні фондових ринків [2]. Козаченко О. В., Романюк О. А. в своїй роботі аналізують ефективність алгоритмів машинного навчання, таких як Random Forest, SVM, LSTM для прогнозування цін акцій [3]. Кравченко Д. В. в своєму дослідженні акцентує увагу на поєднанні класичних статистичних методів із сучасними підходами машинного навчання [4]. Ладижець В. І., Теренчук С. А. аналізують основні підходи технічного аналізу, включаючи трендові індикатори та осцилятори [5]. Маслій В. В., Березка К. М. в [6] демонструють процес побудови та налаштування ARIMA для економічних прогнозів.

Серед зарубіжних досліджень та публікацій по даній тематиці можна виділити роботи Hyndman R.J. та Box G. E. P., що є комплексними підручниками, які описують теорію та практики прогнозування часових рядів [7, 8]. Хаяс А. окреслює основні концепції ARIMA моделі та зосереджується на практичному застосуванні ARIMA [9]. Дослідження S. Siarni-Namini та інші [10] порівнює дві моделі ARIMA та LSTM в прогнозуванні часових рядів та різних сценаріях прогнозування.

Розглянуті роботи демонструють широкий спектр підходів до прогнозування фінансових ринків із використанням ARIMA, SARIMA, LSTM і гібридних моделей.

Викладення основного матеріалу. Часові ряди є важливим інструментом на фондовому ринку, адже вони дозволяють відстежувати динаміку зміни цін на активи в часі. Особливістю часових рядів є їх послідовна природа, де кожен елемент залежить від попереднього, що робить їх ідеальним засобом для створення прогнозів. Враховуючи дані властивості, прогнозування майбутніх значень на основі історичних даних стає можливим за допомогою різноманітних методів – від простих статистичних моделей до складніших методів машинного навчання. У даному дослідженні розглядаються три популярні методи прогнозування: авторегресійна інтегрована модель ковзного середнього (ARIMA), її розширена версія, що враховує сезонні коливання (SARIMA), а також нейромережева модель довготривалої короткочасної пам'яті (LSTM), яка здатна навчатися складним нелінійним залежностям у даних.

ARIMA є базовою технікою прогнозування часових рядів, яка широко використовується в різних сферах, зокрема: у фінансах, економіці та ін. Її здатність моделювати та прогнозувати майбутні значення шляхом аналізу й використання минулих трендів робить цей метод незамінним. Розглянемо основні компоненти ARIMA, особливості її застосування та детальні етапи реалізації.

Абревіатура ARIMA описує три основні компоненти, з яких складається модель, а саме: авторегресія (AR), інтегрування (I) та ковзне середнє (MA). Як відомо, компонент авторегресії використовує минулі значення для прогнозування майбутніх значень, це означає, що при прогнозуванні враховуються попередні дані, останнє дозволяє брати до уваги автокореляцію. Компонент інтегрування стосується процесу диференціювання. У багатьох даних часових рядів існують тренди та шаблони, які роблять значення нестабільними, тобто їх статистичні властивості, такі як середнє або дисперсія, змінюються з часом. Однак стаціонарність є важливою властивістю для продуктивного навчання статистичних моделей. Ковзне середнє стосується залежності помилок або залишків протягом часу. Цей компонент враховує помилки, які виникли при прогнозуванні попередніх значень, і включає їх у поточну оцінку. Інакше велика похибка в одному місяці може негативно вплинути на наступні місяці та збільшити її.

В роботі для стандартного вираження моделі ARIMA пропонується використовувати наступну формулу:

$$\Delta^d y_t = \alpha + \sum_{i=1}^p \phi_i \Delta^d y_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \epsilon_t, \quad (1)$$

де y_t – значення часового ряду на момент часу t , $\Delta^d y_t$ – різниця ряду ступеня d , різниця першого ступеня записується як $\Delta y_t = y_t - y_{t-1}$, α – константа, ϵ_t – значення біло-

го шуму, ϕ_1, \dots, ϕ_p – коефіцієнти авторегресійної моделі, $\theta_1, \dots, \theta_q$ – коефіцієнти моделі

ковзного середнього.

Визначення моделі ARIMA (1) для певного часового ряду полягає у виборі значень параметрів p , d і q , що є досить складним завданням. Параметр p позначає порядок авторегресійної частини, d – ступінь різниці ряду, q – порядок частини ковзного середнього [6].

Для визначення параметрів ARIMA: p , d і q використовують два ключових інструменти:

- ACF (функція автокореляції), яка допомагає визначити порядок частини ковзного середнього q , кількість попередніх помилок прогнозу, які потрібно врахувати;
- PACF (функція часткової автокореляції), яка допомагає визначити порядок авторегресійної частини p , кількість врахованих лагів спостережень.

В роботі використовується датасет з цінами закриття акцій компанії Apple (NASDAQ:AAPL) з 01.01.2023 по 20.01.2025 р. з сервісу ufinance [12].

Візуалізація графіків функцій ACF та PACF надає чітке розуміння того, як минулі значення впливають на поточні дані (рис. 1).

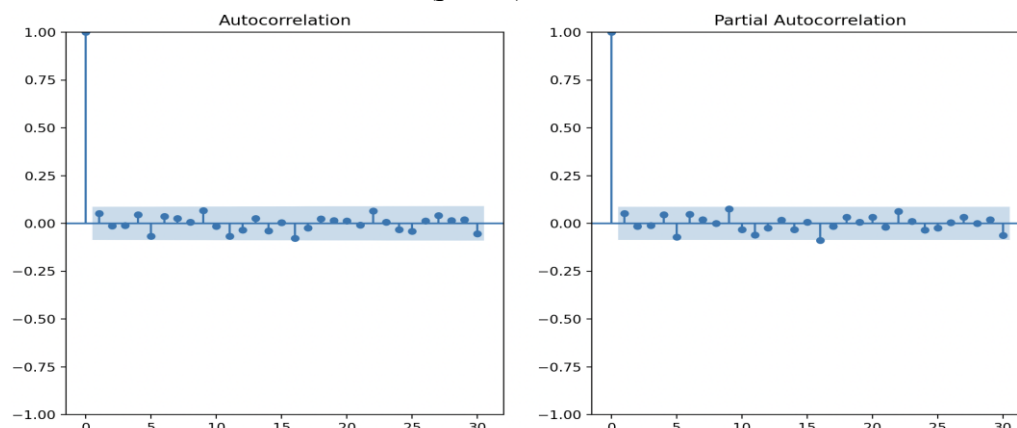


Рисунок 1 – Графіки функцій ACF та PACF

Після проведення чисельних експериментів розрахунку параметрів моделі ARIMA знайдено оптимальні значення для $p = 2$, $d = 1$, $q = 2$. Базуючись на знайдених оптимальних значеннях наведемо графік прогнозу ціни закриття цінного паперу AAPL на тридцять днів в майбутньому (рис. 2).

Модель ARIMA дозволяє робити прогнозування стаціонарних даних, але додавання сезонності та зовнішніх змінних може значно покращити її продуктивність. Оскільки ARIMA припускає стаціонарність часового ряду, необхідно використовувати іншу модель, яка підтримує сезонну складову. Для цього використаємо модель SARIMA, яка являється розширенням моделі ARIMA, додаючи додаткові сезонні компоненти авторегресії та ковзного середнього. Такі додаткові лаги відповідають частоті сезонності (наприклад, дванадцять для місячних даних, двадцять чотири для щоденних).



Рисунок 2 – Графік прогнозу ціни закриття акції AAPL за допомогою моделі ARIMA

Ключовими компонентами моделі SARIMA є сезонні компоненти, які враховують закономірності в даних, а саме те, що вони повторюються з фіксованим інтервалом (щотижня, щомісяця або щороку). В цій частині модель включає сезонну авторегресію (SAR), сезонне інтегрування (I) та сезонне ковзне середнє (SMA). Крім того, модель SARIMA враховує несезонні компоненти, спадкуючи їх обробку від моделі ARIMA та додаткові параметри порядку які визначаються трьома групами параметрів: (p, d, q) для несезонних компонентів і (P, D, Q, s) для сезонних. Наведені параметри задають кількість авторегресивних, різницевих і ковзних середніх членів як для сезонних, так і для несезонних частин моделі.

У роботі використано наступну формулу SARIMA:

$$\Delta^d \Delta_s^D y_t = \alpha + \sum_{i=1}^p \phi_i \Delta^d \Delta_s^D y_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \sum_{k=1}^P \Phi_k \Delta^d \Delta_s^D y_{t-ks} + \sum_{l=1}^Q \Theta_l \epsilon_{t-ls} + \epsilon_t, \quad (2)$$

де Δ_s^D – оператор сезонного диференціювання порядку D з сезонністю S , $\theta_1, \dots, \theta_q$ – коефіцієнти моделі ковзного середнього, Φ_1, \dots, Φ_k – коефіцієнти сезонного авторегресійного (SAR) компонента, P – оператор сезонного авторегресійного процесу, $\Theta_1, \dots, \Theta_l$ – коефіцієнти сезонного ковзного середнього (SMA) компонента, Q – оператор сезонного процесу ковзного середнього.

Перший набір параметрів (p, d, q) визначає порядок моделі ARIMA, а (P, D, Q) s відповідає за сезонні компоненти. Зокрема, P, D, Q позначають сезонні порядки авторегресії, інтегрування та ковзного середнього відповідно. Параметр s вказує кількість спостережень у кожному сезонному періоді.

Під час чисельних експериментів було використано наступні дані для моделі SARIMA (2): $p = 2, d = 1, q = 2$. Після підрахунку сезонних показників отримаємо

наступні показники моделі: $P = 0$, $D = 1$, $Q = 1$, $s = 24$, де 24 (добова сезонність). Прогноз на майбутні 30 днів зроблений з використанням моделі SARIMA з наведеними параметрами зображений на рисунку 3.

Таким чином, використання ARIMA моделі доцільно тоді, коли дані мають чіткий тренд і є нестационарними. Перевагами цієї моделі є вміння працювати зі складними шаблонами даних, вона підходить для короткострокових і довгострокових прогнозів та є гнучкою у врахуванні різних типів сезонності та трендів. Звісно, що є обмеження, які потребують великого обсягу даних для точного моделювання, модель може бути складною для налаштування, що відноситься до фондового ринку тому, що данні постійно змінюються і вони не завжди мають чіткий тренд. Крім того, ця модель не підходить для даних зі структурними зламами або нелінійними залежностями [13].



Рисунок 3 – Графік прогнозу ціни закриття акції AAPL за допомогою моделі SARIMA

Очевидно, що виникає необхідність розглядати інші моделі, які більш комплексно можуть враховувати додаткові параметри часових рядів, а саме: модель SARIMA, яка враховує сезонність, що, у свою чергу, підвищує точність прогнозів для часових рядів із сезонними коливаннями, крім того модель підходить для опису різноманітних сезонних шаблонів. Додаємо, що модель широко підтримується в статистичних бібліотеках, зокрема, на мові програмування Python (наприклад, statsmodels). Проте, як і всі моделі, які працюють з часовими рядами, вона має ряд особливостей з її використанням, а саме: вибір моделі ускладнюється через додаткові параметри. Крім того, необхідно ретельно проводити діагностику залишків і перевірку моделі на похибки. Додамо, що ще одним фактором є те, що для надійної оцінки сезонних компонентів може знадобитися довший часовий ряд.

Хоча традиційні статистичні моделі добре справляються із задачами, пов'язаними з часовими рядами, сучасні технології пропонують більш вдосконалені підходи для прогнозування майбутніх значень. Одним із таких є використання нейронних мереж, зокрема, моделі Long Short-Term Memory (LSTM) [14, 15]. Як відомо, LSTM є спеціалізованою рекурентною нейронною мережею типу (RNN – Recurrent Neural Networks), яка розроблена для аналізу послідовних даних, таких як часові ряди. Завдяки

здатності зберігати довготривалі залежності, LSTM демонструє високу продуктивність у прогнозуванні. Як зазначається в [11] «Комірка LSTM забезпечує ще ефективніше збереження довготривалої пам'яті, оскільки дозволяє навчатись більшій кількості параметрів. Це робить її однією з найсильніших рекурентних нейронних мереж для прогнозування, особливо коли у даних спостерігається довготривалий тренд. LSTM сьогодні вважається однією з найбільш передових моделей для прогнозування». Зв'язки між компонентами мережі LSTM приведені на рисунку 4.




Рисунок 4 – LSTM комірка

Ключовим елементом мережі LSTM є стан комірки, який передається від входу до її виходу. Завдяки цьому, стан комірки забезпечує потік інформації через весь ланцюг із мінімальними лінійними діями через три гейти. Таким чином, стан комірки виступає як довгострокова пам'ять LSTM.

Як відомо, нейронна мережа Long Short-Term Memory була розроблена для подолання проблеми довгострокових залежностей, оскільки мережа використовує гейти для контролю процесу збереження інформації.

Першим етапом у створенні LSTM є визначення, яка інформація є непотрібною і має бути виключена з комірки на цьому кроці. Такий процес ідентифікації та виключення даних здійснюється за допомогою сигмоїдної функції σ , яка отримує на вході значення з попереднього блоку LSTM (h_{t-1}) на момент часу $t-1$ та поточний вхід x_t на

момент часу t . Сигмоїдна функція, крім того, визначає, яку частину попереднього результату потрібно видалити. Розглянуті гейти називаються гейтами забуття і позначаються як f_t .

$$f_t = \sigma(W_{f,x}x_t + W_{f,h}h_{t-1} + b_f), \quad (3)$$

де f_t – гейт забуття, вихідні значення якого варіюються від 0 до 1, де нуль означає повне забуття інформації, а одиниця – повне збереження, що відповідає кожному числу в стані комірки, h_{t-1} – прихований стан моменту часу $t-1$ та поточний вхід x_t , W_f та b_f – відповідно вагова матриця та зміщення гейта забуття.

Наступним етапом є прийняття рішення щодо збереження інформації з нового входу (X_t) в стан комірки, а також оновлення цього стану. Процес включає два рівні:

сигмоїдний шар та другий шар гіперболічний тангенс \tanh . Сигмоїдний рівень визначає чи слід оновлювати нову інформацію або ігнорувати її (нуль або одиниця), а функція \tanh надає вагу значенням, які пройшли через попередні етапи, оцінюючи їх важливість (від -1 до $+1$). Обидва значення множаться, щоб оновити стан комірки, і ця нова пам'ять додається до старої пам'яті, що призводить до нового стану комірки C_t .

$$i_t = \sigma(W_i[h_{t-1}, X_t] + b_i), \quad (4)$$

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

$$\bar{c}_t = \tanh(W_c[h_{t-1}, X_t] + b_c), \quad (5)$$

$$C_t = C_{t-1}f_t + \bar{c}_ti_t, \quad (6)$$

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

На останньому етапі вихідні значення (h_t) базуються на стані вихідної комірки (O_t), але є відфільтрованою версією цього стану. Сигмоїдний шар визначає, 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), де значення знаходяться в діапазоні від -1 до $+1$.

$$O_t = \sigma(W_o[h_{t-1}, X_t] + b_o); \quad (7)$$

$$h_t = O_t * \tanh(C_t) \quad (8)$$

де O_t – вихідний вентиль, який визначає, скільки інформації з поточного стану передається до прихованого, дозволяючи мережі вибирати між довгостроковою або короткостроковою пам'яттю, коли це необхідно; h_t – прихований стан, що містить інформацію про стан виведення та розраховується на основі 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 для вихідного вентиля; \tanh –

функція, яка масштабує значення комірки в діапазоні від -1 до +1.

Під час проведення чисельних експериментів було побудовано нейронну мережу з параметрами, які наведені у таблиці 1.

Таблиця 1

Параметри розробленої моделі

Параметри	Значення
Кількість входів	1
Кількість LSTM шарів	50
Крок часу	60
Розмір пакета	32
Оптимізатор	Adam
Функція втрат	Середня квадратична похибка
Епохи	50

Програмний інструментарій створено за допомогою мови програмування Python, яка широко застосовується в галузі штучного інтелекту. Для побудови та навчання моделі використовувалась бібліотека Keras, а для масштабування даних був використаний модуль `sklearn.preprocessing`.

Без обмеження суджень, зауважимо, що отримані данні були поділені на навчальну та тестову вибірки у пропорції вісімдесят до двадцяти. Як відомо, перша частина використовується для навчання, а друга – для перевірки її точності. Результати навчання моделі з обраними параметрами в розрізі зміни функції втрат протягом етапу навчання з залученням окремого тестувального набору даних (рис. 5).




Рисунок 5 – Зміна значення функції втрат протягом навчання моделі

Результати прогнозування на тестових та тренувальних даних наведені на рисунку 6.



Рисунок 6 – Графік прогнозу за допомогою LSTM на тренувальних та тестових даних

Результати прогнозування на майбутні тридцять днів представлено на рисунку 7.



Рисунок 7 – Графік прогнозу за допомогою LSTM на майбутні 30 днів

Під час роботи з кожною з моделей ARIMA, SARIMA та LSTM було створено відповідний прогноз ціни закриття акції AAPL на тридцять днів. Загальний вигляд прогнозованих значень представлено на рисунку 8.



Рисунок 8 – Графік порівняння результатів прогнозування ціни закриття цінного паперу AAPL на майбутні 30 днів за допомогою ARIMA, SARIMA та LSTM

Для оцінки якості роботи кожної моделі було обрано такі метрики: MAE (Mean Absolute Error), MSE (Mean Squared Error), RMSE (Root Mean Squared Error) та MAPE (Mean Absolute Percentage Error), які є відомими та не потребують додаткових пояснень.

Метрику MSE включено до аналізу, оскільки саме вона мінімізується під час навчання моделі. RMSE використовується, оскільки є квадратним коренем із MSE і відображає якість моделі дещо інакше. Як відомо, якщо MSE дає загальне уявлення про величину похибки, то RMSE має той самий масштаб, що й вихідні дані, і, як наслідок, є зручнішою метрикою для інтерпретації отриманих результатів.

Важливо зазначити, що оцінки MSE та RMSE підкреслюють вплив великих похибок, оскільки похибки підводяться у квадрат перед усередненням і тому це робить метрику RMSE більш чутливою до викидів. Однак така чутливість може бути недоліком, тому для більш збалансованої оцінки якості прогнозів додатково використовуються MAE та MAPE, які менш залежні від аномальних значень. Отримані чисельні результати прозглянутих метрик наведено у таблиці 2.

Таблиця 2

Обчислені метрики точності ARIMA, SARIMA та LSTM

Метрика \ Модель	MAE	MSE	RMSE	MAPE
ARIMA	8,4159	144,8973	12,0373	3,4804
SARIMA	7,7675	89,3812	9,4542	5,1187
LSTM	6,8124	42,8118	8,0669	2,8784

Після проведених чисельних експериментів та аналізу отриманих результатів метрик точності кожної з моделей, можна зробити висновок, що модель LSTM забезпечує найнижчі похибки за всіма показниками. SARIMA показала, що є прийнятною альтернативою але її точність поступається LSTM. ARIMA має найнижчу точність, що робить її менш придатною для точного прогнозування в цьому випадку.

Висновки. В роботі було розглянуто основні характеристики використаного часового ряду: акцій компанії Apple; реалізовано графічне представлення прогнозування; досліджено найпоширеніші методи прогнозування, такі як: авторегресійна інтегрована модель ковзного середнього (ARIMA), сезонна авторегресійна інтегрована модель ковзного середнього (SARIMA) та нейронна мережа довготривала короткочасна пам'ять (LSTM). В якості даних було використано датасет з вартостями закриття цінного паперу AAPL з 01.01.2023 року по 20.01.2025 року.

Виконано прогнозування цін на майбутні тридцять днів при застосуванні кожної з розглянутих моделей. Представлено отримані результати чисельних експериментів у вигляді відповідних графіків. Проведено аналіз метрик оцінювання якості роботи кожної з моделей, який дозволяє зробити висновок, що модель LSTM показує найкращі результати, оскільки найбільш адаптована для подібних задач прогнозування часових рядів на фондовому ринку. Надано рекомендації щодо використання розглянутих у роботі моделей та наведено основні характеристики для кожної з них.

ЛІТЕРАТУРА / REFERENCES

1. Григор'єв, І. А., Сорокін, В. О. (2020). Гібридні моделі для прогнозування цін акцій на фондовому ринку // Вісник Харківського національного університету. – 2020. – №2. – С. 45-53.
2. Карпова, Л. В. (2018). Нейронні мережі у фінансовому аналізі: теорія та практика застосування // Вісник Київського національного університету. Економіка. – 2018. – №4. – С. 90-98.
3. Козаченко, О. В., Романюк, О. А. (2020). Прогнозування цін акцій на основі моделей машинного навчання // Економіка та прогнозування. – 2020. – №2. – С. 75-88.
4. Кравченко, Д. В. (2021). Статистичні методи та машинне навчання у фінансових дослідженнях // Фінансовий ринок України. – 2021. – №3. – С. 67-73.
5. Ладижець, В. ., Теренчук, С. . (2021). МОДЕЛІ ТА МЕТОДИ ТЕХНІЧНОГО АНАЛІЗУ ФІНАНСОВИХ РИНКІВ. Управління розвитком складних систем, (48), 47–52. <https://doi.org/10.32347/2412-9933.2021.48.47-52>
6. Masliy, V. V., & Berezka, K. M. (2017). Selection and evaluation of ARIMA models for forecasting foreign direct investment. Scientific Bulletin of the International Humanitarian University. Series: Economics and Management, 24(2), 115-119. [http://nbuv.gov.ua/UJRN/Nvmgu_eim_2017_24\(2\)_26](http://nbuv.gov.ua/UJRN/Nvmgu_eim_2017_24(2)_26)
7. Hyndman R.J., Athanasopoulos G. Forecasting: principles and practice. 3rd ed. Melbourne, Australia : OTexts, 2021. 442 p.
Reinsel, G. M. Ljung. – New Jersey : John Wiley & Sons. – 2015
8. Hayes, A. (n.d.). Autoregressive Integrated Moving Average (ARIMA) Prediction Model. Investopedia. <https://www.investopedia.com/terms/a/autoregressive-integrated-moving-average-arima.asp>
9. Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). Time series analysis: Forecasting and control (5th ed.). Hoboken, NJ, USA: John Wiley & Sons Inc. <https://doi.org/10.1111/jtsa.12194>
10. S. Siami-Namini, N. Tavakoli and A. Siami Namin, “A Comparison of ARIMA and LSTM in Forecasting Time Series,” 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA), 2018, pp. 1394-1401, doi: 10.1109/ICMLA.2018.00227
11. Korstanje J. Advanced Forecasting with Python. Apress, 2021.
12. Yfinance. PyPI. (n.d.). <https://pypi.org/project/yfinance/>
13. Перцев Ю. О., Коротка Л.І. Інноваційний підхід у прогнозуванні часових рядів: від традиційних методів до новаторської моделі TIMESFM. International scientific and technical conference Information Technologies in Metallurgy and Machine building – ITMM 2024. 2024. С. 434-439. (DOI: 10.34185/1991-7848.itmm.2024.01.084)
14. Перцев Ю. О., Коротка Л. І. Порівняння нейронних мереж RNN та LSTM типу при прогнозуванні цін на фондовому ринку. Матеріали VIII Міжнародної науково-технічної конференції комп'ютерне моделювання та оптимізація складних систем (1-3 листопада 2023 року м. Дніпро, Україна). С. 124-127.

15. Перцев Ю.О., Коротка Л.І. Нейромережеве прогнозування цін на фондовому ринку. International scientific and technical conference Information Technologies in Metallurgy and Machine building (ITMM 2023). 314-317 p.(DOI: 10.34185/1991-7848.itmm.2023.01.085)

Received 15.01.2025.
Accepted 17.01.2025.

***Comparative analysis of traditional statistical methods
and the lstm neural network model***

This paper presents a comparative analysis of traditional statistical methods (ARIMA, SARIMA) and a modern deep learning approach (LSTM) for financial time series forecasting. The study focuses on evaluating the efficiency of each model in predicting the closing price of Apple Inc. (NASDAQ: AAPL) stock. These models were selected due to their widespread use in financial analysis: ARIMA is suitable for stationary time series, SARIMA accounts for seasonal variations, and LSTM excels at capturing nonlinear dependencies and long-term trends.

The study is based on historical closing price data of AAPL stock from January 1, 2023, to January 20, 2025, obtained via the yfinance service. The experimental modeling aimed to compare the forecasting accuracy of each method using key performance metrics such as Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE).

The results indicate that the LSTM model outperforms ARIMA and SARIMA in forecasting accuracy due to its ability to efficiently model complex patterns in time series. SARIMA also demonstrated strong predictive capabilities, particularly for data with distinct seasonal components, surpassing ARIMA in accuracy. However, ARIMA yielded the lowest accuracy due to its limitations in capturing seasonality and nonlinear dependencies.

These findings provide valuable insights for analysts, investors, and researchers involved in financial forecasting. The study offers practical recommendations on model selection based on data characteristics and forecasting requirements, as well as an overview of the strengths and limitations of each approach.

Keywords: time series forecasting, ARIMA, SARIMA, LSTM, financial markets, machine learning, neural networks, accuracy assessment, stock market, data modeling

Перцев Юрій Олександрович - аспірант кафедри інформаційних систем за спеціальністю 122 «Комп'ютерні науки», Український університет науки і технологій.

Коротка Лариса Іванівна - к.т.н., доцент, доцент кафедри інформаційних систем, Український університет науки і технологій.

Pertsev Yurii Oleksiyovych - Postgraduate at the Department of Information Systems, with a specialty 122 «Computer Science», Ukrainian State University of Science and Technology.

Korotka Larysa Ivanivna - Candidate of Technical Sciences, Docent, Associate Professor at the Department of Information Systems, Ukrainian State University of Science and Technology.