

УДК (UDC) 519.9

**Бондаренко
Костянтин
Володимирович**

студент, ННІ комп'ютерних наук та штучного інтелекту,
Харківський національний університет імені В.Н. Каразіна, майдан
Свободи, 6, Харків, Україна, 61022
e-mail: bondarenko.konstantin.privat@gmail.com
<https://orcid.org/0009-0003-9911-7507>

**Стрілець
Вікторія Євгенівна**

к.т.н., доцент кафедри комп'ютерних систем та робототехніки, ННІ
комп'ютерних наук та штучного інтелекту, Харківський
національний університет імені В.Н. Каразіна, майдан Свободи, 6,
Харків, Україна, 61022
e-mail: viktoria.strilets@karazin.ua
<https://orcid.org/0000-0002-2475-1496>

**Шевченко
Дмитро Олександрович**

аспірант, ННІ комп'ютерних наук та штучного інтелекту,
Харківський національний університет імені В.Н. Каразіна, майдан
Свободи, 6, Харків, Україна, 61022
e-mail: dimyich24@gmail.com
<http://orcid.org/0000-0002-7897-250X>

Прогнозування економічних показників за допомогою моделі LSTM

Актуальність. Прогнозування економічних показників, зокрема цін на нафту, є критично важливим для різних галузей, таких як енергетика, фінанси, виробництво, транспорт та урядова політика. Точні прогнози сприяють прийняттю обґрунтованих рішень та оптимізації ресурсів. В умовах високої волатильності цін на нафту традиційні методи прогнозування, такі як ARIMA, часто не забезпечують належної точності, тому використання сучасних методів, таких як LSTM, є необхідним.

Метою дослідження є підвищення точності прогнозування економічних показників, зокрема цін на нафту марки Brent з використанням моделі LSTM та порівняння її точності з традиційними методами, зокрема ARIMA.

Методи дослідження. Для дослідження було використано два основні методи прогнозування часових рядів: ARIMA та LSTM. Було проведено розвідувальний аналіз даних, підготовку даних, побудову моделей, їх налаштування та оцінку за допомогою метрик MSE, MAE та RMSE. Дані про ціни на нафту марки Brent були оброблені та нормалізовані перед подачею в моделі.

Результати. Модель LSTM показала значно вищу точність прогнозування порівняно з ARIMA. Значення метрик для LSTM (MSE = 0.003, MAE = 0.055, RMSE = 0.055) суттєво перевищують відповідні значення для ARIMA (MSE = 12.59, MAE = 2.84, RMSE = 3.55). LSTM краще обробляє нелінійні залежності та волатильність даних, що робить її оптимальним вибором для довгострокового прогнозування.

Висновки. Використання LSTM для прогнозування економічних показників, зокрема цін на нафту, є більш ефективним у порівнянні з традиційними методами. Модель демонструє здатність до точного моделювання складних залежностей та адаптації до волатильності ринку, що робить її надійним інструментом для прогнозування в сучасних умовах.

Ключові слова: прогнозування економічних показників, LSTM, ARIMA, ціни на нафту, машинне навчання, часові ряди, волатильність.

Як цитувати: Бондаренко К. В., Стрілець В. Є., Шевченко Д. О. Прогнозування економічних показників за допомогою моделі LSTM. *Вісник Харківського національного університету імені В.Н. Каразіна, серія Математичне моделювання. Інформаційні технології. Автоматизовані системи управління*. 2024. вип. 64. С.13-24. <https://doi.org/10.26565/2304-6201-2024-64-02>

How to quote: K. V. Bondarenko, V. Y. Strilets, D. O. Shevchenko, "Forecasting economic indicators using the LSTM model" *Bulletin of V.N. Karazin Kharkiv National University, series Mathematical modelling. Information technology. Automated control systems*, vol. 64, pp.13-24, 2024. <https://doi.org/10.26565/2304-6201-2024-64-02>

1 Вступ

Прогнозування економічних показників таких, як ціни на нафту є важливим аспектом в економіці, фінансах та багатьох інших галузях. Ціна на нафту впливає на вартість енергоносіїв, транспорту, виробництва та багатьох інших сфер діяльності. Точне прогнозування цін на нафту допомагає підприємствам та урядам приймати обґрунтовані рішення та планувати свої дії. Наприклад, прогнозування цін на нафту має важливе значення для:

1. Планування виробництва енергетичними компаніями. Енергетичні компанії використовують прогнози цін на нафту для планування обсягу видобутку та виробництва. Це допомагає оптимізувати ресурси та зменшити витрати.

2. Управління запасами ресурсів. Прогнозування допомагає ефективно управляти сировини, що забезпечує безперервність виробництва.

3. Інвестиційні стратегії. Інвестори використовують прогнози цін на нафту для розробки стратегій торгівлі та інвестування. Це допомагає зменшити ризики та підвищити прибутковість інвестицій.

4. Планування витрат у транспортній логістиці. Компанії, що займаються транспортом, використовують прогнози цін на нафту для планування своїх витрат на паливо. Це допомагає ефективніше розподіляти бюджет та встановлювати ціни на свої послуги.

5. Формування бюджетів компаній і країн. Прогнозування допомагає урядам планувати доходи від нафтогазового сектора, що є важливим для формування державного бюджету.

Таким чином, прогнозування цін на нафту є критично важливим для багатьох галузей економіки та має значний вплив на прийняття рішень на різних рівнях. Використання сучасних методів прогнозування, таких як LSTM, дозволяє отримувати більш точні та надійні прогнози, що сприяє підвищенню ефективності та стабільності роботи підприємств та організацій.

Метою дослідження є підвищення точності прогнозування цін на нафту марки Brent за допомогою розробки відповідних моделей на основі методів глибокого навчання, зокрема довготривалої короткострокової пам'яті (LSTM). Використання LSTM обумовлене його здатністю ефективно обробляти часові ряди та враховувати довготривалі залежності у даних.

У роботі також була здійснена спроба побудови моделі на основі авторегресійної інтегрованої моделі ковзного середнього (ARIMA). Однак результати показали, що ARIMA має обмежену здатність до точного прогнозування в умовах високої волатильності даних про ціни на нафту.

2 Моделювання економічних показників

Під час моделювання або аналізу показники економічних систем розглядають у вигляді часових рядів [1]. Прогнозування часових рядів є важливим інструментом в аналізі даних, що дозволяє передбачати майбутні значення на основі наявних історичних даних. Цей підхід, що широко використовується в багатьох сферах, таких як економіка, фінанси, енергетика, метеорологія, виробництво та багато інших. Основна мета прогнозування часових рядів полягає у створенні моделі, яка може точно передбачати майбутні значення ряду.

Прогнозування часових рядів є ключовим напрямком досліджень в області машинного навчання, особливо з появою глибоких нейронних мереж, таких як LSTM. Дослідження показують, що LSTM має здатність ефективно моделювати часові залежності та враховувати довготривалі залежності у даних, що робить його більш ефективним у порівнянні з традиційними методами, такими як ARIMA [2].

LSTM (Long Short-Term Memory) – це різновид рекурентних нейронних мереж, розроблений для подолання проблеми довгострокової залежності, яка є характерною для традиційних рекурентних нейронних мереж. LSTM здатна зберігати інформацію на довгі періоди часу, що робить її ефективною для задач прогнозування часових рядів [3].

Дослідження [2, 4-6] показують, що моделі LSTM широко застосовуються в різних галузях, включаючи фінанси, охорону здоров'я та енергетику. Особливо успішно вони використовуються для прогнозування цін на нафту завдяки здатності враховувати нелінійні залежності та волатильність ринку.

Модель ARIMA (Autoregressive Integrated Moving Average) є класичним методом прогнозування часових рядів, що базується на авторегресії, інтеграції та ковзному середньому [2, 7, 8]. ARIMA ефективна для прогнозування стаціонарних часових рядів і широко використовується в економетричному моделюванні [9, 10].

Однак, модель ARIMA має обмеження в умовах високої волатильності та нелінійних залежностей, що часто спостерігаються в реальних даних про ціни на нафту [11].

Згідно з оглядом літератури, сучасні дослідження підтверджують, що методи глибокого навчання, такі як LSTM, мають значні переваги перед традиційними методами, такими як ARIMA, у задачах прогнозування складних часових рядів. Наприклад, у статті [12] розглядаються різні глибокі послідовні моделі та їх застосування для прогнозування часових рядів, включаючи LSTM, що демонструє їх ефективність у порівнянні з традиційними методами.

Це дослідження підкреслює важливість використання глибоких нейронних мереж у сучасних задачах прогнозування, що підтверджує обґрунтованість вибору методу LSTM для даної курсової роботи.

3. Опис даних та розвідувальний аналіз

3.1 Набір даних для дослідження

Для наукового дослідження було використано датасет, що містить дані про ціни на нафту марки Brent. Джерело датасету — відкритий архів історичних цін на нафту, доступний для завантаження з Інтернету (<https://www.kaggle.com/datasets/mabusalah/brent-oil-prices>).

Датасет охоплює тривалий період, починаючи з 1980х років, що дозволяє аналізувати динаміку змін цін на нафту протягом багатьох років. Це забезпечує достатньо даних для тренування та тестування моделей прогнозування. Дані збираються щоденно, що забезпечує високу точність та деталізацію для аналізу та побудови прогнозних моделей.

Кожен запис у датасеті складається з:

- дата (Date): стовпчик, що містить дату спостереження у форматах "%d-%b-%y" або "%b %d, %Y".
- ціна (Price): стовпчик, що містить ціну на нафту марки Brent у відповідний день.

Дані були очищені від пропущених значень та приведені до єдиного формату дати для забезпечення коректності аналізу. Датасет був відсортований за датою, що дозволило представити дані як послідовність часових рядів.

Значення змінної Price були нормалізовані для подальшого використання у моделях глибокого навчання, що дозволяє поліпшити продуктивність та стабільність моделей.

Використаний датасет забезпечує достатню кількість даних для проведення аналізу та побудови прогнозних моделей. Його основні характеристики, такі як тривалий період покриття, щоденна частота даних та попередня обробка, дозволяють ефективно використовувати сучасні методи машинного навчання для прогнозування цін на нафту марки Brent.

3.2. Розвідувальний аналіз даних

Розвідувальний аналіз даних (EDA) є важливим етапом у підготовці даних для моделювання, оскільки він допомагає зрозуміти основні характеристики та структуру даних [8].

Для датасету цін на нафту марки Brent спочатку був побудований графік часового ряду (рис. 1), щоб візуалізувати зміну цін на нафту протягом часу. Це допомагає ідентифікувати тренди, сезонність та будь-які аномалії у даних.




Рисунок 1. Графік часового ряду ціни на нафту

Було обчислено основні статистичні показники, такі як середнє, медіана, стандартне відхилення, мінімум та максимум цін на нафту (табл. 1). Вони показують розподіл даних та їх варіативність.

Таблиця 1. Статистичні показники часового ряду

Min	1st Qu.	Median	Mean	3rd Qu.	Max
9,10	19,05	38,57	48,42	70,09	143,95

Було проведено аналіз на наявність сезонності та довгострокових трендів у даних. Для цього використовувалися методи декомпозиції часових рядів, що дозволяють виділити тренд, сезонну складову та залишкові компоненти (рис. 2).




Рисунок 2. Декомпозиція часового ряду

Було побудовано графік автокореляційної функції (ACF) для виявлення автокореляції у даних. Графік показує, що поточні значення цін на нафту залежать від попередніх значень (рис. 3).




Рисунок 3. Графік автокореляційної функції

Розвідувальний аналіз даних дозволив глибше зрозуміти структуру та характеристики датасету цін на нафту марки Brent. Виявлені тренди, сезонність та автокореляція забезпечують цінну інформацію для подальшого моделювання та прогнозування. Використання EDA допомагає підготувати дані до побудови ефективних моделей машинного навчання, таких як LSTM, що дозволяє отримувати більш точні прогнози.

4 Побудова і оцінка моделей прогнозування

4.1. Модель ARIMA

Модель ARIMA (Autoregressive Integrated Moving Average) є однією з найбільш поширених і широко використовуваних моделей для аналізу та прогнозування часових рядів [7].

Вона поєднує три основні компоненти:

– авторегресію (AR): цей компонент передбачає, що значення часових рядів залежить від попередніх значень. Модель авторегресії включає параметр p , який вказує на кількість попередніх значень, що враховуються при прогнозуванні;

– інтеграцію (I): цей компонент включає різницювання, щоб зробити ряд стаціонарним. Параметр d вказує на кількість разів, які потрібно різницювати ряд для досягнення стаціонарності;

– ковзне середнє (MA): цей компонент враховує попередні похибки прогнозування. Модель ковзного середнього включає параметр q , який визначає кількість попередніх похибок, що використовуються для корекції прогнозу.

Модель ARIMA зазвичай позначається як ARIMA (p, d, q), де p – порядок авторегресії, d – порядок інтеграції, q – порядок ковзного середнього. У роботі значення параметрів p, d, q були отримані із використанням функції `auto.arima`, яка автоматично їх підбирає.

Модель ARIMA була налаштована з параметрами ARIMA (2,1,2). На її основі змодельовані фактичні, тестові та прогнозовані значення цін на нафту марки Brent за останні 60 днів (рис. 4).




Рисунок 4. Результат прогнозування ціни на нафту на основі моделі ARIMA

Для оцінки точності прогнозів моделі ARIMA були використані три основні метрики: середньоквадратична похибка (MSE), середня абсолютна похибка (MAE) та корінь середньоквадратичної похибки (RMSE). Були отримані такі показники якості моделі ARIMA:

- MSE (Mean Squared Error): 12.59455;
- MAE (Mean Absolute Error): 2.84492;
- RMSE (Root Mean Squared Error): 3.54888.

Високе значення MSE свідчить про те, що помилки прогнозування значні і моделі складно передбачати точні значення цін на нафту. Значення MAE 2.84492 показує, що в середньому модель помиляється на 2.84 долари при прогнозуванні ціни на нафту. Значення RMSE 3.54888 також свідчить про значні помилки прогнозування.

Графік та метрики показують, що модель ARIMA змогла частково вловити тренди у тестових даних, але її прогнози не були достатньо точними, що підкреслює необхідність використання більш потужних методів, таких як LSTM, для більш точного прогнозування цін на нафту.

Серед причини недостатньої продуктивності моделі ARIMA можна навести:

1. Ціни на нафту характеризуються високою волатильністю і можуть різко змінюватися через різні фактори, такі як політичні події, природні катаклізми або зміни попиту та пропозиції. ARIMA модель може мати труднощі з прогнозуванням таких різких змін.

2. ARIMA модель є лінійною моделлю і не враховує нелінійні залежності між значеннями в часових рядах. Це може призвести до менш точних прогнозів у випадках, коли дані мають складні нелінійні залежності.

3. ARIMA модель вимагає, щоб дані були стаціонарними (мають постійне середнє і дисперсію). Незважаючи на застосування різницювання для досягнення стаціонарності, моделі може бути складно адекватно врахувати довгострокові тренди та сезонність у даних.

Таким чином, результати моделі ARIMA демонструють обмеження лінійних методів для прогнозування складних часових рядів з високою волатильністю та нелінійними залежностями.

4.2. Модель LSTM

LSTM (Long Short-Term Memory) – це різновид рекурентних нейронних мереж (RNN), спеціально розроблений для розв'язання проблеми довгострокової залежності, яка є характерною для традиційних RNN. LSTM-мережі здатні ефективно обробляти часові ряди, зберігаючи інформацію на тривалий період, що робить їх ідеальними для прогнозування часових рядів [13].

Архітектура LSTM:

1. Осередок пам'яті (Memory Cell) – основний компонент LSTM, який зберігає інформацію на довгий час. Осередок пам'яті контролюється трьома основними гейтами (воротами), які дозволяють керувати потоком інформації через нейронну мережу.

2. Гейт забуття (Forget Gate) вирішує, яку частину інформації з осередку пам'яті потрібно забути. Вхід до цього гейту – це комбінація попереднього стану прихованого шару та поточного вхідного сигналу, який проходить через сигмоїдну функцію активації:

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f).$$

3. Гейт введення (Input Gate) вирішує, яку нову інформацію потрібно додати до осередку пам'яті. Складається з двох частин: сигмоїдного шару, який вирішує, які значення оновити, та тангенсного шару, який створює нові кандидати на додавання до осередку пам'яті:

$$\begin{aligned} i_t &= \sigma(W_i * [h_{t-1}, x_t] + b_i), \\ \bar{C}_t &= \tanh(W_C * [h_{t-1}, x_t] + b_C). \end{aligned}$$

4. Гейт виходу (Output Gate) вирішує, яку частину інформації з осередку пам'яті потрібно вивести. Сигмоїдний шар вирішує, що вивести, а тангенсний шар обмежує значення між -1 та 1:

$$\begin{aligned} o_t &= \sigma(W_o * [h_{t-1}, x_t] + b_o), \\ h_t &= o_t * \tanh(C_t). \end{aligned}$$

5. Оновлення осередку пам'яті. Новий стан осередку пам'яті формується за допомогою забуття частини старої інформації та додавання нової:

$$C_t = f_t * C_{t-1} + i_t * \bar{C}_t.$$

LSTM може використовуватися для прогнозування часових рядів, оскільки має такі особливості:

- завдяки своїй архітектурі, LSTM може зберігати та використовувати інформацію з попередніх кроків на довгих відстанях у часових рядах, що дозволяє їй ефективно моделювати складні часові залежності⁴

- на відміну від традиційних RNN, LSTM менш схильна до проблеми градієнтного затухання, що робить її більш стійкою та ефективною при тренуванні на довгих часових рядах;

- LSTM може адаптуватися до різних типів даних та структур часових рядів, що робить її універсальним інструментом для прогнозування;

- завдяки своїй здатності до обробки нелінійних залежностей, LSTM може краще моделювати складні процеси у часових рядах, що забезпечує точніші прогнози порівняно з лінійними моделями, такими як ARIMA.

Таким чином, LSTM є потужним інструментом для прогнозування часових рядів завдяки своїй здатності ефективно обробляти довгострокові та нелінійні залежності, що робить її ідеальною для задач прогнозування цін на нафту марки Brent.

Процес налаштування гіперпараметрів є критичним етапом при побудові моделі LSTM, оскільки від правильного вибору гіперпараметрів залежить точність та ефективність моделі [14]. Основні гіперпараметри, які потрібно налаштувати для LSTM, включають кількість блоків (units), кількість епох (epochs), розмір пакета (batch size) та оптимізатор (optimizer).

Кількість блоків (units) LSTM визначає розмір прихованого шару. Більша кількість блоків може дозволити моделі захоплювати більш складні патерни, але також збільшує обчислювальні витрати та ризик перенавчання. Діапазон перевірених значень: 10, 50, 100 блоків.

Кількість епох (epochs) визначає, скільки разів модель пройде через весь тренувальний набір даних. Більша кількість епох може поліпшити точність моделі, але також може призвести до перенавчання. Діапазон перевірених значень: від 1 до 2 епох.

Розмір пакета (batch size) визначає кількість прикладів, що використовуються для одного оновлення ваг під час тренування. Менший розмір пакета може забезпечити більш стабільне оновлення ваг, але збільшує час тренування. Діапазон перевірених значень: 1, 10.

Оптимізатор (optimizer) визначає метод оновлення ваг моделі під час тренування. Вибір оптимізатора може суттєво вплинути на швидкість збіжності та точність моделі. Діапазон перевірених значень: 'adam', 'sgd', 'rmsprop', 'adagrad', 'adadelat', 'adamax', 'nadam', 'ftrl'.

Процес налаштування гіперпараметрів включав ітеративне тестування різних комбінацій гіперпараметрів для визначення кращих налаштувань моделі для прогнозування цін на нафту марки Brent.

Для побудови та навчання моделі LSTM використовувався скрипт на мові програмування R [15]. Використовувались бібліотеки, такі як keras, tensorflow, tidyverse, timetk.

Для оцінки моделі LSTM були використані три основні метрики: MSE, MAE та RMSE. У табл. 2 наведено 5 кращих результатів з цієї таблиці для різних конфігурацій моделі LSTM, відсортовану за показником RMSE:

Таблиця 2. Результати тестування гіперпараметрів моделі

Units	Batch size	Epochs	Optimizer	MSE	MAE	RMSE
50	1	2	adam	0.003056	0.055120	0.055283
10	1	2	adam	0.004808	0.063459	0.069341
100	1	2	nadam	0.006688	0.077512	0.081778
100	1	2	adam	0.009115	0.090693	0.095471

Кращою виявилася модель з конфігурацією: Units: 50, Batch size: 1, Epochs: 2, Optimizer: adam, з найменшим значенням RMSE 0.055283.

Для оцінки та розуміння роботи моделі LSTM були створені декілька графіків, які допомагають проаналізувати продуктивність моделі, помилки прогнозування та відповідність фактичних та прогнозованих значень.

Крива втрат під час навчання (Training Loss Curve) показує, як зменшується значення функції втрат під час навчання моделі на кожній епосі. Графік (рис. 5) демонструє зменшення втрат, що свідчить про покращення моделі під час навчання.




Рисунок 5. Графік кривої втрат

Графік фактичних та прогнозованих значень (Actual vs. Forecasted Values) показує порівняння фактичних значень цін на нафту та прогнозованих значень на основі моделі LSTM. Візуалізація включає прогнози на 100 днів назад (рис. 6), що дозволяє оцінити точність та відповідність моделі.

Графік автокореляції залишків (ACF of Prediction Errors) показує автокореляцію помилок прогнозування для різних лагів. Він допомагає виявити, чи існує автокореляція між помилками прогнозування, що може вказувати на недоліки моделі. На графіку (рис. 7) видно, що автокореляція помилок швидко зменшується, що вказує на хорошу модель прогнозування.




Рисунок 6. Графік прогнозування значень на 100 днів назад




Рисунок 7. Графік автокореляції залишків

На рис. 8 показаний графік прогнозу значень цін на нафту на 100 днів вперед. Він дозволяє оцінити, як модель передбачає майбутні значення на основі історичних даних. Прогнози моделі LSTM на наступні 100 днів демонструють високу точність та відповідність фактичним значенням, що підтверджує ефективність цієї моделі для задач прогнозування.




Рисунок 8. Графік прогнозування значень на 100 днів вперед

6. Аналіз результатів

Порівняння продуктивності моделей ARIMA та LSTM було проведено по основним метрикам MSE, MAE та RMSE (табл. 3).

Таблиця 3. Порівняння моделей ARIMA та LSTM

Модель	MSE	MAE	RMSE
ARIMA	12.59455	2.84492	3.54888
LSTM	0.003056	0.055120	0.055283

Модель LSTM має значно менше значення MSE (0.003056) порівняно з моделлю ARIMA (12.59455). Це вказує на те, що модель LSTM має значно менші помилки прогнозування в середньому. Модель LSTM також має значно менше значення MAE (0.055120) порівняно з моделлю ARIMA (2.84492). Це означає, що в середньому помилки прогнозування моделі LSTM є набагато меншими. І значення RMSE для моделі LSTM (0.055283) є значно меншим порівняно з моделлю ARIMA (3.54888). Оскільки RMSE надає інтерпретоване значення помилки в тих же одиницях, що і прогнозовані значення, можна сказати, що модель LSTM є більш точною.

Результати порівняння моделей показують, що використання сучасних методів глибокого навчання, таких як LSTM, забезпечує значно кращу точність і ефективність прогнозування порівняно з традиційними методами, такими як ARIMA. Це підтверджує необхідність використання більш потужних і адаптивних моделей для складних задач прогнозування у реальних умовах.

На основі порівняння моделей та їх продуктивності, модель LSTM з найкращими показниками точності була обрана як остаточна модель для прогнозування цін на нафту марки Brent. Цей вибір обумовлений значно вищою точністю прогнозів, здатністю обробляти складні нелінійні залежності та адаптацією до високої волатильності ринку. Використання моделі LSTM забезпечує більш надійні та точні прогнози, що є критично важливим для прийняття обґрунтованих рішень у різних галузях економіки та фінансів.

7 Висновки та рекомендації

У роботі було розглянуто процес побудови та оцінки моделей для прогнозування цін на нафту марки Brent з використанням моделей ARIMA та LSTM. На основі проведеного аналізу можна зробити основні висновки:

- Модель ARIMA, хоча і є популярною та широко використовуваною для прогнозування часових рядів, показала недостатньо точні результати для прогнозування цін на нафту марки Brent. Основні обмеження моделі ARIMA включають її лінійність та обмежену здатність обробляти складні, нелінійні залежності у даних.

- Модель LSTM показала значно кращі результати у прогнозуванні цін на нафту порівняно з моделлю ARIMA. Це обумовлено здатністю LSTM моделювати довгострокові залежності та складні патерни у часових рядах. Модель LSTM продемонструвала високу точність прогнозування, адаптацію до волатильності ринку та здатність обробляти нелінійні залежності.

Таким чином, сучасні методи глибокого навчання, такі як LSTM, є значно більш ефективними для прогнозування цін на нафту марки Brent порівняно з традиційними методами, такими як ARIMA. Висока точність прогнозів, здатність моделювати складні залежності та адаптація до волатильності ринку роблять LSTM потужним інструментом для прогнозування у різних галузях економіки та фінансів.

На основі проведеного дослідження та отриманих результатів можна запропонувати наступні рекомендації щодо подальшого покращення моделі LSTM для прогнозування цін на нафту марки Brent, а також напрямків для майбутніх досліджень:

1. Подальше покращення моделі LSTM:

- Провести більш детальний пошук гіперпараметрів, включаючи більший діапазон значень для units, batch size, epochs та різні типи оптимізаторів. Можна використовувати методи, такі як Grid Search або Random Search, для автоматизації цього процесу.

- Додати регуляризацию (наприклад, Dropout) для запобігання перенавчанню моделі. Це допоможе зробити модель більш стійкою та покращити її узагальнення на нових даних.

- Використовувати більш тривалий історичний період для навчання моделі. Збільшення обсягу даних може покращити точність прогнозування, особливо якщо включити дані з різних ринкових умов.

- Включити додаткові ознаки (features), такі як макроекономічні показники, геополітичні події, сезонні фактори тощо. Це може допомогти моделі краще розуміти контекст і робити точніші прогнози.

2. Напрямки для майбутніх досліджень:

- Порівняння з іншими моделями. Порівняти продуктивність моделі LSTM з іншими сучасними моделями глибокого навчання, такими як GRU (Gated Recurrent Unit) або Transformer моделі. Це може допомогти знайти ще більш ефективні підходи до прогнозування.

- Розробити гібридні моделі, які поєднують LSTM з іншими методами машинного навчання або економетричними моделями. Гібридні підходи можуть забезпечити більш точні та стабільні прогнози.

- Аналіз впливу зовнішніх факторів. Дослідити вплив різних зовнішніх факторів на точність прогнозування, таких як зміни в регуляторній політиці, технологічні інновації, зміни в попиті та пропозиції на ринку нафти. Це допоможе краще зрозуміти, як модель реагує на різні умови.

- Працювати над покращенням інтерпретованості моделі LSTM. Це включає розробку методів для пояснення, які фактори впливають на прогнози, що може бути важливим для прийняття бізнес-рішень.

- Впровадити модель у реальне середовище для тестування її продуктивності в реальних умовах. Це дозволить оцінити її практичну цінність та ефективність у прийнятті рішень.

Рекомендації щодо подальшого покращення моделі LSTM та напрямків для майбутніх досліджень дозволяють забезпечити подальший розвиток та вдосконалення методів прогнозування цін на нафту марки Brent. Використання передових технік машинного навчання та глибокого аналізу даних допоможе підвищити точність прогнозів та забезпечити ефективні інструменти для прийняття обґрунтованих рішень у фінансових та економічних галузях.

СПИСОК ЛІТЕРАТУРИ

1. Box, G. E., Jenkins, G. M., & Reinsel, G. C. (2015). *Time Series Analysis: Forecasting and Control* (5th ed.). Wiley. <https://doi.org/10.1002/9781118619193> (дата звернення 12.10.2024)
2. Dozdar Mahdi Ahmed, Masoud Muhammed Hassan and Ramadhan J. Mstafa (2022). A Review on Deep Sequential Models for Forecasting Time Series Data. <https://doi.org/10.1155/2022/6596397> (дата звернення 12.10.2024)
3. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735> (дата звернення 12.10.2024)
4. Bouktif, S., Fiaz, A., Ouni, A., & Serhani, M. A. (2018). Optimal deep learning LSTM model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches. *Energies*, 11(7), 1636. <https://doi.org/10.3390/en11071636> (дата звернення 12.10.2024)
5. Nelson, D. M., Pereira, A. C. M., & de Oliveira, R. A. (2017). Stock market's price movement prediction with LSTM neural networks. *Proceedings of the International Joint Conference on Neural Networks (IJCNN)*, 1419-1426. <https://doi.org/10.1109/IJCNN.2017.7966019> (дата звернення 12.10.2024)
6. Shahid, F., Zameer, A., & Muneeb, M. (2020). Predictions for COVID-19 with deep learning models of LSTM, GRU and Bi-LSTM using sequential and statistical data. *Chaos, Solitons & Fractals*, 140, 110212. <https://doi.org/10.1016/j.chaos.2020.110212> (дата звернення 12.10.2024)
7. Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0) (дата звернення 12.10.2024)
8. Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS ONE*, 13(3), e0194889. <https://doi.org/10.1371/journal.pone.0194889> (дата звернення 12.10.2024)

9. Smyl, S. (2020). A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, 36(1), 75-85. <https://doi.org/10.1016/j.ijforecast.2019.03.017> (дата звернення 12.10.2024)
10. Lawrence, M. J., Goodwin, P., O'Connor, M., & Önköl, D. (2006). Judgmental forecasting: A review of progress over the last 25 years. *International Journal of Forecasting*, 22(3), 493-518. <https://doi.org/10.1016/j.ijforecast.2006.03.007> (дата звернення 12.10.2024)
11. Hyndman, R. J., & Athanasopoulos, G. (2018). Forecasting: Principles and Practice (2nd ed.). OTexts. <https://otexts.com/fpp3/> (дата звернення 12.10.2024)
12. Siami-Namini, S., Tavakoli, N., & Siami Namin, A. (2019). A comparison of ARIMA and LSTM in forecasting time series. *IEEE International Conference on Machine Learning and Applications (ICMLA)*, 1394-1401. <https://doi.org/10.1109/ICMLA.2018.00227> (дата звернення 12.10.2024)
13. Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451-2471. <https://doi.org/10.1162/089976600300015015> (дата звернення 12.10.2024)
14. Zhou, Z. H. (2012). Ensemble methods: Foundations and algorithms. *Chapman and Hall/CRC*. <https://doi.org/10.1201/b12207> (дата звернення 12.10.2024)
15. Hyndman, R. J., & Khandakar, Y. (2008). Automatic time series forecasting: The forecast package for R. *Journal of Statistical Software*, 27(3), 1-22. <https://doi.org/10.18637/jss.v027.i03> (дата звернення 12.10.2024)

REFERENCES

1. Box, G. E., Jenkins, G. M., & Reinsel, G. C. (2015). Time Series Analysis: Forecasting and Control (5th ed.). Wiley. <https://doi.org/10.1002/9781118619193> (дата звернення 12.10.2024)
2. Dozdar Mahdi Ahmed, Masoud Muhammed Hassan and Ramadhan J. Mstafa (2022). A Review on Deep Sequential Models for Forecasting Time Series Data. <https://doi.org/10.1155/2022/6596397> (дата звернення 12.10.2024)
3. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735> (дата звернення 12.10.2024)
4. Bouktif, S., Fiaz, A., Ouni, A., & Serhani, M. A. (2018). Optimal deep learning LSTM model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches. *Energies*, 11(7), 1636. <https://doi.org/10.3390/en11071636> (дата звернення 12.10.2024)
5. Nelson, D. M., Pereira, A. C. M., & de Oliveira, R. A. (2017). Stock market's price movement prediction with LSTM neural networks. *Proceedings of the International Joint Conference on Neural Networks (IJCNN)*, 1419-1426. <https://doi.org/10.1109/IJCNN.2017.7966019> (дата звернення 12.10.2024)
6. Shahid, F., Zameer, A., & Muneeb, M. (2020). Predictions for COVID-19 with deep learning models of LSTM, GRU and Bi-LSTM using sequential and statistical data. *Chaos, Solitons & Fractals*, 140, 110212. <https://doi.org/10.1016/j.chaos.2020.110212> (дата звернення 12.10.2024)
7. Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0) (дата звернення 12.10.2024)
8. Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS ONE*, 13(3), e0194889. <https://doi.org/10.1371/journal.pone.0194889> (дата звернення 12.10.2024)
9. Smyl, S. (2020). A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, 36(1), 75-85. <https://doi.org/10.1016/j.ijforecast.2019.03.017> (дата звернення 12.10.2024)
10. Lawrence, M. J., Goodwin, P., O'Connor, M., & Önköl, D. (2006). Judgmental forecasting: A review of progress over the last 25 years. *International Journal of Forecasting*, 22(3), 493-518. <https://doi.org/10.1016/j.ijforecast.2006.03.007> (дата звернення 12.10.2024)
11. Hyndman, R. J., & Athanasopoulos, G. (2018). Forecasting: Principles and Practice (2nd ed.). OTexts. <https://otexts.com/fpp3/> (дата звернення 12.10.2024)

12. Siami-Namini, S., Tavakoli, N., & Siami Namin, A. (2019). A comparison of ARIMA and LSTM in forecasting time series. *IEEE International Conference on Machine Learning and Applications (ICMLA)*, 1394-1401. <https://doi.org/10.1109/ICMLA.2018.00227> (дата звернення 12.10.2024)
13. Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451-2471. <https://doi.org/10.1162/089976600300015015> (дата звернення 12.10.2024)
14. Zhou, Z. H. (2012). Ensemble methods: Foundations and algorithms. *Chapman and Hall/CRC*. <https://doi.org/10.1201/b12207> (дата звернення 12.10.2024)
15. Hyndman, R. J., & Khandakar, Y. (2008). Automatic time series forecasting: The forecast package for R. *Journal of Statistical Software*, 27(3), 1-22. <https://doi.org/10.18637/jss.v027.i03> (дата звернення 12.10.2024)

**Bondarenko
Kostiantyn**

student of Education and Research Institute of Computer Sciences and Artificial Intelligence, V.N. Karazin Kharkiv National University, 6 Svobody sq., Kharkiv, Ukraine, 61022

Strilets Viktoriia

Ph.D, associate professor of the Department of Computer Systems and Robotics, Education and Research Institute of Computer Sciences and Artificial Intelligence, V.N. Karazin Kharkiv National University, 6 Svobody sq., Kharkiv, Ukraine, 61022

Shevchenko Dmytro

PhD student of Education and Research Institute of Computer Sciences and Artificial Intelligence, V.N. Karazin Kharkiv National University, 6 Svobody sq., Kharkiv, Ukraine, 61022

Forecasting economic indicators using the LSTM model

Relevance. Forecasting economic indicators, particularly oil prices, is critically important for various industries such as energy, finance, manufacturing, transportation, and government policy. Accurate forecasts facilitate informed decision-making and resource optimization. In conditions of high oil price volatility, traditional forecasting methods like ARIMA often do not provide sufficient accuracy, making the use of modern methods such as LSTM necessary.

Objective. The objective of the study is to develop a model for forecasting Brent crude oil prices using the LSTM model and to compare its accuracy with traditional methods, including ARIMA.

Research methods. Two main time series forecasting methods, ARIMA and LSTM, were used in this study. Exploratory data analysis, data preparation, model building, model tuning, and evaluation using MSE, MAE, and RMSE metrics were conducted. Brent crude oil price data was processed and normalized before being fed into the models.

Results. The LSTM model demonstrated significantly higher forecasting accuracy compared to ARIMA. The metrics for LSTM (MSE = 0.003, MAE = 0.055, RMSE = 0.055) significantly outperform the corresponding values for ARIMA (MSE = 12.59, MAE = 2.84, RMSE = 3.55). LSTM better handles nonlinear dependencies and data volatility, making it an optimal choice for long-term forecasting.

Conclusions. The use of LSTM for forecasting economic indicators, particularly oil prices, is more effective compared to traditional methods. The model demonstrates the ability to accurately model complex dependencies and adapt to market volatility, making it a reliable tool for forecasting in modern conditions.

Keywords: economic indicator forecasting, LSTM, ARIMA, oil prices, machine learning, time series, volatility.