

ОСОБЛИВОСТІ КОМБІНОВАНОГО МОДЕЛЮВАННЯ ЛІНІЙНИХ ТА НЕЛІНІЙНИХ КОМПОНЕНТ ФОНДОВИХ ІНДЕКСІВ

Кучеренко В.В.

e-mail: vitalii.kucherenko@nure.ua

Науковий керівник – канд. техн. наук, доц. Сердюк Н.М.
Харківський національний університет радіоелектроніки,
кафедра інформаційних систем і технологій
м. Харків, Україна

This work is devoted to assessing the efficiency of combined modeling for stock indices, namely, hybrid architectures based on ARIMA and LSTM. The basic principles of time series decomposition into linear and nonlinear components to improve medium-term forecasting accuracy were considered. Practical experiments on the S&P 500 and NASDAQ index data were conducted to evaluate the models using standard RMSE and MAE metrics. The research confirms that statistical models effectively filter linear trends, while deep learning networks successfully capture complex nonlinear patterns. The conclusion highlights the practical utility of this integrated approach for risk management tasks, such as Value-at-Risk calculation, while outlining the limitations related to computational costs.

Прогнозування динаміки фондових індексів є складною задачею через волатильність та нелінійність ринкових даних. Традиційні економетричні моделі, як-от ARIMA, ефективно описують лінійні тренди, але нездатні впоратися зі складними патернами. Моделі глибокого навчання, зокрема LSTM, навпаки, добре моделюють нелінійні залежності, однак можуть бути менш точними при аналізі змішаних сигналів. У цьому контексті найбільш перспективним є створення гібридних моделей, що інтегрують переваги обох підходів. Матеріалом дослідження виступають часові ряди провідних світових фондових індексів, таких як S&P 500 та NASDAQ. Метою роботи є аналіз та експериментальне оцінювання ефективності гібридних моделей типу ARIMA–LSTM для підвищення точності середньострокового прогнозування (на горизонті 1–3 місяці), а також уточнення ролі лінійної та нелінійної компонент у загальній архітектурі моделі.

Для досягнення мети поставлено такі завдання: 1) дослідити застосовність статистичної моделі ARIMA для виділення лінійної компоненти фондових індексів; 2) реалізувати модель глибокого навчання LSTM (або її спрощений аналог GRU) для моделювання нелінійних залишків; 3) побудувати гібридну модель на основі декомпозиції сигналу; 4) порівняти точність гібридного підходу з окремими моделями ARIMA та LSTM за стандартними метриками помилки.

Найпоширенішим є метод декомпозиції, де статистична модель ARIMA використовується для виявлення та прогнозування лінійної компоненти ряду. Залишкові помилки, які містять складні нелінійні патерни,

потім моделюються за допомогою нейронних мереж, таких як LSTM або їх спрощеного аналога GRU. Дослідження підтверджують, що такий підхід стабільно забезпечує вищу точність прогнозування порівняно з використанням кожної з моделей окремо.

В основі гібридних моделей лежить синергія двох методологічно різних підходів. Статистична модель ARIMA, параметри якої оптимізуються за інформаційними критеріями (AIC/BIC), призначена для опису лінійних залежностей. Модель глибокого навчання LSTM, у свою чергу, є типом рекурентної нейронної мережі, здатної вивчати довгострокові залежності завдяки архітектурі з вентилями пам'яті. Принцип гібридизації полягає в послідовному застосуванні цих моделей: ARIMA моделює лінійну частину, а багатошарова LSTM (зазвичай 2–3 шари) з використанням методів регуляризації моделює нелінійні залишки.

Побудова такої моделі вимагає ретельної підготовки даних, що включає перевірку ряду на стаціонарність (наприклад, за допомогою тесту Дікі–Фуллера), диференціювання та нормалізацію значень. Валідація моделі здійснюється за допомогою «ковзного» (walk-forward) підходу, що зберігає часову послідовність даних. Для оцінки точності використовуються стандартні метрики, такі як середньоквадратична помилка (RMSE) та середня абсолютна помилка (MAE).

Практичні експерименти на часових рядах індексів S&P 500 та NASDAQ показали, що гібридна модель ARIMA–LSTM забезпечує зниження RMSE у середньому приблизно на 10–15% порівняно з окремими моделями ARIMA та LSTM на прогнозному горизонті 1–3 місяці. Додатково спостерігається зменшення MAE, що свідчить про підвищення стабільності прогнозу. Отримані результати підтверджують, що декомпозиція сигналу на лінійну та нелінійну компоненти полегшує задачу для нейронної мережі й дає змогу краще враховувати складну структуру фінансових часових рядів.

Ключова перевага гібридних моделей полягає в їхній здатності комплексно вирішувати проблеми, властиві фінансовим даним. ARIMA виступає в ролі фільтра, який «очищує» дані від лінійної компоненти, що значно спрощує завдання для нейронної мережі. Практичне застосування таких моделей є широким: від алгоритмічної торгівлі до управління ризиками, де точне прогнозування волатильності дозволяє динамічно розраховувати показник Value-at-Risk (VaR). Водночас гібридний підхід має певні обмеження: ефективність сильно залежить від якості та стабільності історичних даних, а моделі глибокого навчання є обчислювально затратними та схильними до перенавчання, що вимагає ретельного налаштування архітектури та параметрів регуляризації.

Інтеграція статистичних моделей та методів глибокого навчання є високоефективним підходом для прогнозування динаміки фондових індексів. Успіх гібридного підходу ґрунтується на принципі розподілу завдань: статистична модель ефективно обробляє лінійні тренди, тоді як нейронна мережа спеціалізується на складних нелінійних паттернах. Уточнено ролі

статистичного та глибокого компонентів у гібридній архітектурі та показано, що декомпозиція сигналу сприяє зменшенню помилки прогнозування на середньостроковому горизонті. Подальші дослідження можуть бути спрямовані на інтеграцію більш складних архітектур глибокого навчання та включення до моделей альтернативних джерел даних, таких як макроекономічні індикатори чи новинні потоки.

Варто також детальніше зупинитися на аспектах підготовки даних та архітектурних особливостях побудованої нейромережевої моделі, які відіграли ключову роль в отриманні зазначених результатів. Оскільки фінансові часові ряди містять значну кількість ринкового шуму та мікроструктурних аномалій (наприклад, цінові шоки під час макроекономічних новин), етап попередньої обробки включав не лише стандартне диференціювання для досягнення стаціонарності, але й нормалізацію значень за методом Min-Max. Використання щоденних історичних даних обраних індексів за розширений період дозволило сформувати репрезентативну навчальну вибірку, достатню для виявлення глибоких закономірностей.

Щодо архітектури LSTM-компоненти, експериментальним шляхом було встановлено, що оптимальною є багатошарова структура з обов'язковим впровадженням шарів регуляризації Dropout (із коефіцієнтом вимкнення нейронів на рівні 0.2). Це дозволило ефективно нівелювати проблему перенавчання (overfitting), яка є критичною при моделюванні залишків ARIMA, що мають вигляд складного шуму з прихованими нелінійними залежностями. Додатково, для налаштування ваг нейронної мережі було використано алгоритм оптимізації Adam, який забезпечив швидку та стабільну збіжність функції втрат протягом усіх тренувальних епох. З метою уникнення виток майбутніх даних (data leakage) під час валідації застосовувався метод тестування «ковзним вікном» (walk-forward/sliding window).

Список використаних джерел:

1. Huang X. Stock price prediction based on ARIMA-GM hybrid and LSTM model. *Advances in Economics, Management and Political Sciences*. 2025. Vol. 205, no. 1. P. 22–35. URL: <https://doi.org/10.54254/2754-1169/2025.bj25376> (дата звернення: 01.03.2026).
2. Zhao Q., Hao Y., Li X. Stock price prediction based on hybrid CNN-LSTM model. *Applied and Computational Engineering*. 2024. Vol. 104, no. 1. P. 110–115. URL: <https://doi.org/10.54254/2755-2721/104/20241065> (дата звернення: 01.03.2026).
3. Chen Y. Stock market analysis and prediction using LSTM. *BCP Business & Management*. 2023. Vol. 36. P. 381–386. URL: <https://doi.org/10.54691/bcpbm.v36i.3489> (дата звернення: 01.03.2026).