

МЕТОДИКА ОЦІНКИ ЕФЕКТИВНОСТІ МОДЕЛЕЙ ПРОГНОЗУВАННЯ ПОВЕДІНКИ ФІНАНСОВИХ РИНКІВ

Прогнозування фінансових ринків має ключове значення через його вплив на управління ризиками та прийняття інвестиційних рішень. Точні прогнози можуть допомогти уникнути значних фінансових втрат та максимізувати прибутки. Традиційні методи прогнозування фінансових ринків включають моделі часових рядів, такі як авторегресивна інтегрована модель середнього, модель середнього та авторегресивна модель середнього, які базуються на статистичних принципах і використовують історичні дані для прогнозування майбутніх значень. Однак традиційні моделі мають свої обмеження, особливо у випадках високої волатильності або економічних криз, коли ринок піддається значним змінам. У роботі запропонована нова методика аналізу моделей, яка враховує ризики та адаптивність моделей прогнозування із використанням рекурентних нейронних мереж. Вона має можливість гнучкого налаштування завдяки використанню вагових коефіцієнтів у розрахунках, що дозволяє адаптуватися не лише до змін на ринку, а й до різних аналітичних інструментів. Архітектура розробленої системи передбачає модульний підхід, де кожен компонент методу реалізований як окремий модуль з чітко визначеними інтерфейсами взаємодії. Це дозволило протестувати методику на реальних історичних даних та підтвердити її ефективність у порівнянні з традиційними підходами.

Ключові слова: нейронні мережі, інформаційна модель, фінансова аналітика, ухвалення рішень.

Вступ

Проблема прогнозування поведінки фінансових ринків полягає у надзвичайній складності точного передбачення їхнього руху через вплив нескінченних економічних, політичних, психологічних та соціальних факторів. Існуючі методики оцінки ефективності моделей прогнозування добре підходять для одних фінансових даних, і в той же час видаються хибні показники на інших. Наприклад, згідно наукових досліджень, метод R^2 необхідно доповнювати іншими метриками оцінки для отримання більш цілісної картини, оскільки значна частина факторів може впливати на кінцевий результат [1]. З іншого боку, метод середньоквадратичної похибки прогнозу (MSE) є більш популярним рішенням для оцінки ефективності моделей, але дає якісні результати, якщо на періоді прогнозу не виникають принципово нові закономірності [2]. Це та нелінійність методу є причиною складної інтерпретації результатів дослідження [3]. Варто зазначити, що актуальним питанням залишається розробка методик, що враховують поведінку моделей в умовах різких змін на фінансових ринках та беруть до уваги складову ризику.

Аналіз проблеми та літературних досліджень

Дослідженню проблем прогнозування фінансових результатів присвячено багато наукових робіт, серед яких переважає загальний огляд методів прогнозування. Цими дослідженнями, зокрема займалися Малініна Т., Підгорна О., Виборнова К., Блоховцева Г., Єріна А., Азарова А., Рузакова О. та інші.

В цілому класичним методам аналізу і прогнозування курсу фінансових інструментів присвячено багато праць таких учених, як Алперт М., Андерсон А., Барбер Е., Талер Р., Берг Н., Бревер Е., Булір А., Камерер С. та інші.

Зважаючи на те, що більшість методів прогнозування можна використовувати для коротко- та середньострокових періодів прогнозування, тому для їх аналізу розглядалися три ключових питання [2]:

- опису статистичного ряду і визначення прогнозу за відомою похибкою за допомогою відомих методів;
- визначення впливу параметрів моделі на похибку прогнозу у випадку, якщо використаний метод прогнозування дає незначну похибку;
- опису реальних практичних результатів.

Часові ряди є одним із найстаріших методів прогнозування фінансових ринків. Вони базуються на аналізі історичних даних для виявлення тенденцій і циклів, що можуть

повторюватися в майбутньому. Моделі ковзного середнього Moving Average (MA) та їх різновиди Autoregressive Moving Average Models (ARMA), Autoregressive Integrated Moving Average (ARIMA) є основними інструментами цього підходу, оскільки історично показували найбільшу точність. Перевагою таких моделей є їх простота та наочність (рис. 1), проте вони можуть не враховувати раптові зміни ринкових умов та неефективно працювати під час високої волатильності.



Рис. 1. Визначення тренду руху ціни із використанням ковзних середніх (графік Bitcoin\USD взято з порталу TradingView)

Відомо, що моделі часових рядів, такі як ARIMA, мають гарну ефективність у прогнозуванні фінансових ринків, коли ринок має відносно стабільні тренди і не піддається різким змінам. За результатами одного дослідження виявилось, що ARIMA забезпечує середню абсолютну помилку на рівні 5% при прогнозуванні цін на акції на стабільних ринках. Це вказує на високу точність для короткострокових прогнозів, особливо якщо ринок має послідовний тренд [4]. При високій волатильності ринкових умов моделі часових рядів демонструють зниження точності. Під час прогнозування фондових індексів у період пандемії COVID-19, модель ARIMA мала помилку на рівні 18%, що було значно вищим, ніж при застосуванні моделей глибокого навчання (таких як RNN, які показали помилку на рівні 10%). Моделі MA та ARMA використовуються для вирівнювання коливань і виявлення трендів. Модель ковзного середнього (MA) показала точність на рівні 7-8% помилки при прогнозуванні короткострокових тенденцій цін на валютних ринках. ARMA також використовувалася для прогнозування змін валютних курсів, де показала середню відносну помилку (MAPE) на рівні 6% під час стабільних періодів.

Нейронні мережі значно розширили можливості фінансового прогнозування. Ці моделі імітують роботу людського мозку, здатні навчатися та розпізнавати складні патерни в даних. Рекурентні нейронні мережі (RNN) та їхні покращені варіанти мають кілька модифікацій, які спрямовані на вирішення проблеми аналізу минулих подій. Ці модифікації покращують точність у прогнозуванні, забезпечують адекватність рішень та підвищують можливості їх аналізу та інтерпретації [5].

Останні дослідження у сфері прогнозування поведінки фінансових ринків демонструють значний прогрес у використанні сучасних методів машинного навчання та штучного

інтелекту. Зокрема, дослідження вказують на високий потенціал нейронних мереж та алгоритмів глибокого навчання у виявленні складних закономірностей у фінансових даних, що є ключовим для створення точних прогнозів [6-8]. Значний внесок у розвиток цієї сфери зробили дослідження, що акцентують увагу на використанні Big Data. Зокрема, великі обсяги даних, які збираються в режимі реального часу, дозволяють створювати більш точні та оперативні прогнози. Використання штучного інтелекту для аналізу таких даних відкриває нові перспективи у фінансовому прогнозуванні. Алгоритми машинного навчання можуть бути застосовані для прогнозування цін на акції та інші фінансові інструменти з високою точністю [9]. Використання комбінованих моделей, які включають як традиційні, так і сучасні методи, може забезпечити додаткову надійність та точність прогнозів. Поєднання глибоких нейронних мереж дозволяє досягти кращих результатів у прогнозуванні поведінки ринку. Також проводяться дослідження методів застосування моделей машинного навчання для створення стратегій управління портфелем, які дозволяють мінімізувати ризики та максимізувати прибутки навіть у нестабільних ринкових умовах [10].

Таким чином часові ряди мають ряд переваг, таких як простота реалізації, швидкість розрахунків та зручність у застосуванні для короткострокових прогнозів, але мають і ряд недоліків, серед яких: неможливість адаптації до різкої динаміки ринку, обмеження у виявленні складних патернів, необхідність постійного оновлення даних. З іншого боку рекурентні нейронні мережі дозволяють враховувати часові залежності, можуть застосовуватися для нелінійних залежностей та мають механізми контролю пам'яті для збереження важливої інформації протягом тривалого часу, хоча і мають проблеми із зниканням градієнта під час навчання, що може призвести до втрати інформації про важливі попередні події, мають високу обчислювальну складність, що вимагає потужних ресурсів і значного часу для навчання, та потребують великого обсягу навчальних даних.

В якості експерименту командою вчених Fischer and Krauss [11] було обрано модель LSTM для прогнозування фінансових ринків на прикладі індексу S&P 500. Було виявлено, що модель LSTM досягла точності у 57% у прогнозуванні напрямку цін акцій, тоді як ARIMA досягла точності лише 52%, що близько до випадкової. Це та дослідження [12] свідчать про переваги LSTM у здатності виявляти складні взаємозв'язки в даних, які важко опрацювати звичайними методами. В іншому дослідженні використовувалися RNN для прогнозування цін на криптовалюту (Bitcoin). Було виявлено, що стандартна рекурентна нейронна мережа мала середню відносну помилку 9.2%, що значно краще, ніж результати, отримані традиційними моделями в 15%. Це підкреслює здатність RNN обробляти складні нелінійні дані у високоволатильних умовах [13].

Комбіновані моделі об'єднують переваги традиційних та сучасних методів для підвищення точності прогнозування. Наприклад, поєднання регресійних моделей з нейронними мережами дозволяє враховувати більший діапазон залежності у даних. Такий підхід дозволяє досягти більшої надійності та точності прогнозів. Комбіновані моделі часто працюють краще інших методів, особливо в умовах високої ринкової невизначеності та підвищеної волатильності [14].

Варто зазначити, що для виявлення саме ефективних інструментів аналізу ринку, виключаючи з розгляду інсайдерську інформацію, маніпулювання фінансовим ринком, актуальним питанням є вибір та дослідження методики оцінки ефективності цих моделей прогнозування.

Мета і задача дослідження

Метою цього дослідження є аналіз різних моделей прогнозування поведінки фінансових ринків та створення нової методики оцінки їхньої ефективності у різних ринкових умовах. Дослідження покликане виявити найбільш надійні та точні способи аналізу інструментів прогнозування, які можуть бути застосовані для прийняття стратегічних інвестиційних рішень та управління ризиками, і розробити інструмент з урахування недоліків вже існуючих методик

для надання інвесторам та аналітикам необхідних даних щодо моделей для їхнього ефективного використання.

Опис існуючих інструментів

Розглянемо найпопулярніші методики оцінки роботи моделей прогнозування фінансових ринків.

Метод R^2 визначає частку варіації залежної змінної, яку можна пояснити незалежними змінними моделі [11]. Він вимірює, наскільки добре модель відповідає фактичним даним:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2},$$

де y_i — фактичні значення,

\hat{y}_i — прогнозовані значення,

\bar{y} — середнє значення фактичних даних.

Помилка прогнозування включає показники середньої абсолютної помилки (MAE) та середньоквадратичної помилки (MSE). Вони показують середню різницю між прогнозованими значеннями та фактичними [12]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|,$$

$$MSE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2.$$

Для оцінки ефективності моделей класифікації використовуються значення істинних позитивних прогнозів TP , хибних позитивних прогнозів FP та хибних негативних прогнозів FN , що дозволяють розрахувати показники:

Precision — частка правильних позитивних прогнозів серед усіх позитивних прогнозів:

$$Precision = \frac{TP}{TP + FP};$$

Recall — частка правильних позитивних прогнозів серед усіх фактичних позитивних значень:

$$Recall = \frac{TP}{TP + FN};$$

F1-score — середнє між Precision та Recall, що забезпечує збалансовану оцінку:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Методика AMES

Розглянемо нову методику Adaptive Market Efficiency Score (AMES), що поєднує традиційні метрики прогнозування з адаптивною оцінкою ринкової ефективності, використовуючи концепцію адаптивної ринкової гіпотези (Adaptive Market Hypothesis, АМН). Він враховує як ефективність прогнозу, так і здатність моделі адаптуватися до змін у ринковій структурі, тому складається з наступних компонент:

- прогнозування (PC), що оцінює точність моделі через метрики прогнозування, такі як середня абсолютна помилка (MAE) або корінь середньоквадратичної помилки (RMSE), де $RMSE = \sqrt{MSE}$. Компонента PC дозволяє визначити, наскільки добре модель передбачає зміни на ринку;

- *адаптивності* (AC), що визначає здатність моделі адаптуватися до змін у ринковій структурі, таких як зміна волатильності або циклічність, де **чутливість до змін** оцінюється через статистику зміни помилки:

$$\Delta RMSE = RMSE_t - RMSE_{t-1},$$

де $RMSE_t$ — помилка в поточному періоді,

$RMSE_{t-1}$ — помилка в попередньому періоді.

Значення компоненти адаптивності розраховується за формулою:

$$AC = 1 - \frac{\Delta RMSE}{N},$$

де N – значення $\Delta RMSE$ в еталонному періоді.

- *ризик* (RC), що включає оцінку ризику через метрику **Value at Risk** (VaR) і показує максимальні потенційні збитки. Це дозволяє враховувати ризикованість прогнозів, зроблених моделлю, і визначати можливі втрати. При розрахунку компоненти враховуються збитки для певного рівня довіри та максимально можливих збитків:

$$RC = 1 - \frac{R_\alpha}{R_{max}},$$

де R_α – максимальні збитки для заданого рівня довіри α ,

R_{max} – максимальні можливі збитки.

Після отримання значень компонент прогнозування, адаптивності та ризику, формула для обчислення значення AMES із урахуванням вагових коефіцієнтів виглядає наступним чином:

$$AMES = w_1 PC + w_2 AC - w_3 RC,$$

де w_1, w_2, w_3 — вагові коефіцієнти, що відповідають важливості кожної з компонент і можуть бути налаштовані залежно від конкретних умов.

Робота методу AMES (рисунок 1) розпочинається із процесу отримання вхідних ринкових даних того інструменту, який буде проаналізовано, які є основою для подальшого розгляду та розрахунків. Після збору початкових даних відбувається розрахунок трьох ключових компонент AMES. Після отримання результатів від усіх трьох компонент відбувається їх «зважування» за допомогою вагових коефіцієнтів. На цьому етапі визначається відносна важливість кожної компоненти та їх внесок у фінальний результат. Процес зважування може враховувати специфіку ринку, мету аналізу, та інші спеціалізовані параметри, що мають вплив на прогнозування. Завершальним етапом є безпосередньо розрахунок значення AMES, де всі зважені компоненти об'єднуються в єдиний показник. Цей фінальний показник надає комплексну оцінку, яка враховує всі фактори аналізу: якість прогнозування, здатність до адаптації та рівень ризику. Такий багатовимірний підхід забезпечує більш надійну та збалансовану оцінку порівняно з використанням окремих метрик.

Розрахована оцінка за методикою AMES набуває значень з відрізка $[0; 1]$, причому значення $[0,9; 1]$ – це максимальний рівень, що характеризується виключною ефективністю і надійністю інструменту завдяки низьким показникам ризиків, високою точністю прогнозів і адаптивністю до ринкових змін.

Архітектура розробленої системи передбачає модульний підхід, де кожен компонент методу AMES (точність прогнозування, адаптивність, управління ризиками) реалізований як окремий модуль з чітко визначеними інтерфейсами взаємодії. Зв'язок і структуру класів можна побачити на діаграмі класів (рис. 3).

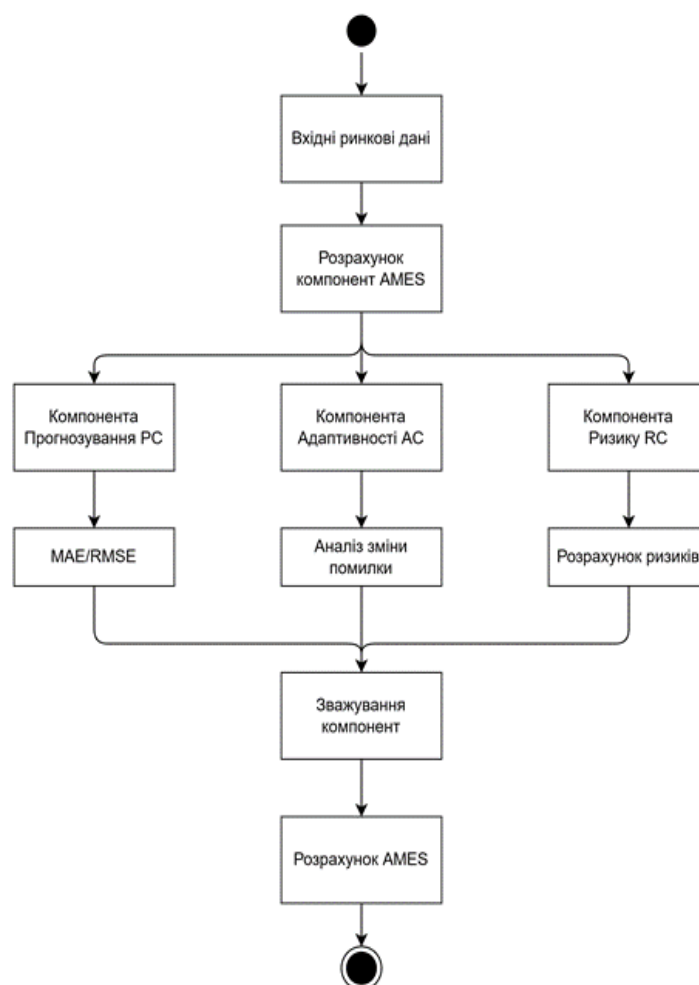


Рис. 2 Схема роботи методу AMES

В інтеграційному рівні системи відбувається взаємодія з різними джерелами даних, зокрема з швидкісною базою даних ClickHouse, що використовується для зберігання історичних даних. Доступ до даних реалізовано із використанням асинхронних операцій та кешування Redis. Це дозволяє скоротити затримки при роботі з великими наборами історичних даних та забезпечити швидку обробку поточних даних в реальному часі. Інтерфейс для взаємодії з фронтенд-частиною системи реалізовано через REST API. Розроблений прошарок Middleware включає в себе механізми валідації вхідних даних та обробки помилок.

Можливості ClickHouse в контексті методики AMES надають перевагу у швидкості виконання деяких статистичних розрахунків на рівні бази даних. Це забезпечує швидке виконання запитів для великих обсягів даних та ефективне обчислення деяких допоміжних даних та агрегованих результатів. Завдяки здатності ClickHouse до інтеграції через використання Entity Framework, взаємодія з базою даних є дуже простою та зрозумілою, що дозволяє легко створити необхідні таблиці та побудувати зв'язки між таблицями (рис. 4).

Тестування методики AMES

Для тестування нової методики необхідно отримати якісні історичні дані. В якості джерела такої інформації використано криптовалютну біржу Binance. Процес отримання даних від біржі залежить від налаштування доступу до API Binance та управління лімітами API Binance. Біржа встановлює обмеження на кількість запитів за одиницю часу та максимальну кількість свічок, яку можна отримати за один запит. Для ефективного

використання доступних ресурсів реалізовано механізм контролю швидкості запитів та чергу запитів з пріоритетами.

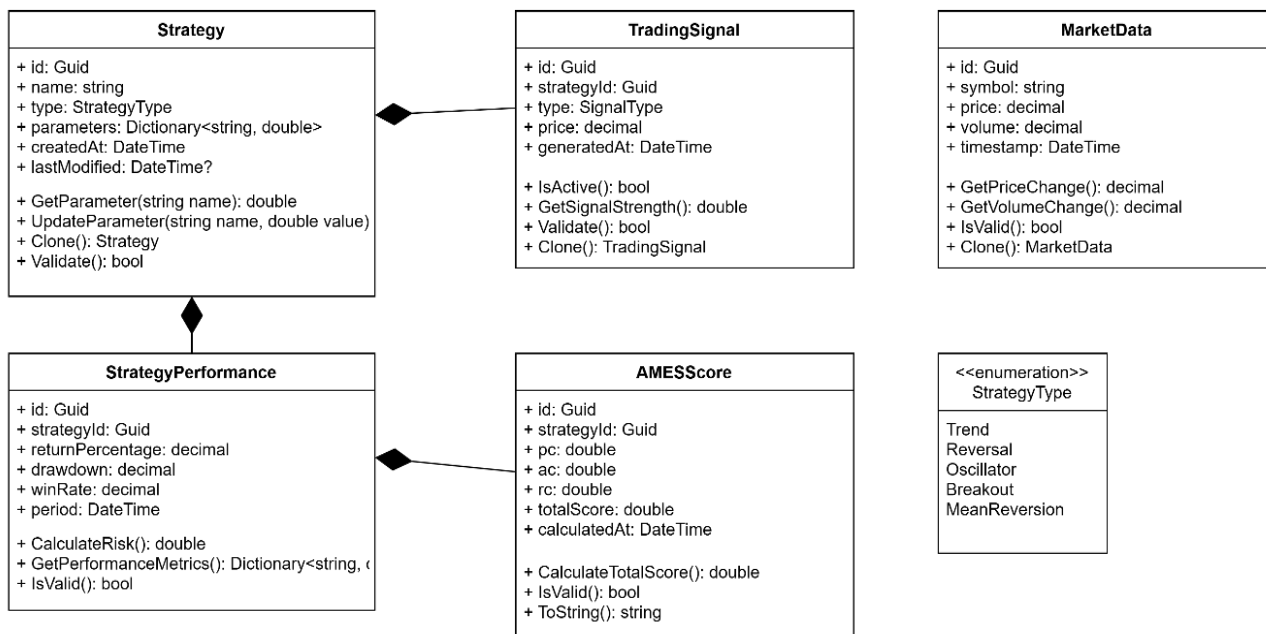


Рис. 3 Діаграма класів UML

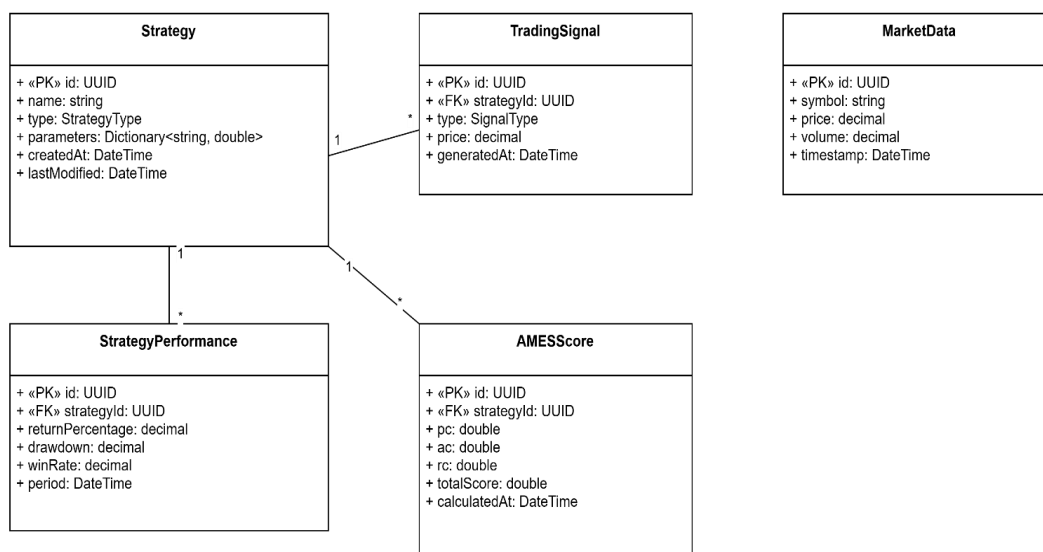


Рис. 4. Схема бази даних застосунку

Тестування проводиться на різних класах активів (криптовалюти, акції) з різними характеристиками волатильності та ринкової динаміки. Особлива увага приділяється порівнянню результатів оцінки за методом AMES з традиційними метриками ефективності.

Для оцінки ефективності різних моделей прогнозування за допомогою вищенаведених методик і валідації нового методу AMES було проведено аналіз на реальних даних для BTC/USD та AAPL за період з 1 січня 2023 по 1 грудня 2024 року (рисунки 4-5). Пара BTC/USD відзначилася високою волатильністю, що було виражено в зміні ціни з \$16,537 до

\$42,894 (+159%). В свою чергу AAPL був помірно вола тильним, оскільки ціна змінилася з \$129.62 до \$193.18 (+49%).

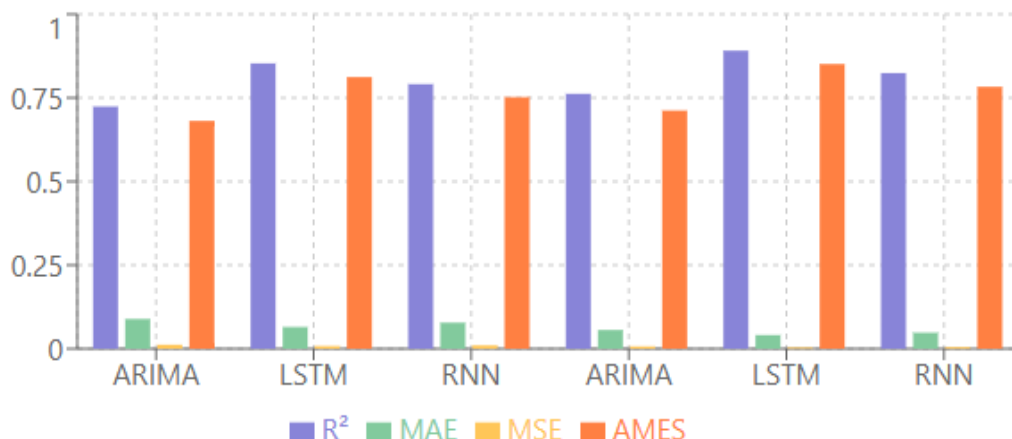


Рис. 5. Порівняння методик оцінки моделей прогнозування

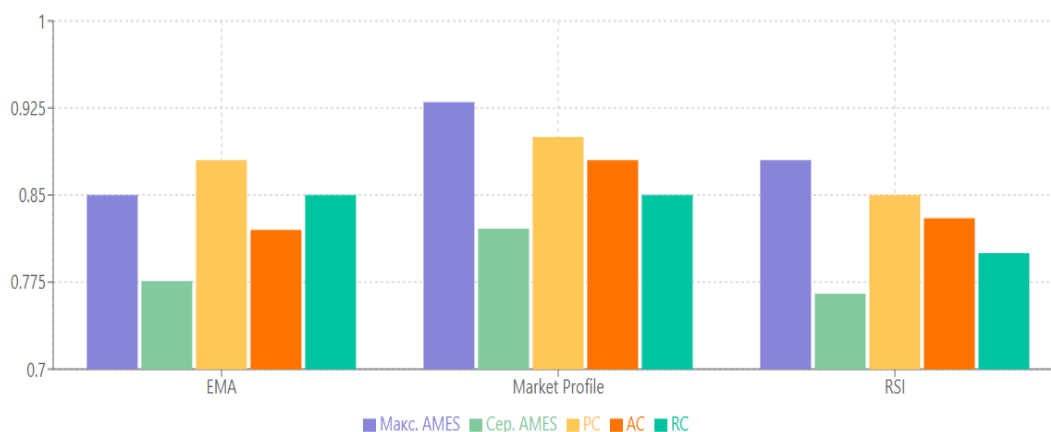


Рис. 6. Порівняння результатів AMES і компонент для різних інструментів прогнозування

Результати тестування різних моделей прогнозування для двох активів (табл. 1) — BTC (Bitcoin) та AAPL (Apple Inc.) дають змогу провести порівняльний аналіз між трьома методами прогнозування: ARIMA та моделями штучного інтелекту LSTM та RNN з оцінкою їхньої ефективності за допомогою метрик R², MAE, MSE та новою методикою AMES.

Таблиця 1.

Результати тестування моделей прогнозування різними методиками

Модель	Актив	R²	MAE	MSE	AMES
ARIMA	BTC	0.724	0.089	0.012	0.681
LSTM	BTC	0.853	0.065	0.008	0.812
RNN	BTC	0.791	0.078	0.010	0.752
ARIMA	AAPL	0.762	0.056	0.007	0.712
LSTM	AAPL	0.891	0.041	0.004	0.851
RNN	AAPL	0.824	0.048	0.005	0.783

При детальному розгляді результатів можна спостерігати, що для обох активів метод LSTM демонструє найвищі показники ефективності. Зокрема, для BTC модель LSTM досягла R² = 0.853, що свідчить про кращу прогнозу здатність моделі порівняно з ARIMA (R² = 0.724).

та RNN ($R^2 = 0.791$). Аналогічна тенденція спостерігається і для AAPL, де LSTM показує $R^2 = 0.891$. Для BTC значення AMES при використанні LSTM становить 0.812, що помітно перевищує результати ARIMA (0.681) та RNN (0.752). Подібна картина спостерігається і для AAPL, де LSTM досягає $AMES = 0.851$, що є найвищим показником серед усіх методів.

Метод дозволяє інтегрувати різні аспекти прогнозування через свої компоненти (PC, AC, RC), що робить можливим додавання нових компонент, які будуть враховувати інші необхідні для аналізу фактори. Адаптивність методу до ринкових змін робить його значно ефективнішим для аналізу високоволатильних активів, таких як криптовалюти, а врахування компоненти ризику в загальній оцінці дозволяє приймати більш зважені інвестиційні рішення. У подальшому метод AMES може бути розширений для аналізу більш складних фінансових інструментів та ринкових ситуацій, а також інтегрований у системи торгівлі.

Порівняльна характеристика методик

Для обґрунтованого вибору методики оцінки ефективності моделей важливо розуміти їх сильні та слабкі сторони, що проаналізовані та представлені в таблиці 2.

Таблиця 2

Порівняльна характеристика оцінки ефективності моделей прогнозування

Методика	Переваги	Недоліки
R²	1. Зрозуміла інтерпретація. 2. Висока ефективність при оцінюванні моделей з лінійними залежностями	1. Чутливість до додаткових змінних 2. Хибні показники при нелінійних зв'язках
MAE	1. Зрозуміла інтерпретація 2. Відсутність впливу великих відхилень	1. Неможливість визначати значні відхилення 2. Відсутність врахування напряму помилки
MSE	1. Врахування великих відхилень і виявлення аномалій 2. Зручність обчислення	1. Можливість переоцінки впливу аномальних значень 2. Надмірна чутливість, що погіршує загальну оцінку моделі
Precision	Ефективність при зменшенні кількості хибних позитивних результатів	Ігнорування хибних негативних результатів
Recall	1. Добре підходить для ситуацій, коли важливо знайти всі позитивні приклади 2. Зменшення ризиків втрати важливих випадків	1. Можлива висока кількість хибних позитивних результатів 2. Зниження якості оцінки через хибні результати
F1-score	Отримання загальної ефективності моделі при врахуванні і точності, і повноти	1. Можлива складність в інтерпретації. 2. Залежність від метрик (Precision і Recall), що впливає на якість всього показника
AMES	1. Врахування адаптивності моделі до динамічних змін на ринку 2. Комплексна оцінка, що включає як точність прогнозу, так і оцінку ризику	1. Складність розрахунку та налаштування ваг для кожної компоненти 2. Високі вимоги до якості даних, особливо для оцінки адаптивності та ризику.

Запропонована методика AMES має суттєві переваги порівняно з існуючими методами завдяки врахуванню адаптивності та оцінки ризику, що є особливо важливо при аналізі волатильних фінансових ринків (таблиця 3). Оскільки метод R^2 не підходить для ринків, де велика динаміка змін, хоча й добре себе рекомендує на відносно стабільних інструментах, а F1-score вимагає велику кількість даних для визначення показника ефективності моделі, хоча не залежить від ринкової динаміки.

Таблиця 3

Порівняння методики AMES з існуючими аналогами

Методики оцінки	Показник				
	Врахування адаптивності	Складність	Точність	Потреба в якості даних	Оцінка ризику
AMES	Так	Висока	Збалансована між прогнозуванням та адаптацією	Висока	Так
Існуючі методики	Відсутня	Середня	Оцінка лише точності	Помірна	Відсутня

Методика AMES показує найбільшу ефективність про наданні оцінки моделей прогнозування фінансових ринків у наступних умовах:

- 1) динамічності та мінливості (таких як зміни тренду, структури або волатильності), що завдяки компоненті адаптивності дозволяє моделі ефективно реагувати на ці зміни;
- 2) врахування ризику та необхідності управління ними;
- 3) необхідності врахування не лише точності прогнозів, але й здатності моделі адаптуватися до змін і контролювати ризику.

Висновки

Прогнозування фінансових ринків має ключове значення через його вплив на управління ризиками та прийняття інвестиційних рішень. Точні прогнози можуть допомогти уникнути значних фінансових втрат та максимізувати прибутки. У роботі представлено нову методику AMES, що дозволяє визначити ефективність моделі прогнозування на основі багатьох факторів, враховуючи ризики та зміну ситуації на ринку, що дозволить побачити, який інструмент є найефективнішим для прийняття фінансових рішень при роботі із тим чи іншим активом.

Розроблена методика AMES, на відміну від своїх аналогів, враховує рівень адаптивності та ризику моделі, що аналізується і має можливість гнучкого налаштування через використання вагів компонент розрахунку для адаптації не лише під зміну ринкових умов, але й під різні інструменти аналізу. Врахування здатності адаптації до різкої зміни ринкових умов і ризикованості використання моделі прогнозування дозволили виявити найбільш ефективний інструмент, Market Profile, для роботи на фінансових ринках, який випереджає аналоги в середньому на 10%.

Перелік посилань

1. Rocca R. Interpreting R²: a Narrative Guide for the Perplexed [Електронний ресурс]. Towards Data Science. – 2024. – Режим доступу до ресурсу: <https://towardsdatascience.com/interpreting-r%C2%B2-a-narrative-guide-for-the-perplexed-086a9a69c1ec>.
2. Демчик Я.М., Розен В.П. Оцінки похибки прогнозних моделей та прогнозів спожитої електричної енергії на об'єктах енергетичного ринку. Енергетика: економіка, технології, екологія. 2019. № 4. — С. 69-78.
3. Kozurkov C. Why is Mean Squared Error (MSE) So Popular? [Електронний ресурс]. Towards Data Science. – 2022. – Режим доступу до ресурсу: <https://towardsdatascience.com/why-is-mean-squared-error-mse-so-popular-4320d5f003e5>.
4. Robert H. Shumway, Devid S. Stoffer. Time Series Analysis and Its Applications: With R Examples. Springer. Springer Texts in Statistics. 2017. 562 p.
5. Бідюк П. І., Гуць С. В., Гавриленко В. В., Рудоман Н. В. Прогнозування цін акцій з використанням рекурентної нейронної мережі LSTM. Системи управління, навігації та зв'язку, 2021, 3(65). С. 64-68. <https://doi.org/10.26906/SUNZ.2021.3.064>
6. Замрій І.В., Федоренко М. Л. Аналіз використання алгоритмів штучного інтелекту для глибокого аналізу фінансових даних. Сучасний захист інформації, 3(59), 2024. С. 55–62. <https://doi.org/10.31673/2409-7292.2024.030005>
7. Xinhui Li. Application of Neural Networks in Financial Time Series Forecasting Models. Journal of Function Spaces 2022(3):1-9. <https://doi.org/10.1155/2022/7817264>

8. Kady Sako, Berthine Nyunga Mpinda, Paulo Canas Rodrigues. Neural Networks for Financial Time Series Forecasting. *Entropy* 2022, 24(5), 657; <https://doi.org/10.3390/e24050657>
9. Пархоменко Б. М., Акименко А. М. Використання інформаційних моделей для прогнозування поведінки фінансових показників. *Технічні науки та технології*. 2024. № 2(36). С. 173-180. [https://doi.org/10.25140/2411-5363-2024-2\(36\)-173-180](https://doi.org/10.25140/2411-5363-2024-2(36)-173-180)
10. Олександра Манзій О., Сенік Ю., Пелех В., Сенік А., Андрейчук С. Використання нейронних мереж для задач інвестиційного аналізу. *Галицький економічний вісник*, № 2 (87) 2024. С. 164-174.
11. Christopher Krauss, Xuan Anh Do, Nicolas Huck. Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *European Journal of Operational Research*. Volume 259, Issue 2, 2017, pp. 689-702. <https://doi.org/10.1016/j.ejor.2016.10.031>
12. David M. Q. Nelson; Adriano C. M. Pereira; Renato A. de Oliveira. Stock market's price movement prediction with LSTM neural networks. 2017 International Joint Conference on Neural Networks (IJCNN). Anchorage, AK, USA, 2017, pp. 1419-1426, <https://doi.org/10.1109/IJCNN.2017.7966019>.
13. Fischer T. Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*. Volume 270, Issue 2, 16 October 2018, pp. 654-669. <https://doi.org/10.1016/j.ejor.2017.11.054>
14. Kelum Gajamannage, Yonggi Park, Dilhani I. Jayathilake. Real-time forecasting of time series in financial markets using sequentially trained dual-LSTMs. *Expert Systems with Applications*. 2023, Volume 223, 119879, <https://doi.org/10.1016/j.eswa.2023.119879>.

Надійшла 06.02.2025