

РОЗРОБКА ТА ДОСЛІДЖЕННЯ ПРОГНОЗНИХ МОДЕЛЕЙ У СИСТЕМАХ АЛГОРИТМІЧНОЇ ТОРГІВЛІ

Ярінко Б.Б.

Національний технічний університет України
«Київський політехнічний інститут ім. Ігоря Сікорського», Київ, Україна

yarinko.b@gmail.com

У роботі запропоновано підхід до аналізу та вдосконалення прогнозних моделей у алгоритмічній торгівлі. Використано методи машинного навчання та розроблено інструментарій автоматизованої діагностики. Отримані результати демонструють підвищення точності моделей і підтверджують практичну ефективність систематизованого аналізу.

Ключові слова: алгоритмічна торгівля, прогнозні моделі, машинне навчання, діагностика моделей, фінансові ринки.

1. ВСТУП

Застосування методів машинного навчання в системах алгоритмічної торгівлі є однією з найактуальніших та водночас найскладніших задач сучасної фінансової інженерії. На відміну від класичних областей, де дані є відносно стабільними, фінансові ринки характеризуються унікальними властивостями: низьким співвідношенням сигнал/шум, нестационарністю та гетероскедастичністю. Як зазначається у сучасних дослідженнях [1, 2], ці характеристики суттєво ускладнюють виявлення стійких закономірностей. Унаслідок цього стандартні підходи до побудови прогнозних моделей, навіть із використанням потужних алгоритмів, таких як градієнтний бустинг чи рекурентні нейронні мережі, часто демонструють низьку та нестабільну ефективність.

Основною проблемою, з якою стикаються дослідники та практики, є значна складність та трудомісткість процесу діагностики та вдосконалення розроблених моделей. Аналіз причин низької продуктивності зазвичай потребує глибоких експертних знань і ручного, інтуїтивного пошуку помилок, що є неефективним, погано масштабованим і схильним до упередженості. Існуючі інструментальні засоби та MLOps-платформи, такі як MLflow або QuantConnect, ефективно автоматизують процеси навчання, версіонування та розгортання моделей, однак вони не надають засобів для глибокої, автоматизованої діагностики їхніх внутрішніх недоліків. Виникає потреба у створенні спеціалізованого інструменту, який би міг виконувати роль «інтелектуального асистента» для дослідника, автоматизуючи процес аудиту моделей.

Це зумовлює необхідність розробки систематизованого підходу до діагностики прогнозних моделей, що ґрунтується на формалізації експертних знань у вигляді структурованої методології. Метою даної роботи є дослідження прогнозних моделей через призму такого підходу: спочатку емпірично виявити типові патерни помилок, а потім розробити та апробувати програмний інструментарій, що автоматизує їх виявлення та пропонує шляхи вдосконалення. У статті представлено результати експериментального дослідження набору прогнозних моделей та продемонстровано ефективність запропонованої методології на практичному прикладі їх ітеративного покращення.

2. ПОСТАНОВКА ЗАДАЧІ ДОСЛІДЖЕННЯ

Загальною задачею даної роботи є дослідження ефективності та виявлення систематичних недоліків у роботі поширених прогнозних моделей при їх застосуванні до фінансових часових рядів, а також розробка та апробація систематизованого підходу для їх цілеспрямованого вдосконалення.

Для досягнення поставленої мети необхідно виконати такі конкретні завдання:

1. Провести експериментальне дослідження набору базових прогнозних моделей, що належать до різних класів (лінійні, ансамблеві на основі дерев, рекурентні нейронні мережі).
2. На основі результатів експериментального аналізу, систематизувати виявлені недоліки у вигляді формалізованих «патернів проблем» та розробити концепцію Базу Знань, що структурує методи їх діагностики й усунення.
3. Спроекувати та реалізувати програмний інструментарій, який автоматизує процес діагностики моделей на основі розробленої Базу Знань
4. Продемонструвати практичну роботу розробленого інструментарію, застосувавши його для автоматизованого аналізу набору базових моделей та формування комплексного плану їх вдосконалення на основі згенерованих рекомендацій.
5. Провести фінальну верифікацію запропонованого підходу, порівнявши продуктивність базових та вдосконалених за допомогою інструментарію моделей на відкладеній тестовій вибірці для оцінки його практичної ефективності.

3. ОСНОВНІ МЕТОДИ

З метою проведення всебічного порівняльного дослідження було обрано чотири алгоритми, що представляють різні парадигми машинного навчання: Логістична регресія як базовий лінійний метод; Випадковий ліс як представник ансамблевих методів; Екстремальний градієнтний бустинг як високоефективна реалізація градієнтного бустингу; та LSTM як модель рекурентної нейронної мережі. Вибір цієї архітектури зумовлений її здатністю ефективно враховувати часові залежності, що, за даними літератури [3], часто забезпечує їй перевагу над традиційними алгоритмами у задачах фінансового прогнозування.

Ключовим елементом дослідження є застосування розробленої методології систематизованого аналізу, яка була реалізована у вигляді спеціалізованого програмного модуля. Ця методологія базується на використанні Базу Знань, що реалізована у вигляді документо-орієнтованої структури. База Знань містить формалізований опис типових проблем прогнозних моделей, систематизованих за класами, що стосуються даних, архітектури моделі та її оцінки. Кожне правило в базі має уніфіковану структуру, що включає об'єкт-детектор, який описує логіку виявлення проблеми, та об'єкт-коректор, що містить пріоритезовані рекомендації щодо її вирішення. Процес аналізу моделей забезпечується аналітичним ядром, яке послідовно викликає програмні реалізації детекторів для перевірки наявності «симптомів» кожної проблеми та генерує фінальний діагностичний звіт.

Методологія експерименту розроблена таким чином, щоб забезпечити об'єктивність та відтворюваність результатів. Дослідження проводилося на історичних денних даних ETH/USD. Весь набір даних було хронологічно розділено на тренувальну, валідаційну та тестову вибірки у співвідношенні 70%, 15% та 15% відповідно. Валідаційна вибірка використовувалася для проміжної оцінки моделей та їх діагностики, тоді як тестова вибірка залишалася недоторканою до фінального етапу. Для оцінки якості було обрано метрику F1-Score. Її використання є рекомендованим для задач із дисбалансом класів, оскільки, на відміну від Accuracy, вона забезпечує об'єктивнішу оцінку балансу між точністю та повнотою [5].

4. РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

В рамках експериментального дослідження було проведено навчання та оцінку чотирьох базових моделей, здійснено їх діагностику за допомогою розробленого програмного інструментарію та проведено фінальну верифікацію покращених версій моделей.

На першому етапі було проведено аналіз продуктивності базових моделей на відкладеній тестовій вибірці. Результати, представлені в табл. 1, демонструють значну диференціацію в ефективності між різними класами алгоритмів. Моделі, що працюють з даними як з таблицею (Logistic Regression, Random Forest, XGBoost), показали точність, близьку до 50-52%, причому XGBoost продемонстрував найкращий F1-Score (0.479) серед цієї групи. Разом з тим, модель LSTM показала найвищу продуктивність за ключовою метрикою F1-Score (0.574). Отриманий результат узгоджується із загальною тенденцією, описаною в літературі [3], щодо вищої ефективності рекурентних архітектур при роботі зі складними послідовними даними. Це свідчить про її вищу здатність ідентифікувати позитивний клас (торговий сигнал), хоча й за рахунок більшої загальної кількості помилок. Тим не менш, той факт, що жодна з моделей не досягла стабільно високих показників, підтверджує вихідну гіпотезу про обмежену ефективність стандартного підходу до моделювання та необхідність глибокого аналізу помилок

Таблиця 1. Продуктивність базових моделей на тестовій вибірці

Модель	Accuracy	F1-Score
Logistic Regression	0.507	0.412
Random Forest	0.523	0.454
XGBoost	0.505	0.479
LSTM	0.483	0.574

Для глибокого та систематизованого аналізу причин низької продуктивності було застосовано розроблений в рамках даної роботи програмний інструментарій для автоматизованої діагностики моделей.

Розроблений програмний інструментарій є модульною аналітичною платформою, призначеною для автоматизації процесу діагностики та підтримки вдосконалення прогнозних моделей. Концептуальна архітектура системи, представлена на рис. 1, ілюструє взаємодію її ключових компонентів.

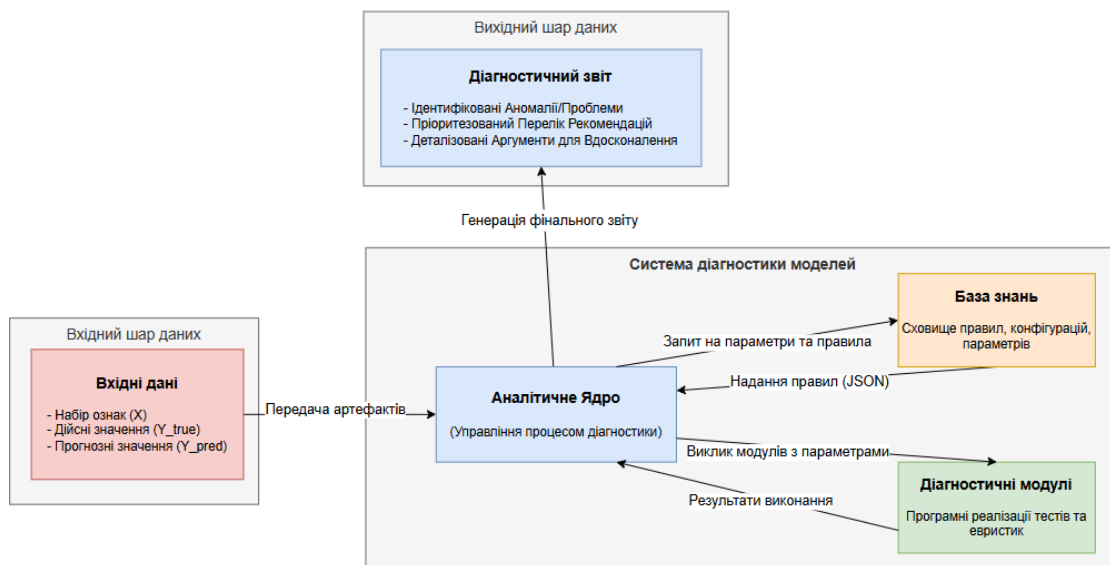


Рисунок 1. Концептуальна архітектура системи діагностики моделей

В основі архітектури лежать три основні компоненти:

1. Аналітичне ядро: Центральний компонент, що керує процесом аналізу. Він приймає на вхід артефакти роботи моделі (вхідні дані, прогнози, метрики), послідовно звертається до бази знань для отримання правил діагностики та викликає відповідні програмні модулі (детектори) для їх перевірки.

2. База знань: Серце системи, що реалізоване у вигляді гнучкої документо-орієнтованої структури. Вона містить формалізований опис типових проблем, з якими стикаються моделі в алгоритмічній торгівлі, та є легко розширюваною.

3. Модулі детекторів та коректорів: Це програмна реалізація логіки, закладеної в базі знань. Детектори є набором функцій, кожна з яких виконує специфічний тест для виявлення «симптомів» певної проблеми. Коректори містять логіку для генерації рекомендацій щодо вирішення виявлених проблем.

Така модульна архітектура дозволяє легко додавати нові правила діагностики, не змінюючи основну логіку системи, що забезпечує її гнучкість та масштабованість.

На другому етапі було проведено автоматизовану діагностику кожної з чотирьох моделей за допомогою цього інструментарію. Для візуалізації та підтвердження закономірностей, виявлених програмним інструментарієм, було проведено сегментований аналіз продуктивності моделей, результати якого представлено на рис. 2.

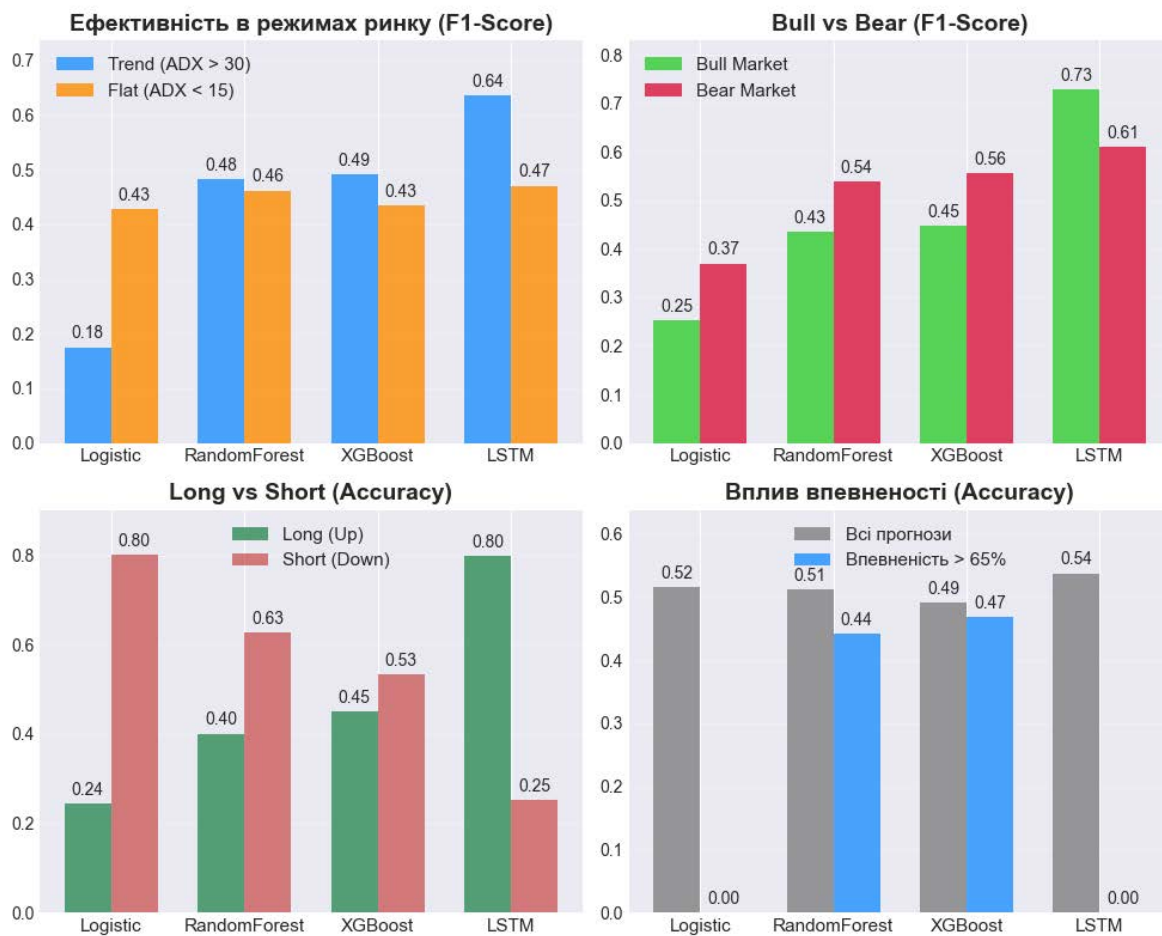


Рисунок 2. Аналіз продуктивності моделей у різних ринкових режимах та умовах

Аналіз звітів системи та візуалізацій на рисунку дозволив виявити кілька ключових, спільних для більшості моделей, патернів неефективності. По-перше, спостерігається чітка залежність від динаміки ринку, де лінійна модель краще працює у боковому русі з показником F1-Score 0.43 проти 0.18 у тренді, тоді як LSTM досягає найвищої ефективності 0.64 саме на трендових ділянках. По-друге, зафіксовано асиметрію щодо фаз ринку, де нейромережа єдина демонструє домінування на ринку, що зростає, зі значенням метрики 0.73. По-третє, аналіз напряму угод виявив полярну спеціалізацію, при якій класичні моделі прогнозують сигнали на продаж з точністю до 0.80, а LSTM показує аналогічну високу точність 0.80 виключно у сигналах на купівлю. По-четверте, фільтрація прогнозів за високим рівнем впевненості виявилася неефективною, призвівши до зниження точності випадкового лісу з 0.51 до 0.44 та виявивши повну відсутність впевнених сигналів у інших алгоритмів. Окрім цього, автоматизований аналіз виявив низку інших спільних недоліків: надлишковість ознак, перенавчання для ансамблевих моделей, автокореляцію помилок та високі методологічні ризики. Ці спостереження доводять, що поверхневий аналіз метрик є недостатнім. Відсутність стандартизованих протоколів оцінювання, на яку вказують дослідники [3], вимагає застосування глибокої діагностики для виявлення справжніх причин неефективності моделей.

На основі узагальненого аналізу діагностичних звітів було сформульовано єдиний, комплексний план вдосконалення, спрямований на вирішення найбільш критичних та поширених проблем. Цей план включав три основні напрямки: інжиніринг ознак (створення комбінованих індикаторів для зменшення мультиколінеарності та додавання ознаки

ринкового режиму на основі ADX), оптимізацію гіперпараметрів (проведення пошуку по сітці для боротьби з перенавчанням деревних моделей) та вдосконалення торгової стратегії (запровадження фільтра сигналів за рівнем «впевненості» прогнозу). Використання індикатора ADX є загальноприйнятою практикою для кількісної ідентифікації сили тренду та розмежування ринкових фаз [6]. Всі чотири моделі були перенавчені з урахуванням цих комплексних корекцій.

Фінальна верифікація покращених моделей на тестовій вибірці (табл. 2) показала надзвичайно показові та позитивні результати, що підтверджують ефективність запропонованої методології. Застосування комплексного плану вдосконалення, сформованого на основі діагностичних звітів, призвело до значного покращення ключової метрики F1-Score для всіх без винятку моделей.

Таблиця 2. Порівняння продуктивності моделей до та після застосування рекомендацій

Модель	F1-Score (Baseline)	F1-Score (Final)	Зміна F1
Logistic Regression	0.412	0.676	+64.1%
Random Forest	0.454	0.550	+21.1%
XGBoost	0.479	0.527	+10.0%
LSTM	0.574	0.672	+17.1%

Найбільш драматичне зростання продемонструвала Логістична регресія, F1-Score якої зріс на 64.1%, досягнувши найвищого значення серед усіх моделей (0.676). Це свідчить про те, що для лінійних моделей правильний інжиніринг ознак та усунення базових проблем даних є критично важливим і здатний кардинально змінити їхню прогнозну силу. Модель LSTM, яка була лідером на базовому етапі, також показала суттєве зростання на 17.1%, що підтверджує ефективність додавання нових контекстних ознак навіть для рекурентних архітектур. Ансамблеві моделі Random Forest та XGBoost також продемонстрували впевнене покращення, що вказує на успішність боротьби з перенавчанням та оптимізації їхньої структури.

Ці результати однозначно демонструють, що систематичний, керований даними підхід до аналізу та вдосконалення, реалізований в розробленому програмному інструментарії, є значно ефективнішим, ніж стандартне застосування моделей. Запропонована методологія дозволила не просто покращити метрики, а й підвищити якість та надійність прогнозів для широкого спектру алгоритмів, що підтверджує її практичну цінність.

5. ВИСНОВОК

У ході дослідження було розроблено та апробовано систематизований підхід до аналізу та вдосконалення прогнозних моделей для задач алгоритмічної торгівлі. Проведені експерименти підтвердили, що стандартне застосування поширених алгоритмів машинного навчання демонструє обмежену ефективність, проте глибокий аналіз їхніх помилок виявляє наявність спільних, систематичних недоліків, таких як чутливість до ринкових режимів, інформаційна надлишковість ознак та процедурні ризики.

Наукова новизна роботи полягає у розробці концепції та прототипу програмного інструментарію, що базується на формалізованій Базі Знань для автоматизованої діагностики моделей. Такий підхід дозволяє перейти від ручного, інтуїтивного аналізу до стандартизованого та відтворюваного процесу аудиту прогнозних систем, що підвищує об'єктивність та швидкість дослідницького циклу.

Практична значущість дослідження підтверджена результатами фінальної верифікації, які продемонстрували, що застосування рекомендацій, згенерованих розробленим інструментарієм, призвело до статистично значущого покращення прогнозної здатності для всіх протестованих моделей, включаючи лінійні, ансамблеві та рекурентні нейронні мережі. Це доводить, що запропонована методологія є дієвим інструментом для створення більш робастних та ефективних прогнозних моделей.

Напрямами подальших досліджень є розширення Баз Знань новими, більш специфічними для різних класів моделей правилами, а також інтеграція розробленого інструментарію з MLOps-платформами для повної автоматизації життєвого циклу розробки торгових стратегій.

ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Wang Z., Ventre C. A Financial Time Series Denoiser Based on Diffusion Model. arXiv preprint arXiv:2409.02138. 2024. URL: <https://arxiv.labs.arxiv.org/html/2409.02138> (дата звернення: 10.11.2025)
2. Zhang L., Hua L. Major Issues in High-Frequency Financial Data Analysis: A Survey of Solutions. Mathematics. 2025. Vol. 13, No. 3. P. 347. URL: <https://www.mdpi.com/2227-7390/13/3/347> (дата звернення: 15.11.2025)
3. Giantsidi S., Tarantola C. Deep Learning for Financial Forecasting: A Review of Recent Trends. SSRN Electronic Journal. 2025. URL: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5263710 (дата звернення: 15.11.2025)
4. Wang T. Automated Model Testing and Monitoring: The Bedrock of Startup MLOps. Medium. 2024. URL: <https://medium.com/@tommyadeliyi/automated-model-testing-and-monitoring-the-bedrock-of-startup-mlops-1061c0b78e2e> (дата звернення: 15.11.2025)
5. F1 Score in Machine Learning Explained. Encord. 2023. URL: <https://encord.com/blog/f1-score-in-machine-learning/> (дата звернення: 20.11.2025)
6. ADX: The Trend Strength Indicator. Investopedia. URL: <https://www.investopedia.com/articles/trading/07/adx-trend-indicator.asp> (дата звернення: 20.11.2025)