

УДК 004.85:336.74-028.63

DOI: 10.31673/2412-9070.2025.051067

І. В. ЦАПРО, аспірант,

ORCID: 0009-0006-8238-2322

Державний університет інформаційно-комунікаційних технологій, Київ

ЗАСТОСУВАННЯ МАШИННОГО НАВЧАННЯ В ЗАДАЧІ ВІДСІЮВАННЯ НЕЕФЕКТИВНИХ ТОРГОВИХ СИГНАЛІВ ЗГЕНЕРОВАНИХ ПОКАЗНИКАМИ МЕХАНІСТИЧНОГО ПІДХОДУ

Предметом цього дослідження є застосування алгоритмів машинного навчання для відсіювання неефективних торгових сигналів, згенерованих індикаторами механістичного підходу до аналізу криптовалютних ринків. Мета роботи полягає у розробці та перевірці моделей ML, здатних підвищити прибутковість торгових стратегій завдяки фільтрації хибних сигналів, що виникають при використанні механістичних показників. Завдання дослідження включають: 1) формалізацію механістичних індикаторів (механістична ковзна, MAS Buy, MAS Sell); 2) використання методу потрійних бар'єрів для класифікації сигналів на ефективні та неефективні; 3) застосування та порівняння 5 алгоритмів машинного навчання (Summary Classifier, Catch22, Rocket, TimeCNN, Stacking); 4) оцінювання ефективності моделей за метриками ROC AUC, Precision, Recall, Average Precision та Sharpe Ratio; 5) ранжування моделей за допомогою багатокритеріального підходу до прийняття рішень. Отримані результати показали, що моделі машинного навчання у більшості випадків перевершують базову Dummy-модель, особливо для довгих позицій, де зафіксовано вищі значення Sharpe Ratio та загальної прибутковості. Найкращі результати продемонстрували класифікатори Catch22, Rocket та Stacking. Натомість короткі позиції виявилися менш ефективними, що пов'язано зі зростаючим трендом криптовалют у 2019–2025 роках. Також встановлено, що варіації вікон (16, 32, 64, 128) істотно впливають на результати, підтверджуючи важливість оптимізації параметрів. Таким чином, робота демонструє доцільність інтеграції алгоритмів машинного навчання в механістичний підхід для підвищення якості торгових сигналів та прибутковості стратегій. Результати можуть бути використані для вдосконалення алгоритмічних систем торгівлі та розвитку нових підходів до застосування ML у напрямі обчислювальних фінансів.

Ключові слова: механістичний підхід; криптовалюта; ретроспективні тестування; машинне навчання; алгоритм; фільтрація; класифікатор; адаптивне навчання; метрика; цільова змінна.

Вступ

Криптовалюти швидко стали амбітною та привабливою частиною фінансових інструментів, поєднуючи технології (криптографічні методи, такі як блокчейн) з новими економічними можливостями. А висока волатильність криптоактивів приваблює трейдерів, які намагаються передбачити зміни, які відбудуться з ціною активу в майбутньому та отримати додаткові прибутки [1]. Обсяг торгів є фундаментальним показником на фінансових ринках, що надає важливу інформацію про ліквідність та цінову поведінку. Він формується взаємодією ринкових ордерів на купівлю та продаж, а також лімітних купівель та продажів, кожен з яких сприяє структурі торгового середовища [2]. Зміни в обсягах часто передують руху цін: сплеск активності купівлі може призвести до зростання цін [3, 4], тоді як підвищений тиск продавців зазвичай штовхає їх вниз [5, 6].

У [7] було запропоновано механістичний підхід для узагальненого технічного аналізу зі застосуванням на фондовому ринку. Цей підхід розширює традиційні методи, включаючи фізичні принципи, враховуючи в аналізі не лише ціну активу, але й обсяг торгів, який інтерпретується як залежна від часу «маса» активу.

Машинне навчання стало сильним інструментом для прогнозування ринкових тенденцій,

пропонуючи можливості адаптивного навчання та покращену точність прогнозування. Алгоритми ML, такі як штучні нейронні мережі (ANN), метод опорних векторів (SVM), випадковий ліс та інші можуть виявляти приховані закономірності, аналізувати настрої та реагувати на динамічні ринкові умови з більшою ефективністю, ніж традиційні підходи [8, 9].

Механістичний підхід, як і технічні індикатори, генерує сигнали, які не обов'язково гарантують прибутковість, особливо за наявності структурних розривів та змін режимів волатильності. Як результат, багато сигналів можуть призводити до збиткових угод. Застосування машинного навчання може бути ефективним інструментом в задачах відсіювання збиткових сигналів [10].

Мета роботи полягає в розробці моделей машинного навчання для відсіювання неефективних торгових сигналів згенерованих показниками механістичного підходу.

Показник узагальненого імпульсу

Механістичний підхід включає обсяг транзакцій як динамічну змінну, яка є аналогією до поняття маси у фізиці, проводячи прямі аналогії з класичною механікою. Аналогія маси: обсяг торгів розглядається як залежна від часу маса, що впливає на узагальнений імпульс. Узагальнений імпульс: визначається як добуток цієї «маси» та швидкості ціни, виявляючи більш глибоку динаміку між змінами ціни та обсягу. Розглянемо $V(t)$ як загальний обсяг активу (сума покупок та продажів) за ціною $x(t)$ у момент часу t . Узагальнений імпульс $\tilde{R}_\tau$ за інтервал часу τ можна визначити через (1):

$$\tilde{R}_\tau(t) = \frac{V(t)}{\langle V(t) \rangle_\tau} \cdot \frac{x(t) - x(t-\tau)}{\tau}, \quad t = \tau + 1, \dots, N, \quad (1)$$

де $V(t)$ – це обсяг транзакцій у момент часу t , загальний обсяг транзакцій за інтервал τ це $\langle V \rangle_\tau = \sum_{i=1}^{\tau} V(i)$ (аналогія маси), а середня швидкість зміни ціни за інтервал часу τ це $\frac{x(t) - x(t-\tau)}{\tau}$ (аналогія прискорення).

Таким чином, ми враховуємо ціну та об'єм активу і таку взаємодію можна представити як класичну силу F , яка діє на об'єкт (фондовий або ринковий індекс).

Для практичного застосування узагальненого імпульсу пропонуємо використовувати ковзні середні. Просте ковзне середнє механістичного імпульсу R за інтервал часу τ визначається як (2):

$$M_t(i) = \frac{1}{\tau} \sum_{i=t}^{t+\tau-1} R(i - \tau), \quad i = \tau + 1, \dots, N \quad (2)$$

Показник поглинання імпульсу

Ідея показника поглинання імпульсу (Momentum Absorption Score, або ж MAS) полягає у тому, щоб знаходити такі ситуації, коли відносно великі обсяги були поглинуті учасниками ринку, але внаслідок цього ціна не змінилася значуще. Показник поглинання імпульсу загальних обсягів наступний (3):

$$MAS_{V,t} = (Z_{HL_t} < P_\alpha(HL_t)) \wedge (Z_{V_t} > P_\alpha(V_t)), \quad (3)$$

де Z_{HL_t} – це z-показник різниці між максимальною та мінімальною ціною за часовий інтервал t , $P_\alpha(HL_t)$ – це функція перцентилі зі значенням $\alpha = 25$ для z-показника аналогічних різниць за попередні періоди, Z_{V_t} – це z-показник загального обсягу за часовий інтервал t , а $P_\alpha(V_t)$ – це функція перцентилі зі значенням $\alpha = 75$ для z-показника аналогічних загальних обсягів за попередні періоди.

Тобто показник набуває значення 1 (аномалія знайдена), якщо ціна не сильно змінилася відносно попередніх значень, але обсяг був вищим за попередні значення. В інших випадках значення показника 0 (аномалії не знайдено).

Аналогічно представлені показники поглинання імпульсу різниці обсягів покупок (4) та різниці обсягів продажів (5).

$$MAS_{buy\,VD,t} = (Z_{HL_t} < P_\alpha(HL_t)) \wedge (Z_{VD_t} > P_\alpha(VD_t)), \quad (4)$$

де Z_{VD_t} – це z-показник різниці ринкових обсягів покупок, а $P_\alpha(VD_t)$ – це верхня межа розподілу VD_t у момент t зі значенням $\alpha = 75$.

$$MAS_{sell\,VD,t} = (Z_{HL_t} < P_\alpha(HL_t)) \wedge (Z_{VD_t} < P_\alpha(VD_t)), \quad (5)$$

де Z_{VD_t} – це z-показник різниці ринкових обсягів продажів, а $P_\alpha(VD_t)$ – це нижня межа розподілу VD_t у момент t зі значенням $\alpha = 25$. Також акцентуємо, що Z_{VD_t} має бути нижчим за $P_\alpha(VD_t)$, на відміну від (7).

Визначення цільових змінних, моделей та метрик

Для задачі бінарної класифікації сигналів (ефективні та не ефективні сигнали) застосовано Метод потрійних бар'єрів (Triple Barrier Method, або ж TBM), що запропонована Лопесом де Прадо (2018) [11]. Потрійний бар'єр оцінює те, як відпрацював сигнал в межах заздалегідь визначеного горизонту прогнозування, використовуючи три бар'єри: бар'єр тейк-профіту (Take-Profit, або ж TP), бар'єр стоп-лосу (Stop-Loss, або ж SL) та часовий бар'єр (максимальний період утримання позиції). В залежності від того, який бар'єр було досягнуто першим, призначається відповідний клас: якщо ціна досягає TP до того як досягне SL або часового бар'єру – тоді призначається клас «1» (прибуток), а якщо ціна досягає SL до того як досягне TP або часового бар'єру – тоді призначається клас «-1» (збиток).

Використано набір ознак (факторів) часових рядів, отримані з необроблених ринкових даних до кожної точки сигналу. Зокрема, для кожного екземпляра сигналу побудовано матрицю 4×128 , де кожен рядок представляє окрему ринкову ознаку, кожен стовпець відповідає часовому кроку упродовж 128-періодного історичного вікна. Використано 4 наступні ринкові ознаки: «close_returns» (абсолютна різниця цін закриття), «Volume» (сумарний ринковий обсяг), «volume_balance» (описує тиск обсягів купівель/продажів) та «number_of_trades» (кількість угод, виконаних упродовж кожного часового інтервалу).

Застосовані наступні алгоритми машинного навчання:

1. Класифікатор описової статистики (Summary Classifier): алгоритм рахує середнє, мінімальне, максимальне значення, стандартне відхилення, а також 25, 50 та 75 перцентиль для усіх розглянутих факторів. Після цього тренує алгоритм Випадкового лісу на цих статистичних значеннях.

2. Catch22 (CAnonical Time-series CHaracteristics) класифікатор: алгоритм розраховує 22 ретельно відібрані ознаки часових рядів, які були автоматично обрані з набагато більшої множини (приблизно 7500 ознак) [12]. Після чого тренує алгоритм Випадкового лісу на цих ознаках.

3. Rocket класифікатор: це алгоритм класифікації часових рядів на основі випадково ініціалізованих згорткових ядер для перетворення вхідних часових рядів у багатовимірний простір ознак [13].

4. TimeCNN класифікатор: це архітектура глибокої нейронної мережі, яка застосовує одновимірні згорткові шари безпосередньо до часових рядів [14].

5. Stacking класифікатор: це мета модель (на основі Випадкового лісу), яка навчається на вихідних даних (прогнозах) базових навчальних моделей: Summary, Catch22 Rocket і TimeCNN.

Описані вище алгоритми навчаються та валідуються за допомогою Ковзної валідації часових рядів [15]. Такий метод валідації імітує, як модель працюватиме в реальному сценарії, шляхом ітеративного навчання на зростаючому історичному вікні та тестування на майбутніх даних, які слідує винятково після тренувальних даних у часовому вимірі. На кожній ітерації вікно навчання переміщується вперед, включаючи новіші дані, а тестовий набір розташовується безпосередньо після вікна навчання, зберігаючи хронологічний порядок. Наступні метрики ефективності моделей обчислюється для кожного тестового набору: ROC AUC, Precision, Recall, Average Precision та Sharpe Ratio.

Багатокритеріальний підхід до прийняття рішень (Multi-Criteria Decision-Making, або ж MCDM) [16] використано для ранжування моделей за ключовими 5 метриками, описаними

вище. Кожну метрику нормалізовано, щоб привести всі значення до однієї шкали. Потім для кожної конфігурації було розраховано кінцевий складений бал як зважену суму нормалізованих значень метрик (6):

$$Score = w_{ROC\ AUC} ROC\ AUC + w_p P + w_R R + w_{AP} AP + w_S S, \quad (6)$$

де $w_{ROC\ AUC}$ – це ваги для ROC AUC, w_p – це ваги для Precision, w_R – це ваги для Recall, w_{AP} – це ваги для Average Precision, а w_S – це ваги для Sharpe Ratio.

У цьому підході використовується наступний розподіл ваг, представлений у табл. 1. Найвищі ваги мають ROC AUC, Precision та Sharpe Ratio, оскільки важливо, щоб модель була здатна до прогнозування якнайкраще (ROC AUC) та генерувала мінімум хибнопозитивних прогнозів (Precision, Sharpe Ratio), мінімізуючи збитки.

Таблиця 1
Ваги для ранжування моделей за допомогою MCDM

	ROC AUC	Precision	Recall	AP	Sharpe Ratio
Ваги	0.25	0.3	0.05	0.1	0.3

Дані та конфігурація моделювання

Для цього дослідження використано історичні дані топ 5 криптовалют (окрім стейбл-коїнів) за ринковою капіталізацією (станом на 1 травня 2025 року), які були отримані з біржі Binance за період з січня 2019 року по січень 2025 року: BTC/UDST, ETH/USDT, XRP/USDT, BNB/USDT та DOGE/USDT.

Досліджувались наступні часові інтервали: 2-годинний, 1-годинний та 30-хвилинний. Часові інтервали вищі за 2-годинний (такі як 4-години або 1 день) вирішено не залучати, оскільки вони генерували недостатню кількість сигналів на кожен тренувальний та тестовий датасети.

Досліджено як довгі (Long) так і короткі (Short) позиції, де конфігурація методу трьох бар'єрів наступна:

- Бар'єр прибутку: 16 стандартних відхилень за останні 128 інтервалів;
- Бар'єр стоп лос: 8 стандартних відхилень за останні 128 інтервалів;
- Часовий бар'єр: 128 інтервалів.

Усього застосовано 3 показника механістичного підходу: Механістична ковзна загального ринкового обсягу, $MAS_{buy\ VD,t}$ та $MAS_{sell\ VD,t}$. Та 2 індикатори ринкових обсягів для порівняння з механістичним підходом: MFI та VWAP.

Сигнали на покупку для Механістичної ковзної та VWAP з'являються тоді, коли швидка ковзна перетинає повільну ковзну з низу на ногу, а на продаж (шорт), коли швидка ковзна перетинає повільну з гори вниз. При цьому VWAP фактично стає VWMA (Volume Wighted Moving Average), що буде використовуватися далі в дослідженні. Для MAS сигнали на покупку з'являються тоді, коли значення показника 1, та стандартне відхилення ціни нижче 25 перцентилля, а на продаж, коли значення 1, а стандартне відхилення ціни вище 75 перцентилля. Для MFI сигнали на покупку з'являються тоді, коли значення індикатора нижче 10 перцентилля, а на продаж, коли значення індикатора вище 90 перцентилля. Для всіх індикаторів застосовувались наступні вікна: 16, 32, 64, та 128. Тобто загалом 20 варіацій індикаторів з різними вікнами.

Також застосовано додаткову бейзлайн модель «Dummy» класифікатор, який генерує всі прогнози одним єдиним класом: «1» для довгих позицій та «-1» для коротких. Тобто ця модель не навчається і з нею можна порівнювати інші моделі, щоб зрозуміти чи навчені моделі більш ефективні.

Результати валідації моделей

У табл. 2 можна побачити співвідношення кількості випадків, коли класифікатори, які натреновані, перевершували за складеним балом Dummy класифікатор, в розрізі індикаторів та часових інтервалів. Якщо співвідношення більше ніж 0.5, то це вказує на більшу кількість випадків, коли натреновані моделі виявилися більш ефективними у порівнянні з Dummy класифікатором, а якщо менше за 0.5, то Dummy виявився більш ефективним. Можна побачити, що в усіх агрегаціях співвідношення більше 0.5 і це вказує на загальну тенденцію до більшої ефективності натренованих класифікаторів.

Найвищі значення у MAS Sell 1 годинний інтервал з 0.925, а найнижчі у Механістичної ковзної 1 година інтервал з 0.65. Також MFI 1 годинний та 30 хвилинний інтервали мають одні з найвищих значень: 0.9 та 0.875 відповідно.

Таблиця 2

Співвідношення кількості випадків, де натреновані класифікатори більш ефективні за Dummy модель, у розрізі індикаторів та часових інтервалів

Індикатор	Інтервал	Співвідношення
Механістична ковзна	2 години	0.825
Механістична ковзна	1 година	0.65
Механістична ковзна	30 хвилин	0.775
MAS Buy	2 години	0.775
MAS Buy	1 година	0.75
MAS Buy	30 хвилин	0.775
MAS Sell	2 години	0.825
MAS Sell	1 година	0.925
MAS Sell	30 хвилин	0.775
MFI	2 години	0.7
MFI	1 година	0.9
MFI	30 хвилин	0.875
VWMA	2 години	0.75
VWMA	1 година	0.825
VWMA	0 хвилин	0.8

У табл. 3 можна побачити топ 10 комбінацій за Sharpe Ratio для довгих позицій, а у табл. 4 для коротких позицій. Можна побачити, що в більшості випадків натреновані класифікатори демонструють кращі метрики, аніж Dummy модель.

Таблиця 3
Топ 10 комбінацій за Sharpe Ratio для довгих позицій

Пара	Інтервал	Індикатор	Вікно	Модель	Roc Auc	Precision	Recall	Sharpe Ratio	Сума доходів, %
BTC/USDT	1 година	Мех. ковзна	128	Catch22	0.628	0.65	0.69	2.0	229.7
BTC/USDT	30 хвилин	VWMA	32	Rocket	0.53	0.5	0.53	1.99	317.7
BTC/USDT	1 година	Мех. ковзна	128	Stacking	0.585	0.66	0.620	1.92	214.3
DOGE/USDT	1 година	Мех. ковзна	64	Catch22	0.54	0.66	0.16	1.65	189.1
ETH/USDT	2 години	Мех. ковзна	64	Rocket	0.58	0.61	0.64	1.65	316.1
BTC/USDT	1 година	VWMA	32	Rocket	0.51	0.5	0.51	1.59	250.1
BTC/USDT	1 година	Мех. ковзна	128	Dummy	0.5	0.56	1.0	1.54	204.3
BTC/USDT	30 хвилин	Мех. ковзна	64	Rocket	0.523	0.52	0.56	1.53	221.6
BTC/USDT	30 хвилин	Мех. ковзна	64	Dummy	0.5	0.49	1.0	1.5	260.8
ETH/USDT	30 хвилин	MAS Buy	128	Catch22	0.57	0.55	0.57	1.49	217.5

Таблиця 4
Топ 10 комбінацій за Sharpe Ratio для коротких позицій

Пара	Інтервал	Індикатор	Вікно	Модель	Roc Auc	Precision	Recall	Sharpe Ratio	Сума доходів, %
DOGE/USDT	1 година	VWMA	128	Rocket	0.49	0.55	0.63	0.7	146.1
XRP/USDT	30 хвилин	MFI	128	Summary	0.55	0.55	0.64	0.68	75.3
BTC/USDT	2 години	Мех. ковзна	64	Stacking	0.58	0.46	0.14	0.66	42.1
ETH/USDT	2 години	VWMA	128	TimeCNN	0.63	0.55	0.82	0.64	95.5

DOGE/USDT	1 година	VWMA	128	Dummy	0.5	0.56	1.0	0.59	99.5
BNB/USDT	30 хвилин	MFI	64	Stacking	0.5	0.55	0.17	0.57	59.6
DOGE/USDT	1 година	VWMA	128	TimeCNN	0.51	0.56	1.0	0.56	87.8
ETH/USDT	30 хвилин	MAS Sell	32	Catch22	0.54	0.55	0.4	0.52	38.5
ETH/USDT	1 година	MAS Buy	16	TimeCNN	0.45	0.4	0.55	0.5	63.3
ETH/USDT	30 хвилин	VWMA	32	Catch22	0.52	0.45	0.22	0.49	103.1

Моделі машинного навчання продемонстрували кращу ефективність у порівнянні з Dummy-класифікатором. Sharpe Ratio для коротких позицій були помітно нижчими в порівнянні з довгими позиціями. Це вказує на загалом вищі ризики та меншу прибутковість коротких позицій у контексті зростаючого ринкового тренду криптовалют у 2019 - 2025 роках. Варіація вікон (16, 32, 64, 128) показала, що оптимальні комбінації параметрів можуть суттєво впливати на ефективність моделей.

Висновки

У роботі продемонстровано доцільність застосування моделей машинного навчання для відсіювання неефективних торгових сигналів, згенерованих індикаторами механістичного підходу. Порівняння з Dummy-класифікатором підтвердило, що розглянуті моделі ML у більшості випадків показали кращі результати. Sharpe Ratio та інші метрики показали, що моделі краще працюють у випадку довгих позицій порівняно з короткими. Використання різних комбінацій вікон показало, що вибір параметрів суттєво впливає на ефективність моделей. Багатокритеріальний підхід до оцінювання моделей дозволив не лише ранжувати моделі за складним балом, але й виявити ті конфігурації, які мають найбільший потенціал прибутковості. Це вказує на перевагу застосування комплексного підходу для задач фільтрації сигналів.

Перспективи подальших досліджень наступні:

1. Використання більшої кількості криптоактивів, включно з парами, які мають менший обсяг торгів.
2. Дослідження більшої кількості варіацій вікон, гнучких порогових значень та адаптивних методів їх визначення.
3. Використання більш сучасних архітектур глибинного навчання (Transformers, Temporal Fusion Transformers) для виявлення складних нелінійних залежностей у часових рядах.
4. Дослідження підходу в формуванні багатовалютного портфелю.

Отже, застосування машинного навчання в задачі фільтрації неефективних сигналів демонструє перспективність для аналізу криптовалютних активів, але потребує подальшого розвитку та оптимізації.

Список літератури

1. Resta, Marina & Pagnottoni, Paolo & De Giuli, Maria. (2020). *Technical Analysis on the Bitcoin Market: Trading Opportunities or Investors' Pitfall?.* Risks. 8. 44. 10.3390/risks8020044.
2. Alexander, Carol & Heck, Daniel & Kaeck, Andreas & Riordan, Ryan. (2024). *Order Flow Impact and Price Formation in Centralized Crypto Exchanges.* SSRN. 10.2139/ssrn.4867599.
3. Charoenwong, Charlie & Visaltanachoti, Nuttawat & Ding, David K. (2003). *Analysis of Limit Order Book and Order Flow.* SSRN. 10.2139/ssrn.488422.
4. Bae, Kee-Hong & Jang, Hasung & Park, Kyung. (2003). *Traders' choice between limit and market orders: Evidence from NYSE stocks.* Journal of Financial Markets. 6. 517-538. 10.1016/S1386-4181(02)00047-2.

5. Hautsch, Nikolaus & Huang, Ruihong. (2011). *The Market Impact of a Limit Order*. *Journal of Economic Dynamics and Control*, Forthcoming. 10.2139/ssrn.167734.
6. Waelbroeck, Henri & Gomes, Carla. (2013). *Is Market Impact a Measure of the Information Value of Trades? Market Response to Liquidity vs. Informed Trades*. SSRN. 10.2139/ssrn.2291720.
7. Ausloos, Marcel & Ivanova, Katrin. (2002). *Mechanistic approach to generalized technical analysis of share prices and stock market indices*. *European Physical Journal B*. 27. 10.1140/epjb/e20020144.
8. Patel J, Shah S, Thakkar P, Kotecha K. *Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques*. *Expert systems with applications*. 2015;42(1):259-68.
9. Vui CS, Soon GK, On CK, Alfred R, Anthony P. *A review of stock market prediction with Artificial neural network (ANN)*. In: 2013 IEEE international conference on control system, computing and engineering. IEEE; 2013. p. 477-82.
10. Saud, Arjun & Shkaya, Subarna. (2024). *Technical Indicator Empowered Intelligent Strategies to Predict Stock Trading Signals*. *Journal of Open Innovation: Technology, Market, and Complexity*. 10. 100398. 10.1016/j.joitmc.2024.100398.
11. M. L. de Prado, *Advances in Financial Machine Learning*. New Jersey: John Wiley & Sons, 2018.
12. Lubba, Carl H., et al. "catch22: Canonical time-series characteristics." *Data Mining and Knowledge Discovery* 33.6 (2019): 1821-1852. <https://link.springer.com/article/10.1007/s10618-019-00647-x>.
13. Dempster, A., Petitjean, F. and Webb, G.I., 2020. *ROCKET: exceptionally fast and accurate time series classification using random convolutional kernels*. *Data Mining and Knowledge Discovery*, 34(5), pp.1454-1495.
14. Zhao et. al, *Convolutional neural networks for time series classification*, *Journal of Systems Engineering and Electronics*, 28(1): 2017.
15. Hyndman, R.J., & Athanasopoulos, G. (2021) *Forecasting: principles and practice*, 3rd edition, OTexts: Melbourne, Australia. [OTexts.com/fpp3](https://otexts.com/fpp3). Accessed on 15.05.2025.
16. Taherdoost, Hamed, and Mitra Madanchian. 2023. "Multi-Criteria Decision Making (MCDM) Methods and Concepts" *Encyclopedia* 3, no. 1: 77-87. <https://doi.org/10.3390/encyclopedia3010006>.

I. Tsapro

APPLICATION OF MACHINE LEARNING TO FILTER INEFFICIENT TRADING SIGNALS GENERATED BY MECHANICAL APPROACH INDICATORS

The subject of this study is the application of machine learning algorithms to filter out ineffective trading signals generated by indicators of the mechanistic approach to the analysis of cryptocurrency markets. The purpose of the work is to develop and test ML models capable of increasing the profitability of trading strategies by filtering false signals that arise when using mechanistic indicators. The research tasks include: 1) formalization of mechanistic indicators (mechanistic moving average, MAS Buy, MAS Sell); 2) use of the triple barriers method to classify signals into effective and ineffective; 3) application and comparison of 5 machine learning algorithms (Summary Classifier, Catch22, Rocket, TimeCNN, Stacking); 4) evaluation of the effectiveness of models using the ROC metrics AUC, Precision, Recall, Average Precision and Sharpe Ratio; 5) ranking models using a multi-criteria approach to decision-making. The results obtained showed that machine learning models outperform the basic Dummy model in most cases, especially for long positions, where higher Sharpe Ratio and total return values were recorded. The best results were demonstrated by the Catch22, Rocket, and Stacking classifiers. On the other hand, short positions turned out to be less effective, which is associated with the growing trend of cryptocurrencies in 2019–2025. It was also found that variations in windows (16, 32, 64, 128) significantly affect the results, confirming the importance of parameter optimization. Thus, the work demonstrates the feasibility of integrating machine learning algorithms into a mechanistic approach to improve the quality of trading signals and the profitability of strategies. The results can be used to improve algorithmic trading systems and develop new approaches to the application of ML in the direction of quantitative finances.

Keywords: mechanistic approach; cryptocurrency; retrospective testing; machine learning; algorithm; filtering; classifier; adaptive learning; metric; target variable.