

Богдан Миколайович Пархоменко¹, Андрій Миколайович Акименко²

¹аспірант кафедри інформаційних технологій та програмної інженерії
Національний університет «Чернігівська політехніка» (Чернігів, Україна)
E-mail: bparkhomenko@stu.cn.ua. ORCID: <https://orcid.org/0009-0005-1279-4981>

²кандидат фізико-математичних наук, доцент кафедри інформаційних технологій та програмної інженерії
Національний університет «Чернігівська політехніка» (Чернігів, Україна)
E-mail: anakim2@stu.cn.ua. ORCID: <https://orcid.org/0000-0002-4594-6559>

ВИКОРИСТАННЯ ІНФОРМАЦІЙНИХ МОДЕЛЕЙ ДЛЯ ПРОГНОЗУВАННЯ ПОВЕДІНКИ ФІНАНСОВИХ ПОКАЗНИКІВ

Стаття є оглядово-інформаційним викладенням матеріалу з використання моделей машинного навчання для прогнозування фінансових показників з можливістю покращення ухвалення рішень з метою формування збалансованого портфеля акцій. Об'єднання глибокого аналізу з машинним навчанням, використовуючи методи лінійної регресії, дерев рішень, випадкових лісів та платформ автоматичного навчання, є потужним інструментом для передбачення ринкових трендів та стратегічних рухів, а також тестування гіпотез. Особлива увага приділяється аналізу ефективності різних методів машинного навчання в умовах невизначеності та турбулентності ринку. Використання моделей штучного інтелекту, дозволяє враховувати залежності у фінансових даних. На основі проведених досліджень визначаються основні напрями подальших дій у цій сфері, включаючи впровадження інформаційних моделей у практичну діяльність фінансових інститутів.

Ключові слова: машинне навчання; фінансова аналітика; інформаційні моделі; ухвалення рішень.

Табл.: 3. Рис.: 1. Бібл.: 9.

Актуальність теми дослідження. Моделі машинного навчання для прогнозування фінансових показників та оптимізації формування портфеля акцій є надзвичайно актуальними в умовах сучасних фінансових ринків, які характеризуються високою динамічністю та невизначеністю. Поширені методи аналізу стають не ефективними через збільшення обсягу даних та складності ринкових взаємодій. Інтеграція нових підходів машинного навчання та теорії ігор дозволяє точніше передбачати поведінку ринку і покращити процес прийняття рішень, що є критично важливим для інвесторів та фінансових аналітиків.

Дослідження має широке значення для галузі фінансової аналітики та інвестування. Інформаційні моделі на основі штучного інтелекту підвищують ефективність управління портфелями акцій мінімізуючи ризики та максимізуючи прибуток. В умовах постійних змін на ринках та зростання конкуренції такі інструменти стають незамінними для ухвалення рішень інвестування [1].

Подальше вдосконалення алгоритмів машинного навчання, зокрема глибоких нейронних мереж, відкриває нові можливості для аналізу складних взаємодій у фінансових даних. Дослідження у цій сфері мають значний практичний внесок у покращення процесів управління інвестиціями.

Постановка проблеми. У зв'язку зі стрімким розвитком технологій останніх років та зростання кількості даних доступних для обробки виникає критична необхідність розробки ефективних методів для прогнозування фінансових показників, які можна використати у формуванні збалансованого портфеля акцій за допомогою моделей машинного навчання. Традиційні методи аналізу не завжди здатні адекватно враховувати всі доступні фактори, що знижує ефективність управління інвестиціями.

Особливо важливим дослідження є для галузі фінансової аналітики та інвестування. Застосування штучного інтелекту для аналізу фінансових даних та прогнозування ринкових трендів дозволяє підвищити точність та ефективність ухвалення рішень. Це особливо актуально в умовах невизначеності та турбулентності ринку, де точні прогнози можуть забезпечити конкурентну перевагу.

Аналіз останніх досліджень і публікацій. За останні роки була проведена велика кількість досліджень пов'язаних з використанням машинного навчання у сфері прогнозування часових рядів, якими у свою чергу є фінансові дані, що використовуються для

дослідження поведінки цін на акції компаній. Новітні методи глибокого навчання демонструють високу ефективність у передбаченні ринкових трендів та цін активів. Однак ці дослідження також виявляють важливі проблеми, зокрема пов'язані з якістю даних та інтерпретованістю моделей [1]. Значною складністю є також відсутність стабільних моделей, які показували б однакову результативність на різних фінансових даних. Більшість моделей потребує значного додаткового калібрування та оптимізації [2].

Широкої популярності набувають методи, які беруть за основу розроблені алгоритми автоматичного машинного навчання. Такі алгоритми намагаються використати одразу декілька моделей, оптимізувати їх і обрати для подальшої роботи одну з представлених у вхідній конфігурації, що показала найбільшу ефективність. Вони показують більшу продуктивність, оскільки за короткий термін можна протестувати кілька алгоритмів одночасно та обрати найкращий. Такі механізми використовуються в роботі з часовими рядами, де показали більшу ефективність за традиційні методи [3]. Зокрема, такі механізми використовується і у сфері прогнозування фінансових показників, де широко використовуються як допоміжний інструмент ухвалення рішень [4].

Виділення недосліджених частин загальної проблеми. Попри досягнення в прогнозуванні фінансових даних за допомогою машинного навчання, є важливі недосліджені грані. Однією з основних проблем є нестабільність моделей, які часто показують різні результати на різних наборах даних. Це створює труднощі для інвесторів, які покладаються на точні прогнози для формування своїх портфелів акцій. Більшість моделей потребує додаткового калібрування та оптимізації, що вимагає значних ресурсів і часу для тестування потенційних гіпотез. Виникає складність підбору моделей.

Метою статті є аналіз процесу використання існуючих моделей машинного навчання для прогнозування фінансових показників і створення додаткових параметрів у прийнятті рішень для формування збалансованого портфеля акцій, а також пошук шляхів, які допоможуть перевірити гіпотези прогнозування на якомога більшій кількості моделей для покращення процесу пошуку найкращого результату.

Виклад основного матеріалу. Збільшення кількості даних доступних для аналізу спонукає використовувати сучасні методи для їх аналізу та пошуку залежностей. Це стосується також і фінансової сфери, де для ухвалення ефективних рішень критично необхідно використовувати інформаційні моделі, оскільки людина більше не може обробити ефективно весь спектр доступних даних [5]. Машинне навчання відкриває нові можливості для аналізу великих обсягів фінансових даних і формування збалансованих портфелів акцій. Завдяки своїй здатності автоматично виявляти складні шаблони і тренди в даних, моделі машинного навчання дозволяють значно підвищити точність прогнозів і оптимізувати інвестиційні стратегії.

Зазвичай робота з моделями включає в себе декілька важливих етапів [2]. Першим кроком є збір історичних даних за допомогою API, таких як Yahoo Finance або іншого джерела. На цьому етапі важливо зібрати якнайбільше даних. Наступним етапом є попередня обробка даних. Важливою частиною цього кроку є створення додаткових ознак на вже наявних, що полегшує роботу моделей машинного навчання. Після обробки даних переходять до створення моделей прогнозування. Це включає вибір і налаштування різних алгоритмів машинного навчання, таких як лінійна регресія, випадкові ліси, градієнтне підсилування або глибокі нейронні мережі. Кожна з цих моделей має свої переваги та недоліки, і вибір конкретної моделі залежить від характеристик даних та вимог до точності прогнозу. Останнім етапом є оцінка моделі, що включає перевірку точності прогнозів на тестових даних. Для цього використовують різні метрики оцінювання, такі як середньоквадратична помилка (RMSE) [4]. Оцінка моделі дозволяє виявити її сильні та слабкі сторони й за потреби додати корективи або вибрати іншу модель.

Для проведення базового експерименту з прогнозування поведінки цін акцій та реалізації першого та другого етапів ланцюга можна використати відкриті дані біржових торгів, а також доповнити додатковими показниками. Весь список використаних характеристик наведено в табл. 1.

Таблиця 1 – Ознаки вхідних даних використаних для експериментального прогнозування

Ознаки	Трактування
Date	Дата відповідного торгового дня.
Open	Ціна відкриття. Відображає ціну акції на початок торгового дня.
High	Максимальна ціна. Найвища ціна акції, досягнута протягом торгового дня.
Low	Мінімальна ціна. Найнижча ціна акції, зафіксована протягом торгового дня.
Close	Ціна закриття. Ціна акції на момент закриття торгів.
Volume	Обсяг торгів. Кількість акцій, що були продані або куплені протягом торгового дня.
SMA_20	Проста ковзаюча середня за 20 днів.
SMA_50	Проста ковзаюча середня за 50 днів.
EMA_20	Експоненційна ковзаюча середня за 20 днів.
EMA_50	Експоненційна ковзаюча середня за 50 днів.
RSI	Індекс відносної сили. Вимірює швидкість і зміну цінових рухів.

Джерело: розроблено автором.

Для перевірки одразу декількох моделей машинного навчання та економії ресурсів доцільно використовувати бібліотеки-агрегатори, що надають можливість використати одразу великий набір алгоритмів та перевірити й порівняти їх показники на наборі даних. До таких бібліотек також належить H2O [6]. Для вибору бібліотеки H2O та платформи H2O.ai як основних засобів для машинного навчання було кілька вагомих причин. Передусім H2O.ai надає можливість високопродуктивного розподіленого тренування на великих наборах даних, що є критично важливим для фінансових ринків з їх великими обсягами даних. Крім того, ця платформа підтримує широкий спектр алгоритмів машинного навчання, включаючи лінійну регресію, дерева рішень, випадкові ліси та градієнтне підсилування, що дозволяє порівнювати різні моделі та обирати найкращі для конкретних задач. Також H2O AutoML автоматизує процес вибору, тренування та налаштування моделей, що значно скорочує час, необхідний для отримання високоякісних прогнозів. Це особливо важливо в умовах швидкоплинного фінансового ринку, де швидкість і точність прийняття рішень є вирішальними факторами. Платформа легко інтегрується з мовами програмування R, Python, Java і Scala, що робить її зручною для використання в різних робочих середовищах.

Існують кілька внутрішніх обмежень середовища H2O, які можуть впливати на моделі машинного навчання. Серед них підтримка обмеженого набору алгоритмів, обмеження на розмір даних, можливості паралельного обчислення, автоматизація процесів (AutoML), обмеження інтерпретації моделей, інтеграція з іншими інструментами та потреба в специфічних знаннях. Наприклад, H2O підтримує лише певний набір алгоритмів, що може обмежувати вибір методів для специфічних задач. Обмеження на розмір даних залежать від доступної оперативної пам'яті, а паралельне обчислення може бути менш ефективним на машинах із малою кількістю ядер.

Крім того, автоматизація процесів за допомогою H2O AutoML може обмежити гнучкість користувачів у налаштуванні моделей, а деякі алгоритми, такі як глибокі нейронні мережі, можуть бути складними для інтерпретації.

Однак, в контексті цього дослідження ці обмеження не є релевантними, оскільки основна мета полягає у порівнянні точності різних моделей на заданому наборі даних. Платформа H2O забезпечує всі необхідні можливості для досягнення цієї мети.

Таким чином, вибір H2O.ai був обумовлений її потужними можливостями для обробки великих обсягів даних, підтримкою різноманітних алгоритмів, автоматизацією процесів машинного навчання та легкою інтеграцією з популярними мовами програмування, що робить її оптимальним рішенням для фінансових аналізів і прогнозування. Аби виконати якісне прогнозування, використовуємо одразу декілька різних типів моделей, що надає платформа H2O.

Першим є GLM (Generalized Linear Model) одна з найпростіших і найбільш інтерпретованих моделей машинного навчання [7]. Модель передбачає залежність між цільовою змінною (ціною акції) та однією чи кількома незалежними змінними шляхом побудови лінійного рівняння. GLM використовується для моделювання лінійних відносин між вхідними змінними і цільовою змінною. Вона добре працює з великими обсягами даних і показує стабільні результати.

Другим є GBM (Gradient Boosting Machine) метод ансамблювання, який створює послідовність дерев рішень, де кожне наступне дерево виправляє помилки попереднього [9]. Градієнтне підсилювання дозволяє ефективно враховувати нелінійні залежності в даних і забезпечує високу точність прогнозів [8].

Третім є DRF (Distributed Random Forest), що складається з великої кількості дерев рішень, кожне з яких навчається на випадковому підмножині даних і ознак. Випадкові ліси забезпечують стійкість до перенавчання і можуть обробляти великі обсяги даних з високою швидкістю [9]. Вони добре працюють з різними типами даних та показують стабільні результати.

Останнім методом є ансамблеві моделі (Stacked Ensembles), який поєднує кілька базових моделей для створення більш точного та стабільного прогнозу. Цей підхід ґрунтується на ідеї, що поєднання декількох моделей дозволяє компенсувати їхні індивідуальні недоліки та підвищити загальну оцінку. Ансамбль складається з двох рівнів: базові моделі та метамодель. Базові моделі – це різноманітні алгоритми машинного навчання, які незалежно тренуються на тому ж самому наборі даних. Кожна з цих моделей генерує свій результат. Метамодель навчається на прогнозах базових моделей.

Для оцінки результативності моделей будемо використовувати Root Mean Squared Error (RMSE). Це метрика, яка використовується для оцінки якості прогнозів моделі машинного навчання [4]. RMSE показує середню квадратичну помилку між прогнозованими та фактичними значеннями. Чим менше значення RMSE, тим точніше модель. Розраховується за формулою:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\hat{y}_i - y_i \right)^2},$$

де n – кількість спостережень, \hat{y}_i – прогнозоване значення, y_i – фактичне значення.

Основною причиною такого вибору є те, що в контексті фінансових ринків найбільш важливим критерієм є точність прогнозів, оскільки інвестори та аналітики орієнтуються на мінімізацію помилок у прогнозах для прийняття оптимальних рішень. Перевірка адекватності моделей також є важливим аспектом, але в такому випадку ми зосередилися на RMSE через те, що це критичний параметр для прийняття рішень на фінансових ринках, і RMSE безпосередньо показує, наскільки модель підходить для прогнозування фінансових показників.

У процесі виконання тренування та прогнозування на даних про ціни акцій за допомогою платформи H2O було отримано результати, що показано в табл. 2.

Таблиця 2 – Результати тренування моделей в ході експерименту

Модель	RMSE
StackedEnsemble_BestOfFamily_1	0,200180
StackedEnsemble_AllModels_1	0,202486
DRF_1	0,205305
GBM_3	0,207178
GBM_2	0,226384
GLM_1	0,254302
GBM_1	0,731782

Джерело: розроблено автором.

Модель `StackedEnsemble_BestOfFamily_1` показала найнижче значення RMSE (0.200180) на тренувальних даних. Це свідчить про її високу точність. Оскільки ансамблеві моделі комбінують прогнози кількох базових моделей, що дозволяє компенсувати індивідуальні недоліки кожної з них і покращити загальну продуктивність. Модель `StackedEnsemble_AllModels_1` продемонструвала схожий результат з RMSE 0.202486, що підкреслює ефективність поєднання всіх створених моделей для досягнення стабільного прогнозу.

Модель `DRF_1` (Distributed Random Forest) також показала високі результати з RMSE 0.205305. Випадкові ліси є стійкими до перенавчання завдяки використанню великої кількості дерев рішень, що працюють на випадкових підмножин даних.

Моделі градієнтного підсилення `GBM_3` та `GBM_2` продемонстрували RMSE 0.207178 і 0.226384 відповідно. Градієнтне підсилення є потужним методом ансамблювання, який створює послідовність дерев рішень, де кожне наступне дерево виправляє помилки попереднього.

Модель `GLM_1` (Generalized Linear Model) мала RMSE 0.254302, що є дещо вищим порівняно з іншими моделями, але все ж показало достатньо стабільні результати.

Нарешті, модель `GBM_1` показала найвищий RMSE серед розглянутих моделей (0.731782), що може свідчити про недостатню оптимізацію або перенавчання на тренувальних даних.

Причиною високого RMSE може бути використання технік автоматичного машинного навчання, що ускладнює безпосередньо процес оптимізації кожної моделі індивідуально. Таким чином, у фінальній вибірці можуть потрапляти не результативні моделі. Але в свою чергу це надає можливість перевірити велику кількість алгоритмів одночасно і перевірити, який може підходити краще за інших для вхідних даних.

Виконання прогнозування на тестовій вибірці показало значно інші результати. Вони наведені в табл. 3.

Таблиця 3 - Результати прогнозування на тестовій вибірці

Модель	RMSE
StackedEnsemble_BestOfFamily_1	52,967622
StackedEnsemble_AllModels_1	57,206504
DRF_1	71,404299
GBM_3	73,420568
GBM_2	73,442396
GLM_1	1,852510
GBM_1	85,858264

Джерело: розроблено автором.

На рис. 1 можна побачити результати прогнозування кожної моделі в порівнянні до реальних даних.




Рис. 1. Результати прогнозу на тестовій вибірці

З отриманих даних можна побачити, що моделі адаптувалися до тренувальних даних, унаслідок чого виникло перенавчання - неможливість працювати з новими даними. Таке часто трапляється при використанні автоматичних платформ, як H2O. У свою чергу це надає можливість одразу виявити проблемні алгоритми й відкинути їх для наступних ітерацій тренувань. У результаті перевірки на тестовій вибірці найкраще показала себе модель GLM_1, яку в подальшому можна використати аналітикам для формування збалансованих портфелів спираючись на результати прогнозу. Хоча в першій ітерації тестування все ще точність дуже низька, що вказує на потребу в додатковому калібруванні.

Висновок. Проведене дослідження показало достатню ефективність використання моделей машинного навчання для прогнозування цін на акції. Ансамблеві моделі, такі як StackedEnsemble_BestOfFamily_1 і StackedEnsemble_AllModels_1, демонструють найкращі результати на тренувальних даних завдяки здатності поєднувати прогнози декількох базових моделей. Важливими факторами для покращення точності є ретельне калібрування даних та регуляризація моделей. Різниця між результатами на тренувальних і тестових даних свідчить про необхідність додаткових кроків для покращення моделей працювати з новими даними.

Результати найкращих моделей можна використовувати для прийняття рішень у формуванні збалансованого портфеля акцій. Прогнози цін на акції, отримані з використанням цих моделей, можуть допомогти інвесторам визначити оптимальні часові проміжки для купівлі або продажу акцій. Наприклад, прогнози можуть вказати на потенційні точки зростання або падіння вартості акцій, що дозволяє інвесторам вчасно реагувати на ринкові зміни й коригувати свої стратегії.

Загалом, результати підкреслюють важливість інтеграції моделей машинного навчання у процес прийняття фінансових рішень. Використання AutoML, яке автоматизує підбір, тренування та налаштування моделей, дозволяє тестувати якомога більше моделей, що сприяє перевірці гіпотез прогнозування і знаходження оптимальних рішень.

Подальші дослідження повинні бути спрямовані на вдосконалення методів регуляризації, покращення якості даних та розробку нових технічних індикаторів для підвищення точності прогнозів. Використання більшої кількості моделей для перевірки гіпотез та трендів стає можливим завдяки AutoML, що дає змогу порівнювати велику кількість моделей за короткий проміжок часу.

Список використаних джерел

1. Machine learning in financial forecasting: A U.S. review: Exploring the advancements, challenges, and implications of AI-driven predictions in financial markets / O. Olubusola, N. Zamanjomane Mhlongo, D. binna Daraojimba [et al.] // *World Journal of Advanced Research and Reviews*. – 2024. – № 21.
2. Gaurang, Sonkavde. Forecasting Stock Market Prices Using Machine Learning and Deep Learning Models: A Systematic Review, Performance Analysis and Discussion of Implications / Gaurang Sonkavde, Gaurang Sonkavde, Anupkumar M. Bongale // *Int. J. Financial Stud.* – 2023. – № 11.
3. Ahmad. Alsharif. Review of ML and AutoML Solutions to Forecast Time-Series Data / Ahmad Alsharif, Karan Aggarwal, Sonia Garg // *Archives of Computational Methods in Engineering*. – 2022. – № 29.
4. George, Westergaard. Time Series Forecasting Utilizing Automated Machine Learning (AutoML): A Comparative Analysis Study on Diverse Datasets / George Westergaard, Utku Erden, Omar Abdallah Mateo // *Information*. – 2024. – № 15.
5. Marko, Kureljusic. Forecasting in financial accounting with artificial intelligence – A systematic literature review and future research agenda / Marko Kureljusic, Erik Karger. // *Journal of Applied Accounting Research*. – 2024. – № 25.
6. Intisar, O. Automated Prediction of Crack Propagation Using H2O AutoML / O. Intisar, M. Khan, A. Starr // *Sensors (Basel)*. – 2023.
7. Comparative Analysis of Stock Price Prediction Models: Generalized Linear Model (GLM), Ridge Regression, Lasso Regression, Elasticnet Regression, and Random Forest -A Case Study on Netflix [Electronic resource]. – 2023. – Accessed mode: https://www.researchgate.net/publication/374950281_Comparative_Analysis_of_Stock_Price_Prediction_Models_Generalized_Linear_Model_GLM_Ridge_Regression_Lasso_Regression_Elasticnet_Regression_and_Random_Forest_-_A_Case_Study_on_Netflix.
8. Tran, K. Machine Learning to Forecast Financial Bubbles in Stock Markets: Evidence from Vietnam / K. Tran, H. Le, C. Lieu // *Int. J. Financial Stud.* – 2023.
9. Sanjiban, S. Random forest, gradient boosted machines and deep neural network for stock price forecasting: a comparative analysis on South Korean companies / S. Sanjiban, R. Chopra, K. Lee // *International Journal of Ad Hoc and Ubiquitous Computing*. – 2020.

References

1. Olubusola, O., Zamanjomane Mhlongo, N., binna Daraojimba, D., & et al. (2024). Machine learning in financial forecasting: A U.S. review: Exploring the advancements, challenges, and implications of AI-driven predictions in financial markets. *World Journal of Advanced Research and Reviews*, 21.
2. Sonkavde, G., Sonkavde, G., & Bongale, A. M. (2023). Forecasting stock market prices using machine learning and deep learning models: A systematic review, performance analysis and discussion of implications. *International Journal of Financial Studies*, 11.
3. Alsharif, A., Aggarwal, K., & Garg, S. (2022). Review of ML and AutoML solutions to forecast time-series data. *Archives of Computational Methods in Engineering*, 29.
4. Westergaard, G., Erden, U., & Abdallah Mateo, O. (2024). Time series forecasting utilizing automated machine learning (AutoML): A comparative analysis study on diverse datasets. *Information*, 15.
5. Kureljusic, M., & Karger, E. (2024). Forecasting in financial accounting with artificial intelligence – A systematic literature review and future research agenda. *Journal of Applied Accounting Research*, 25.
6. Intisar, O., Khan, M., & Starr, A. (2023). Automated prediction of crack propagation using H2O AutoML. *Sensors (Basel)*.

7. Comparative analysis of stock price prediction models: Generalized linear model (GLM), ridge regression, lasso regression, elasticnet regression, and random forest - A case study on Netflix. (2023). https://www.researchgate.net/publication/374950281_Comparative_Analysis_of_Stock_Price_Prediction_Models_Generalized_Linear_Model_GLM_Ridge_Regression_Lasso_Regression_Elasticnet_Regression_and_Random_Forest_-_A_Case_Study_on_Netflix.

8. Tran, K., Le, H., & Lieu, C. (2023). Machine learning to forecast financial bubbles in stock markets: Evidence from Vietnam. *International Journal of Financial Studies*.

9. Sanjiban, S., Chopra, R., & Lee, K. (2020). Random forest, gradient boosted machines and deep neural network for stock price forecasting: A comparative analysis on South Korean companies. *International Journal of Ad Hoc and Ubiquitous Computing*.

Отримано 03.06.2024

UDC 004.94

Bohdan Parkhomenko¹, Andrii Akimenko²

¹PhD student of the Department of Information Technology and Software Engineering
Chernihiv Polytechnic National University (Chernihiv, Ukraine)

E-mail: bparkhomenko@stu.cn.ua. **ORCID:** <https://orcid.org/0009-0005-1279-4981>

²PhD in Physics and Mathematics,

Associate Professor of the Department of Information Technologies and Software Engineering
Chernihiv Polytechnic National University (Chernihiv, Ukraine)

E-mail: anakim2@stu.cn.ua. **ORCID:** <https://orcid.org/0000-0002-4594-6559>

USE OF INFORMATION MODELS TO PREDICT THE BEHAVIOR OF FINANCIAL INDICATORS

The article provides an overview of using machine learning models to predict financial indicators, aiming to enhance decision-making for balanced stock portfolios. The study highlights the relevance of this approach due to the dynamic nature of financial markets, where traditional methods fall short. Machine learning techniques like linear regression, decision trees, random forests, and automatic learning platforms, combined with deep learning, are powerful tools for predicting market trends and strategic moves.

The research addresses the need for accurate forecasting methods, which is critical for investors and analysts. It evaluates the performance of various machine learning models in market uncertainty, focusing on their ability to capture financial data dependencies. Metrics such as RMSE are used to assess model accuracy.

Combining deep learning with machine learning techniques improves prediction capabilities. Ensemble methods, which merge multiple models, particularly enhance accuracy. The study identifies future directions, including refining and integrating models into financial institutions' practices.

The study underscores the potential of AI models to transform financial analytics, leading to better decision-making and more balanced, profitable stock portfolios. Implementing these models in financial institutions can significantly improve their ability to navigate market uncertainties and seize opportunities.

Keywords: machine learning; financial analytics; information models; decision-making.

Table: 3. Fig.: 1. References: 9.