

DOI: <https://doi.org/10.36910/6775-2524-0560-2026-62-36>

УДК 004.8:005.52

Шкітов Андрій Анатолійович¹, аспірант

<https://orcid.org/0009-0005-4600-8467>

Бузоверя Надія Геннадіївна², к.т.н., доцент

<https://orcid.org/0009-0002-1919-5277>

¹ Відкритий міжнародний університет розвитку людини «Україна», м. Київ, Україна

² Івано-Франківський національний технічний університет нафти і газу, м. Івано-Франківськ, Україна

АНАЛІЗ ЕФЕКТИВНОСТІ ТИПОВИХ АЛГОРИТМІВ МАШИННОГО НАВЧАННЯ ДЛЯ ОЦІНЮВАННЯ РИЗИКІВ У ПРОЦЕСІ ПРИЙНЯТТЯ БІЗНЕС-РІШЕНЬ

Шкітов А.А., Бузоверя Н.А. Аналіз ефективності типових алгоритмів машинного навчання для оцінювання ризиків у процесі прийняття бізнес-рішень. У статті розглянуто актуальну проблему підвищення ефективності систем підтримки прийняття рішень у бізнес-середовищі шляхом застосування типових алгоритмів машинного навчання для оцінювання ризиків. У контексті зростаючої складності даних, високої динаміки ринку та невизначеності, традиційні статистичні методи дедалі більше втрачають здатність забезпечувати достатню точність, адаптивність та гнучкість при аналізі ризиків. Машинне навчання, як ключовий інструмент аналітики великих даних, дозволяє побудувати моделі, здатні адаптуватися до змін і враховувати складні взаємозв'язки між змінними. Водночас залишається відкритим питання доцільності використання тих чи інших алгоритмів у конкретних бізнес-сценаріях з урахуванням не лише точності, а й інтерпретованості, стабільності, обчислювальної ефективності та простоти впровадження. У межах дослідження проведено системний аналіз літературних джерел, що охоплюють як класичні моделі (логістична регресія, дерева рішень), так і сучасні підходи (ансамблеві методи, нейронні мережі). Визначено основні переваги й обмеження кожної групи моделей у контексті задач бізнес-аналітики. На основі відкритих наборів бізнес-даних проведено експериментальне моделювання із застосуванням типових алгоритмів: логістичної регресії, дерева рішень, випадкового лісу (Random Forest), градієнтного бустингу та багатошарового перцептрона. Моделі порівнювались за метриками точності, повноти, F1-міри та AUC, а також за такими критеріями, як інтерпретованість, потреба в обчислювальних ресурсах і придатність до інтеграції в реальні системи. Результати дослідження продемонстрували, що ансамблеві методи, зокрема градієнтний бустинг, забезпечують найвищі показники точності та стабільності при роботі з великими обсягами складних даних. Водночас моделі, такі як логістична регресія або дерева рішень, можуть бути рекомендованими в ситуаціях, де критичною є прозорість логіки прийняття рішення або обмеження в ресурсах. Запропоновано підхід до вибору моделі, що враховує не лише технічні характеристики алгоритмів, але й специфіку бізнес-контексту. Розроблено схему інтеграції моделей у корпоративні системи підтримки рішень, що враховує взаємодію з CRM-системами, модулями аналітики ризиків і користувацькими інтерфейсами.

Ключові слова: машинне навчання, оцінювання ризиків, бізнес-аналітика, алгоритми класифікації, градієнтний бустинг, системи підтримки прийняття рішень.

Shkitov A., Buzoveria N. Analysis of the effectiveness of typical machine learning algorithms for assessing risks in the business decision-making process. The article considers the current problem of increasing the efficiency of decision support systems in a business environment by applying typical machine learning algorithms for risk assessment. In the context of growing data complexity, high market dynamics and uncertainty, traditional statistical methods are increasingly losing their ability to provide sufficient accuracy, adaptability and flexibility in risk analysis. Machine learning, as a key tool in big data analytics, allows you to build models that can adapt to changes and take into account complex relationships between variables. At the same time, the question of the appropriateness of using certain algorithms in specific business scenarios remains open, taking into account not only accuracy, but also interpretability, stability, computational efficiency and ease of implementation. The study conducted a systematic analysis of literature sources, covering both classical models (logistic regression, decision trees) and modern approaches (ensemble methods, neural networks). The main advantages and limitations of each group of models in the context of business analytics tasks were identified. Based on open business data sets, experimental modeling was conducted using typical algorithms: logistic regression, decision tree, random forest, gradient boosting, and multilayer perceptron. The models were compared according to the metrics of accuracy, completeness, F1-measure, and AUC, as well as criteria such as interpretability, computational resource requirements, and suitability for integration into real systems. The results of the study demonstrated that ensemble methods, in particular gradient boosting, provide the highest accuracy and stability when working with large volumes of complex data. At the same time, models such as logistic regression or decision trees can be recommended in situations where transparency of decision-making logic or resource constraints are critical. An approach to model selection is proposed that takes into account not only the technical characteristics of the algorithms, but also the specifics of the business context. A scheme for integrating models into corporate decision support systems has been developed, which takes into account interaction with CRM systems, risk analytics modules, and user interfaces.

Key words: machine learning, risk assessment, business analytics, classification algorithms, gradient boosting, decision support systems.

Постановка проблеми та її зв'язок із важливими науковими чи практичними завданнями. У сучасному бізнес-середовищі, що характеризується високим рівнем динаміки, невизначеності та конкуренції, ухвалення рішень на основі точного аналізу ризиків є критичним

чинником успішності компаній [1]. Ризики можуть мати різне походження – фінансове, операційне, регуляторне, репутаційне – і здатні впливати на стійкість бізнесу в коротко- та довгостроковій перспективі [2]. З огляду на це, традиційні підходи до оцінки ризиків, засновані на статистичних або експертних методах, часто не враховують складність сучасних даних, їхню високовимірність, а також не забезпечують достатньої гнучкості в умовах швидкої зміни ринкової ситуації [3].

Машинне навчання, як одна з провідних технологій обробки великих обсягів даних, відкриває нові можливості для побудови адаптивних моделей прогнозування та оцінки ризиків [4]. Проте ефективність алгоритмів машинного навчання суттєво залежить від типу даних, обраної моделі, метрики якості, а також від характеру ризиків, які підлягають аналізу [5]. У зв'язку з цим постає завдання системного дослідження типових алгоритмів машинного навчання з метою виявлення їх придатності до задач бізнес-аналітики, зокрема, для підтримки процесів ухвалення рішень в умовах ризику.

Наукова актуальність проблеми зумовлена потребою у підвищенні якості автоматизованих систем підтримки прийняття рішень, орієнтованих на обробку великих потоків даних у реальному часі. Практична значущість полягає у можливості інтеграції найбільш ефективних алгоритмів у корпоративні інформаційні системи для зниження втрат від ризикованих дій, підвищення адаптивності до зовнішніх змін та покращення управління бізнес-процесами.

Незважаючи на значну кількість досліджень у галузі машинного навчання, питання порівняльного аналізу ефективності типових алгоритмів саме в контексті оцінювання ризиків у сфері бізнесу залишається відкритим. Відсутність уніфікованих критеріїв вибору моделей, з урахуванням специфіки бізнес-середовища, обмежує практичне застосування машинного навчання в автоматизованих системах ризик-менеджменту. Саме тому виникає потреба в комплексному підході до оцінювання моделей, який враховуватиме не лише точність прогнозу, а й інтерпретованість, стабільність, адаптивність та обчислювальну ефективність.

Метою дослідження є аналіз ефективності типових алгоритмів машинного навчання для оцінювання ризиків у процесі прийняття бізнес-рішень шляхом порівняння їх продуктивності на прикладах різних сценаріїв управлінських задач.

Аналіз останніх досліджень та публікацій. Упродовж останніх років спостерігається зростання інтересу до застосування алгоритмів машинного навчання у сфері бізнес-аналітики та управління ризиками [6]. У публікаціях [7–9] описано використання дерев рішень, логістичної регресії та наївного байєсівського класифікатора для виявлення кредитних ризиків і прогнозування фінансових втрат. Ці методи вирізняються високою швидкістю навчання і простотою інтерпретації результатів, що робить їх привабливими для впровадження в корпоративні системи. Водночас вони демонструють нижчу точність у порівнянні з більш складними моделями, особливо на великих масивах неструктурованих даних.

Глибокі нейронні мережі, згорткові структури та рекурентні архітектури вивчалися у контексті прогнозування попиту, виявлення шахрайства та оцінки операційних ризиків [10, 11]. Вони дають змогу знаходити складні нелінійні залежності між ознаками, але вимагають великих обсягів навчальних даних і значних обчислювальних ресурсів, що обмежує їх використання у практичних бізнес-сценаріях з обмеженим бюджетом.

Переваги моделей ансамблевого навчання, таких як Random Forest або градієнтний бустинг, розкриваються на задачах із великою кількістю ознак і складною структурою даних [12, 13]. Такі алгоритми демонструють високу точність, здатність до узагальнення та стійкість до перевчання. Однак їх ефективність значною мірою залежить від налаштування гіперпараметрів, що потребує додаткових витрат часу й ресурсів.

Роботи, присвячені оцінці моделей, підкреслюють важливість вибору відповідних метрик продуктивності. У задачах аналізу ризиків використовуються не лише точність (accuracy), а й recall, precision, F1-міра, а також специфічні бізнес-метрики втрат або вигоди [14, 15]. Вибір метрики впливає на рішення щодо моделі, особливо в ситуаціях, де вартість хибнопозитивного або хибнонегативного рішення може бути критичною.

Оцінювання ролі машинного навчання в системах підтримки прийняття рішень свідчить про необхідність забезпечення не лише високої точності, а й зрозумілості моделей для кінцевого користувача [16]. Багато компаній надають перевагу моделям, які дозволяють відслідковувати логіку прийняття рішення, як-от дерева рішень або інструменти з пояснюваністю (explainable AI), замість «чорних скриньок», що характерно для глибоких нейронних мереж.

В окремих дослідженнях також порушується проблема нестабільності моделей при зміні умов ринку або джерел даних. Автори [17] зазначають важливість адаптивного навчання та регулярного оновлення моделей, аби підтримувати їхню релевантність у динамічному середовищі. Це особливо актуально для сфери фінансів, логістики та електронної комерції, де ризики змінюються надто швидко, щоб моделі залишалися статичними.

Попри значний обсяг наявних досліджень, спостерігається брак комплексних порівнянь типових алгоритмів машинного навчання на прикладах реальних бізнес-завдань. Більшість публікацій зосереджуються на вузькоспеціалізованих кейсах або на оцінці одного типу моделі без урахування практичних обмежень, таких як обчислювальні ресурси, потреба в інтерпретованості або швидкість реакції. Це ускладнює вибір оптимального алгоритму для конкретного завдання з урахуванням особливостей бізнес-середовища.

Таким чином, наявна наукова база підтверджує ефективність машинного навчання для оцінювання ризиків, але потребує доповнення системним аналізом і практично орієнтованими дослідженнями, які враховують не лише якість моделей, а й специфіку впровадження в бізнес-процеси.

Виклад основного матеріалу й обґрунтування отриманих результатів дослідження. У контексті прийняття бізнес-рішень завдання оцінювання ризику розглядається як задача прогнозування, в залежності від типу проблеми – класифікації або регресії. Якщо потрібно передбачити настання певної події, наприклад, дефолту клієнта, відмови партнера або вірогідність шахрайства, то застосовується класифікаційний підхід. Якщо ж завданням є оцінка кількісного ризикового показника, наприклад, прогноз збитків або рівня недоотриманого доходу, використовуються моделі регресії.

Типовими параметрами задачі є набір вхідних характеристик (ознаки), що відображають поточний стан об'єкта аналізу, історичні дані, поведінкові чи транзакційні патерни. Цільова змінна залежить від специфіки задачі – бінарна мітка (ризиковий/неризиковий), ймовірність події, сума втрат або коефіцієнт ризику. Серед особливостей ризикових ситуацій у бізнес-середовищі – наявність асиметричних втрат, нерівномірний розподіл класів, значущість хибнопозитивних або хибнонегативних прогнозів.

На рисунку 1 зображено узагальнену схему процесу прийняття бізнес-рішень, яка включає етап збору даних, їх попередньої обробки, побудови моделі оцінки ризику, інтерпретації результатів та ухвалення відповідного рішення.

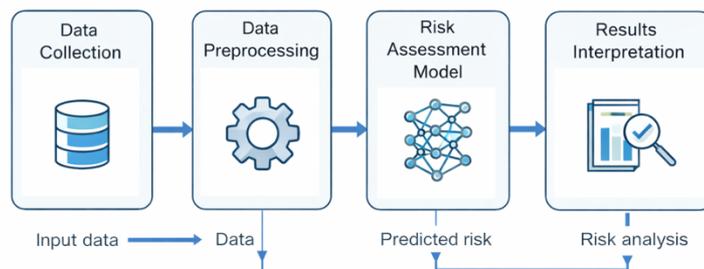


Рис. 1 – Загальна схема оцінювання ризику як етапу бізнес-рішення

Схема ілюструє, що якість прийнятого рішення залежить від точності моделі, її здатності адаптуватися до нових даних і надавати зрозуміле обґрунтування для управлінського персоналу.

Для дослідження було обрано типові алгоритми машинного навчання, які активно використовуються в задачах бізнес-аналітики. До них належать моделі з різним ступенем складності, інтерпретованості та вимог до навчальних даних.

Логістична регресія є базовою моделлю класифікації, яка дозволяє оцінити ймовірність настання події на основі лінійної комбінації ознак. Вона проста в реалізації та добре інтерпретується, проте не враховує складні взаємозв'язки між ознаками.

Дерева рішень будують ієрархію умов, за якими здійснюється класифікація або регресія. Вони здатні працювати з неоднорідними даними, легко інтерпретуються, але схильні до перенавчання.

На рисунку 2 представлено схематичні структури моделей логістичної регресії та дерева рішень.

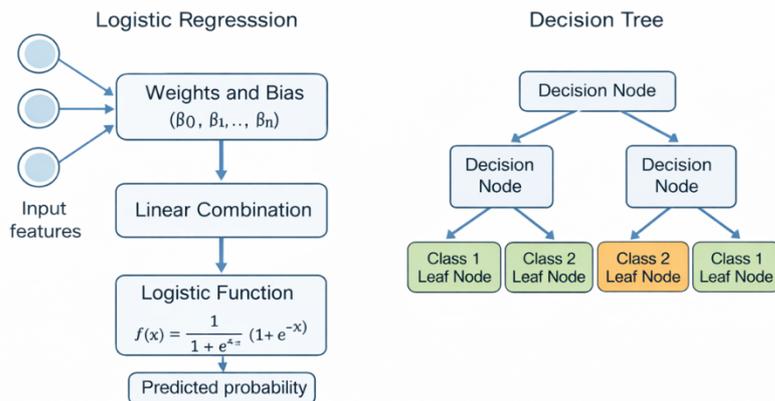


Рис. 2 – Структури моделей: логістична регресія і дерево рішень

Випадковий ліс (Random Forest) є ансамблем дерев рішень, що усереднюють результати кількох моделей для зменшення варіативності. Дає високу точність, менш чутливий до шумів, проте втрачає інтерпретованість.

Гرادієнтний бустинг поступово будує послідовність слабких моделей, що коригують помилки попередніх. Дає високу точність на складних задачах, однак вимагає тривалого навчання та налаштування.

Багатошаровий перцептрон (нейронна мережа) дозволяє моделювати складні нелінійні залежності. Ефективний на великих наборах даних, але вимагає значних ресурсів і має обмежену прозорість. На рисунку 3 представлено схематичну структуру моделі багатошарового перцептрона.

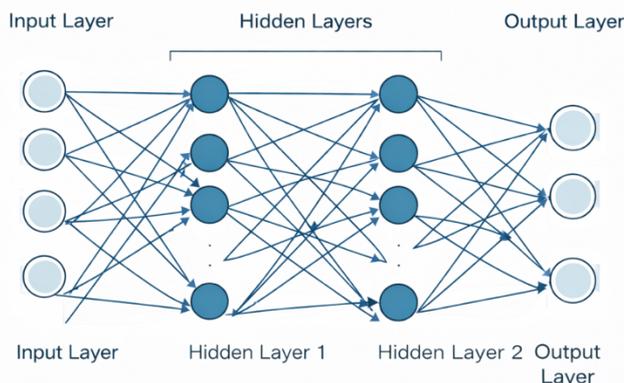


Рис. 3 – Архітектура багатошарового перцептрона

У таблиці 1 наведено порівняльну характеристику обраних алгоритмів за критеріями інтерпретованості, обчислювальної складності та вимог до даних. Це дозволяє оцінити доцільність їх використання в умовах обмежених ресурсів, різного типу бізнес-процесів і доступності фахівців для підтримки моделей.

Таблиця 1 – Порівняльна характеристика алгоритмів машинного навчання

Алгоритм	Інтерпретованість	Обчислювальна складність	Вимоги до обсягу даних
Логістична регресія	Висока	Низька	Невеликі
Дерева рішень	Висока	Середня	Середні
Random Forest	Середня	Висока	Середні
Градiєнтний бустинг	Низька	Висока	Великі
Багатошаровий перцептрон	Низька	Дуже висока	Великі

Порівняльний аналіз дозволяє сформулювати уявлення про практичну застосовність моделей ще до їх тестування, виходячи з цілей підприємства, обсягів даних та вимог до пояснюваності результатів.

Для побудови експериментального середовища були використані відкриті набори бізнес-даних, що відображають реальні сценарії ухвалення рішень з оцінюванням ризиків. Зокрема, застосовано датасет із кредитного скорингу, що містить фінансову, соціально-демографічну та

поведінкову інформацію клієнтів, а також набір транзакційних даних для виявлення шахрайства в електронній комерції. Обидва набори характеризуються наявністю змішаних типів ознак (числових і категоріальних), класовою дисбалансованістю та значною кількістю записів із пропущеними значеннями.

Попередня обробка даних включала видалення або заміну пропущених значень, категоріальне кодування, нормалізацію числових ознак та виділення цільової змінної. Для покращення якості моделювання було проведено аналіз кореляцій між ознаками, зменшення кількості параметрів за допомогою методів відбору ознак, а також балансування вибірки шляхом надсемплінгу меншості (SMOTE).

Дані були розділені на навчальну та тестову вибірки у пропорції 70/30. Для підвищення достовірності результатів використано крос-валідацію на 5 фолдах. Моделі навчались з урахуванням гіперпараметрів, що підбирались за допомогою grid search. Всі експерименти проводились у середовищі Python із використанням бібліотек scikit-learn, XGBoost та TensorFlow. Технічні характеристики обчислювальної системи: CPU Intel Core i7, 32 GB RAM, GPU NVIDIA RTX 3060.

Таблиця 2. Основні параметри моделей і середовище тестування

Параметр	Значення
Мови програмування	Python 3.10
Бібліотеки	scikit-learn, XGBoost, TensorFlow
Метод крос-валідації	5-fold
Метод оптимізації гіперпараметрів	GridSearchCV
Технічна платформа	CPU: Intel i7, RAM: 32 GB, GPU: RTX 3060
Стратегія поділу даних	Навчальна: 70%, Тестова: 30%

Отримані результати моделювання подано у вигляді ROC-кривих, що дозволяють порівняти здатність моделей відокремлювати класи. На рисунку 4 представлено порівняльні ROC-криві для всіх протестованих алгоритмів.

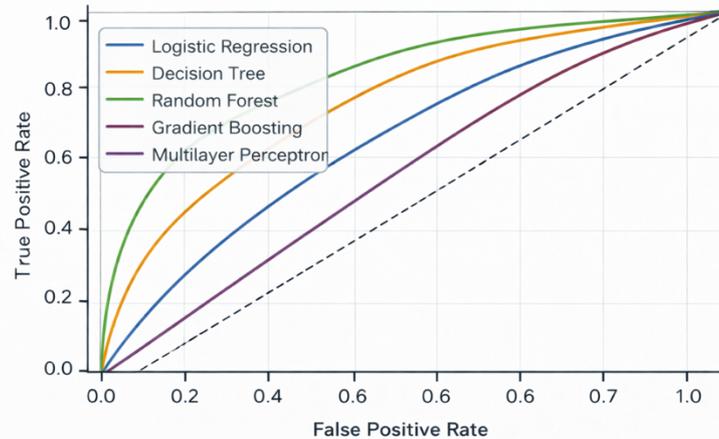


Рис.4 – Порівняння ROC-кривих для моделей логістичної регресії, дерева рішень, Random Forest, градієнтного бустингу та багатошарового перцептрона

Крім того, оцінку якості моделей виконано за метриками точності (accuracy), повноти (recall), специфічності, F1-міри та площі під ROC-кривою (AUC). Побудовано матриці неточностей для аналізу типів помилок. Це дозволяє не лише порівняти моделі між собою, а й виявити потенційно ризиковані випадки помилкової класифікації у прикладних сценаріях.

У таблиці 3 наведено узагальнені результати моделювання.

Таблиця 3. Ефективність алгоритмів за обраними метриками

Модель	Accuracy	Recall	F1-score	AUC
Логістична регресія	0.83	0.76	0.79	0.87
Дерево рішень	0.81	0.72	0.77	0.84
Random Forest	0.89	0.83	0.86	0.92
Градієнтний бустинг	0.91	0.85	0.88	0.94
Багатошаровий перцептрон	0.88	0.80	0.84	0.91

Інтерпретація результатів свідчить про перевагу ансамблевих моделей, зокрема градієнтного бустингу, для задач з високим ступенем ризику та необхідністю точного прогнозу. У той же час логістична регресія та дерева рішень демонструють задовільні результати за менших обчислювальних витрат і залишаються придатними для інтеграції в системи реального часу або в умовах обмежених ресурсів.

У бізнес-сценаріях, пов'язаних із видачею кредитів, виявленням фінансових шахрайств або оцінкою ризиків інвестицій, рекомендовано застосовувати моделі з високими значеннями AUC та F1-міри. Це дозволяє мінімізувати кількість хибнонегативних результатів, які несуть найбільшу загрозу з боку втрат.

Результати, отримані в межах експериментального дослідження, свідчать про помітну різницю в ефективності моделей. Найвищі показники точності, F1-міри та площі під ROC-кривою (AUC) продемонстрував градієнтний бустинг. Це пояснюється його здатністю послідовно враховувати помилки попередніх моделей, адаптуючись до складних патернів у даних. Випадковий ліс також виявився ефективним, особливо на даних з високою варіативністю, завдяки внутрішньому механізму усереднення.

Логістична регресія показала задовільні результати на збалансованих та лінійно розділних вибірках. Її перевага полягає в простоті реалізації, інтерпретованості та низькій чутливості до параметрів. Однак вона не враховує складних взаємозв'язків між ознаками, що обмежує її застосування в задачах з великою кількістю ознак або взаємозалежностей.

Дерева рішень є зручними для початкового аналізу через прозору логіку прийняття рішень. Проте їх чутливість до незначних змін у даних і схильність до переобучення знижують стабільність результатів. У свою чергу, багатосаровий перцептрон добре справляється з нелінійними залежностями, але вимагає тривалого навчання та не завжди забезпечує пояснюваність.

У практичних сценаріях застосування доцільно використовувати логістичну регресію для швидкого аналізу ризику в реальному часі, наприклад, при попередньому скорингу клієнтів. Random Forest і градієнтний бустинг рекомендовані для більш відповідальних задач — кредитування, інвестиційне планування або виявлення шахрайських операцій. Нейронні мережі доцільні при наявності великих обсягів даних і потребі в моделюванні складних нелінійностей, зокрема в e-commerce або персоналізованих маркетингових системах.

Запропонований підхід передбачає врахування бізнес-контексту під час вибору моделі. Так, у випадках, коли потрібна прозорість та інтерпретація для управлінського персоналу, перевагу слід віддати моделям з чіткою логікою прийняття рішень. Якщо ж головним критерієм є точність і виявлення складних залежностей, доречно використовувати більш складні моделі з регулярною валідацією.

На рисунку 5 наведено схему інтеграції моделі машинного навчання в типову бізнес-архітектуру. Вона ілюструє, як модуль ризик-аналізу на основі ML може бути вбудований у CRM-систему або інструменти для прийняття управлінських рішень.

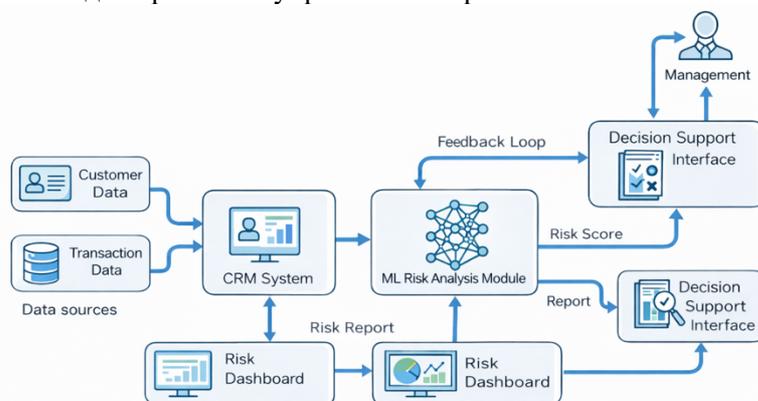


Рис. 5 – Інтеграція моделі оцінювання ризиків на основі машинного навчання в систему підтримки бізнес-рішень

Наукова новизна дослідження полягає у запропонованому підході до вибору моделей машинного навчання, який базується не лише на точності класифікації, а й на комплексному урахуванні таких факторів, як стабільність результатів, інтерпретованість, обчислювальна

складність та гнучкість адаптації до нових умов. У попередніх роботах ці критерії аналізувались переважно окремо, без спроби системного порівняння в контексті практичних бізнес-задач.

Запропонована структура оцінювання дозволяє не лише обрати найточнішу модель, а й забезпечити її придатність до впровадження в реальні інформаційні системи з урахуванням обмежень часу, ресурсів і потреб користувача. У цьому полягає її практична цінність та перевага над наявними підходами, які обмежуються суто метриками точності без врахування контексту застосування.

Висновки та перспективи подальшого дослідження. У ході дослідження було здійснено порівняльний аналіз ефективності типових алгоритмів машинного навчання для оцінювання ризиків у процесі прийняття бізнес-рішень. Визначено, що моделі ансамблевого типу, зокрема градієнтний бустинг і випадковий ліс, демонструють найвищі значення метрик якості в задачах з великою кількістю ознак і нерівномірним розподілом класів. У той же час простіші моделі, як-от логістична регресія або дерева рішень, мають переваги в інтерпретованості та швидкості обробки, що є критичним у реальному часі та обмежених обчислювальних ресурсах.

Практична цінність полягає в узагальненні критеріїв вибору алгоритмів з урахуванням специфіки бізнес-сценарію: типу даних, потреб у прозорості прийняття рішень, доступності ресурсів і необхідної точності. Запропоновано підхід до оцінки моделей, що враховує не лише традиційні метрики, а й параметри стабільності та придатності до інтеграції в управлінські процеси.

Наукова новизна полягає у формуванні комбінованої моделі вибору алгоритму машинного навчання для задач ризик-менеджменту, орієнтованої на баланс між точністю, адаптивністю та зрозумілістю моделі.

Перспективи подальших досліджень передбачають розширення експериментального середовища за рахунок галузевих кейсів, включення часових рядів і аналіз динамічних змін ризиків, а також дослідження Explainable AI-підходів для покращення пояснюваності результатів у складних нейронних структурах. Окрему увагу планується приділити автоматизації вибору моделей з урахуванням бізнес-контексту шляхом застосування мета-навчання.

Список бібліографічного опису

1. Iriani, N., Agustianti, A., Suciarti, R., Rahman, A., Putera, W. Understanding risk and uncertainty management: A qualitative inquiry into developing business strategies amidst global economic shifts, government policies, and market volatility. *Golden Ratio of Finance Management*. 2024. Vol. 4. No. 2. P. 62–77. <https://doi.org/10.52970/grfm.v4i2.444>
2. Лісовський, П. М., Лісовська, Ю. П., Романенко, С. О., Шкітов, А. А. Цифрова криптографія програмування: сучасні виклики війни. Київ. Видавництво Ліра-К. 2026. 760 с.
3. Luo, N., Yu, H., You, Z., Li, Y., Zhou, T., Jiao, Y., Qiao, S. Fuzzy logic and neural network-based risk assessment model for import and export enterprises: A review. *Journal of Data Science and Intelligent Systems*. 2023. Vol. 1. No. 1. P. 2–11. <https://doi.org/10.47852/bonviewJDSIS32021078>
4. Wang, X., Mazumder, R. K., Salarieh, B., Salman, A. M., Shafieezadeh, A., Li, Y. Machine learning for risk and resilience assessment in structural engineering: Progress and future trends. *Journal of Structural Engineering*. 2022. Vol. 148. No. 8. 03122003. [https://doi.org/10.1061/\(ASCE\)ST.1943-541X.0003392](https://doi.org/10.1061/(ASCE)ST.1943-541X.0003392)
5. Olukoya, O. Time series-based quantitative risk models: enhancing accuracy in forecasting and risk assessment. *International Journal of Computer Applications Technology and Research*. 2023. Vol. 12. No. 11. P. 29–41. DOI:10.7753/IJCATR1211.1006
6. Hsu, M. F., Hsin, Y. S., Shiue, F. J. Business analytics for corporate risk management and performance improvement. *Annals of Operations Research*. 2022. Vol. 315. No. 2. P. 629–669. <https://doi.org/10.1007/s10479-021-04259-x>
7. Lee, C. S., Cheang, P. Y. S., Moslehpour, M. Predictive analytics in business analytics: decision tree. *Advances in Decision Sciences*. 2022. Vol. 26. No. 1. P. 1–29.
8. Al-Zoubi, L., Al-Khazaleh, S., Badwan, N. Financial risk management in the supply chain using business intelligence and big data. *International Journal of Management and Business Research*. 2023. Vol. 7. No. 1. P. 1–27.
9. Dong, X., Qiu, W. A case study on the relationship between risk assessment of scientific research projects and related factors under the Naive Bayesian algorithm. *Scientific Reports*. 2024. Vol. 14. No. 1. 244. <https://doi.org/10.1038/s41598-024-58341-y>
10. Jiang, B., Cao, J., Tan, Y., Qiu, S. Deep learning architectures for sequential decision-making in financial systems: From fraud detection to risk management. *Journal of Banking and Financial Dynamics*. 2025. Vol. 9. No. 9. P. 1–11. DOI: 10.55220/2576-6821.v9.631
11. Dunka, V. AI-driven claims fraud detection using hybrid deep learning models: Integrating convolutional neural networks and recurrent neural networks for real-time fraud detection in insurance claims. *Essex Journal of AI Ethics and Responsible Innovation*. 2023. Vol. 3. P. 276–311.
12. Kavzoglu, T., Teke, A. Predictive performances of ensemble machine learning algorithms in landslide susceptibility mapping using random forest, extreme gradient boosting (XGBoost) and natural gradient boosting (NGBoost). *Arabian Journal for Science and Engineering*. 2022. Vol. 47. No. 6. P. 7367–7385. <https://doi.org/10.1007/s13369-022-06560-8>
13. Natras, R., Soja, B., Schmidt, M. Ensemble machine learning of random forest, AdaBoost and XGBoost for vertical total electron content forecasting. *Remote Sensing*. 2022. Vol. 14. No. 15. P. 3547. <https://doi.org/10.3390/rs14153547>

14. India, N. M. Exploring artificial intelligence models for early warning systems with systemic risk analysis in finance. Proceedings of the 2025 International Conference on Advanced Computing Technologies (ICoACT). 2025. P. 1–6. DOI: [10.1109/ICoACT63339.2025.11005357](https://doi.org/10.1109/ICoACT63339.2025.11005357)
15. Noriega, J. P., Rivera, L. A., Herrera, J. A. Machine learning for credit risk prediction: A systematic literature review. Data. 2023. Vol. 8. No. 11. P. 169. <https://doi.org/10.3390/data8110169>
16. Ali, R., Hussain, A., Nazir, S., Khan, S., Khan, H. U. Intelligent decision support systems: An analysis of machine learning and multicriteria decision-making methods. Applied Sciences. 2023. Vol. 13. No. 22. P. 12426. <https://doi.org/10.3390/app132212426>
17. Arena, S., Florian, E., Zennaro, I., Orrù, P. F., Sgarbossa, F. A novel decision support system for managing predictive maintenance strategies based on machine learning approaches. Safety Science. 2022. Vol. 146. P. 105529. <https://doi.org/10.1016/j.ssci.2021.105529>

References

1. Iriani, N., Agustianti, A., Sucianti, R., Rahman, A., Putera, W. Understanding risk and uncertainty management: A qualitative inquiry into developing business strategies amidst global economic shifts, government policies, and market volatility. Golden Ratio of Finance Management. 2024. Vol. 4. No. 2. P. 62–77. <https://doi.org/10.52970/grfm.v4i2.444>
2. Lisovskyy, P. M., Lisovska, Y. P., Romanenko, E. O., Shkitov, A. A. Digital cryptography of programming: modern challenges of war. Kyiv. Publishing house Lira-K. 2026. 760 p.
3. Luo, N., Yu, H., You, Z., Li, Y., Zhou, T., Jiao, Y., Qiao, S. Fuzzy logic and neural network-based risk assessment model for import and export enterprises: A review. Journal of Data Science and Intelligent Systems. 2023. Vol. 1. No. 1. P. 2–11. <https://doi.org/10.47852/bonviewJDSIS32021078>
4. Wang, X., Mazumder, R. K., Salarieh, B., Salman, A. M., Shafieezadeh, A., Li, Y. Machine learning for risk and resilience assessment in structural engineering: Progress and future trends. Journal of Structural Engineering. 2022. Vol. 148. No. 8. 03122003. [https://doi.org/10.1061/\(ASCE\)ST.1943-541X.0003392](https://doi.org/10.1061/(ASCE)ST.1943-541X.0003392)
5. Olukoya, O. Time series-based quantitative risk models: enhancing accuracy in forecasting and risk assessment. International Journal of Computer Applications Technology and Research. 2023. Vol. 12. No. 11. P. 29–41. DOI:10.7753/IJCATR1211.1006
6. Hsu, M. F., Hsin, Y. S., Shiue, F. J. Business analytics for corporate risk management and performance improvement. Annals of Operations Research. 2022. Vol. 315. No. 2. P. 629–669. <https://doi.org/10.1007/s10479-021-04259-x>
7. Lee, C. S., Cheang, P. Y. S., Moslehpour, M. Predictive analytics in business analytics: decision tree. Advances in Decision Sciences. 2022. Vol. 26. No. 1. P. 1–29.
8. Al-Zoubi, L., Al-Khazaleh, S., Badwan, N. Financial risk management in the supply chain using business intelligence and big data. International Journal of Management and Business Research. 2023. Vol. 7. No. 1. P. 1–27.
9. Dong, X., Qiu, W. A case study on the relationship between risk assessment of scientific research projects and related factors under the Naive Bayesian algorithm. Scientific Reports. 2024. Vol. 14. No. 1. 244. <https://doi.org/10.1038/s41598-024-58341-y>
10. Jiang, B., Cao, J., Tan, Y., Qiu, S. Deep learning architectures for sequential decision-making in financial systems: From fraud detection to risk management. Journal of Banking and Financial Dynamics. 2025. Vol. 9. No. 9. P. 1–11. DOI: 10.55220/2576-6821.v9.631
11. Dunka, V. AI-driven claims fraud detection using hybrid deep learning models: Integrating convolutional neural networks and recurrent neural networks for real-time fraud detection in insurance claims. Essex Journal of AI Ethics and Responsible Innovation. 2023. Vol. 3. P. 276–311.
12. Kavzoglu, T., Teke, A. Predictive performances of ensemble machine learning algorithms in landslide susceptibility mapping using random forest, extreme gradient boosting (XGBoost) and natural gradient boosting (NGBoost). Arabian Journal for Science and Engineering. 2022. Vol. 47. No. 6. P. 7367–7385. <https://doi.org/10.1007/s13369-022-06560-8>
13. Natras, R., Soja, B., Schmidt, M. Ensemble machine learning of random forest, AdaBoost and XGBoost for vertical total electron content forecasting. Remote Sensing. 2022. Vol. 14. No. 15. P. 3547. <https://doi.org/10.3390/rs14153547>
14. India, N. M. Exploring artificial intelligence models for early warning systems with systemic risk analysis in finance. Proceedings of the 2025 International Conference on Advanced Computing Technologies (ICoACT). 2025. P. 1–6. DOI: [10.1109/ICoACT63339.2025.11005357](https://doi.org/10.1109/ICoACT63339.2025.11005357)
15. Noriega, J. P., Rivera, L. A., Herrera, J. A. Machine learning for credit risk prediction: A systematic literature review. Data. 2023. Vol. 8. No. 11. P. 169. <https://doi.org/10.3390/data8110169>
16. Ali, R., Hussain, A., Nazir, S., Khan, S., Khan, H. U. Intelligent decision support systems: An analysis of machine learning and multicriteria decision-making methods. Applied Sciences. 2023. Vol. 13. No. 22. P. 12426. <https://doi.org/10.3390/app132212426>
17. Arena, S., Florian, E., Zennaro, I., Orrù, P. F., Sgarbossa, F. A novel decision support system for managing predictive maintenance strategies based on machine learning approaches. Safety Science. 2022. Vol. 146. P. 105529. <https://doi.org/10.1016/j.ssci.2021.105529>

Історія статті:

Отримано: 15.02.2026 Доопрацьовано: 27.02.2026 Прийнято до друку: 23.03.2026 Опубліковано: 29.03.2026