

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ ЕКОНОМІЧНИЙ УНІВЕРСИТЕТ ІМЕНІ
ВАДИМА ГЕТЬМАНА

Навчально-науковий інститут
«Інститут інформаційних технологій в економіці»

Кафедра системного аналізу та кібербезпеки

ОСВІТНЬО-ПРОФЕСІЙНА ПРОГРАМА «Системний аналіз»

Галузь знань 12 Інформаційні технології

Спеціальність 124 Системний аналіз

Форма навчання: денна

КВАЛІФІКАЦІЙНА БАКАЛАВРСЬКА РОБОТА

на тему:

**«Оцінювання кредитних ризиків корпоративних позичальників на
основі ансамблевих алгоритмів»**

здобувача Демченка Данііла Олександровича _____

Науковий керівник: к.ф.-м.н., доцент Позднякович О.Є. _____

**Робота допущена до захисту перед екзаменаційною комісією
з атестації здобувачів вищої освіти (ЕК)**

Завідувач кафедри: д.ф.-м.н., професор Джалладова І.А. _____

Київ 2026

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ ЕКОНОМІЧНИЙ УНІВЕРСИТЕТ
ІМЕНІ ВАДИМА ГЕТЬМАНА**

Навчально-науковий інститут «Інститут інформаційних технологій в економіці»
Кафедра системного аналізу та кібербезпеки

**ОСВІТНЬО-ПРОФЕСІЙНА ПРОГРАМА «СИСТЕМНИЙ АНАЛІЗ»
СПЕЦІАЛЬНІСТЬ 124 «СИСТЕМНИЙ АНАЛІЗ»**

ПОГОДЖЕНО

Керівник проєктної групи (гарант)
освітньо-професійної програми

«___» _____ 2026 р.

ЗАТВЕРДЖУЮ

Завідувач кафедри системного
аналізу та кібербезпеки
_____ Джалладова І.А.

«___» _____ 2026 р.

ІНДИВІДУАЛЬНЕ ЗАВДАННЯ

здобувачу вищої освіти Демченку Даніілу Олександровичу
очної (денної) форми навчання

на підготовку кваліфікаційної бакалаврської роботи

**на тему «Оцінювання кредитних ризиків корпоративних позичальників
на основі ансамблевих алгоритмів»**

Тему затверджено наказом ректора Університету від «___» _____
2026 р. № _____.

Кваліфікаційна бакалаврська робота виконується на матеріалах сучасної професійної літератури та наукових джерел, нормативно-правових актів (стандарти Basel III, Постанова НБУ № 351), а також відкритого датасету Polish Companies Bankruptcy Data.

План кваліфікаційної бакалаврської роботи

Розділ 1 Теоретико-методологічні засади аналізу кредитного ризику корпоративних позичальників

Розділ 2 Розробка методичного підходу до оцінювання кредитного ризику корпоративних клієнтів з використанням алгоритмів машинного навчання

Розділ 3 Реалізація та експериментальна валідація системи підтримки прийняття рішень оцінювання кредитного ризику

Об'єкт дослідження: процес оцінювання кредитного ризику корпоративних позичальників у банківській установі.

Предмет дослідження: ансамблеві моделі машинного навчання на основі стекінгового узагальнення та методи SHAP-інтерпретації для оцінювання ймовірності дефолту (PD) корпоративних клієнтів банку.

Мета роботи: розробка та експериментальна валідація системи оцінювання кредитних ризиків корпоративних позичальників на основі стекінгової ансамблевої моделі машинного навчання, яка забезпечує підвищену прогностичну точність оцінки ймовірності дефолту порівняно з

базовими класифікаторами та відповідає вимогам регуляторної інтерпретованості в рамках IRB-підходу Basel III.

Конкретні завдання, які здобувач повинен виконати для досягнення поставленої мети:

1. Провести системний аналіз специфіки кредитного ризику корпоративних позичальників та систематизувати чинні регуляторні вимоги (Basel III, Постанова НБУ № 351).
2. Здійснити системний аналіз факторів кредитоспроможності корпоративних клієнтів та структурувати ознаковий простір моделі.
3. Провести порівняльний аналіз класичних та сучасних методів оцінювання кредитного ризику і обґрунтувати вибір ансамблевого підходу.
4. Формалізувати задачу прогнозування дефолту корпоративного позичальника як задачу бінарної класифікації, визначити функцію втрат та критерії якості.
5. Розробити методику підготовки даних, зокрема стратегію роботи з незбалансованими класами (SMOTE, зважування класів, оптимізація порогу).
6. Сформулювати інформаційну базу дослідження, провести дослідницький аналіз даних та визначити ключові предиктори дефолту на основі датасету Polish Companies Bankruptcy Data.
7. Розробити та реалізувати дворівневу стекінгову ансамблеву модель (логістична регресія, Random Forest, XGBoost, LightGBM, MLP → мета-модель) з OOF крос-валідацією та байєсівською оптимізацією гіперпараметрів.
8. Провести порівняльну експериментальну валідацію стекінгової моделі та базових класифікаторів, виконати SHAP-аналіз та сформулювати практичні рекомендації.

У розділі 1 дослідити сутність та специфіку кредитного ризику корпоративних позичальників, провести системний аналіз факторів кредитоспроможності та класифікацію методів оцінювання кредитного ризику.

У розділі 2 формалізувати задачу оцінювання кредитного ризику як задачу бінарної класифікації, обґрунтувати систему метрик якості для незбалансованих даних та розробити методичний підхід до побудови ансамблевої моделі.

У розділі 3 реалізувати та експериментально валідувати стекінгову ансамблеву модель, провести SHAP-аналіз і сформулювати практичні рекомендації щодо впровадження.

Завдання підготував науковий керівник к.ф.-м.н., доцент Позднякович О.Є.

Завдання одержав здобувач Демченко Д.О.

РЕФЕРАТ

Кваліфікаційна бакалаврська робота містить **98 сторінок, 22 таблиці, 14 рисунків**, список використаних джерел з **59 найменувань, 5 додатків**.

«Оцінювання кредитних ризиків корпоративних позичальників на основі ансамблевих алгоритмів»

Об’єкт дослідження – процес оцінювання кредитного ризику корпоративних позичальників у банківській установі.

Предмет дослідження – ансамблеві моделі машинного навчання на основі стекінгового узагальнення та методи SHAP-інтерпретації для оцінювання ймовірності дефолту (PD) корпоративних клієнтів банку.

Мета роботи – розробка та експериментальна валідація системи оцінювання кредитних ризиків корпоративних позичальників на основі стекінгової ансамблевої моделі машинного навчання, яка забезпечує підвищену прогностичну точність оцінки ймовірності дефолту порівняно з базовими класифікаторами та відповідає вимогам регуляторної інтерпретованості в рамках IRB-підходу Basel III.

Для досягнення поставленої мети були реалізовані **такі завдання:**

1. Проведено системний аналіз специфіки кредитного ризику корпоративних позичальників та систематизовано чинні регуляторні вимоги (Basel III, Постанова НБУ №351).
2. Здійснено системний аналіз факторів кредитоспроможності корпоративних клієнтів та структуровано ознаковий простір моделі за п’ятьма аналітичними блоками.
3. Проведено порівняльний аналіз класичних та сучасних методів оцінювання кредитного ризику і обґрунтовано вибір ансамблевого підходу.
4. Формалізовано задачу прогнозування дефолту корпоративного позичальника як задачу бінарної класифікації, визначено функцію втрат та критерії якості відповідно до стандартів банківської валідації.
5. Розроблено методикку підготовки даних, зокрема стратегію роботи з незбалансованими класами (SMOTE, зважування класів, оптимізація порогу) та обробки пропущених значень.
6. Сформовано інформаційну базу дослідження, проведено дослідницький аналіз даних та визначено ключові предиктори дефолту на основі датасету Polish Companies Bankruptcy Data.
7. Розроблено та реалізовано дворівневу стекінгову ансамблеву модель (логістична регресія, Random Forest, XGBoost, LightGBM, MLP → мета-модель) з OOF крос-валідацією та байєсівською оптимізацією гіперпараметрів засобами Optuna.
8. Проведено порівняльну експериментальну валідацію стекінгової моделі та базових класифікаторів за системою метрик регуляторної валідації, виконано

SHAP-аналіз та сформульовано практичні рекомендації щодо впровадження у банківську практику.

Методи дослідження. У роботі використано методи системного аналізу, математичного моделювання, машинного навчання (логістична регресія, Random Forest, градієнтний бустинг XGBoost та LightGBM, штучні нейронні мережі), байєсівської оптимізації гіперпараметрів (Optuna), статистичного аналізу, методів роботи з незбалансованими даними (SMOTE) та теорії кооперативних ігор (SHAP) для інтерпретації прогнозів моделі.

Теоретичне значення роботи полягає в розвитку методичних засад системного аналізу кредитного ризику корпоративних позичальників, формуванні концептуальної моделі, що інтегрує сучасні методи машинного навчання з регуляторними вимогами Basel III, та узагальненні підходів до побудови стекінгових ансамблевих систем для задач фінансового прогнозування.

Методична цінність полягає у розробці відтворюваної процедури побудови стекінгової моделі кредитного скорингу, що враховує специфіку незбалансованих даних, забезпечує запобігання витоку інформації через OOF крос-валідацію та може бути адаптована для інших наборів фінансових даних корпоративного сектору.

Практична значущість дослідження полягає у створенні дієвого інструменту оцінювання ймовірності дефолту корпоративних позичальників із вбудованим механізмом SHAP-пояснення кожного кредитного рішення, що дозволяє банківським установам підвищити точність прогнозування дефолтів, оптимізувати процес прийняття кредитних рішень та забезпечити відповідність вимогам регуляторної прозорості.

Інформаційна база дослідження охоплює наукові джерела з теорії кредитного ризику, машинного навчання та системного аналізу; нормативно-правові акти (Закон України «Про банки і банківську діяльність», Постанова НБУ №351, стандарти Basel III); публічно доступний датасет Polish Companies Bankruptcy Data з платформи Kaggle, що містить фінансові показники корпоративних підприємств.

Рік виконання роботи – 2026.

Рік захисту роботи – 2026.

Ключові слова: кредитний ризик, корпоративні позичальники, машинне навчання, стекінгове узагальнення, ансамблеві моделі, незбалансовані дані, SHAP, ймовірність дефолту, Basel III.

ВІДГУК
про кваліфікаційну бакалаврську роботу
здобувача навчально-наукового інституту «Інститут інформаційних
технологій в економіці Київського національного економічного університету
ім. В. Гетьмана»
освітньо-професійної програми «Системний аналіз»
Демченка Данііла Олександровича
**на тему «Оцінювання кредитних ризиків корпоративних позичальників
на основі ансамблевих алгоритмів»**

Кваліфікаційна бакалаврська робота є ґрунтовним і завершеним дослідженням, присвяченим актуальній проблемі підвищення точності та інтерпретованості оцінювання кредитного ризику корпоративних позичальників.

В умовах посилення регуляторних вимог до банківських установ (Basel III, Постанова НБУ № 351) та зростання обсягів кредитування корпоративного сектору особливої ваги набуває задача точного й водночас прозорого прогнозування ймовірності дефолту позичальників. Саме цим обумовлена актуальність обраної теми.

Структура роботи є логічною та послідовною, вимоги до написання кожного розділу дотримані. У першому розділі здійснено системний аналіз сутності кредитного ризику корпоративних позичальників, структуровано ознаковий простір та проведено порівняльний аналіз класичних і сучасних методів оцінювання кредитоспроможності, що дозволило обґрунтувати вибір ансамблевого підходу.

У другому розділі формалізовано задачу прогнозування дефолту як задачу бінарної класифікації, обґрунтовано систему метрик якості для незбалансованих даних та розроблено методичний підхід до побудови ансамблевої моделі.

У третьому розділі реалізовано та експериментально валідовано дворівневу стекінгову ансамблеву модель (логістична регресія, Random Forest, XGBoost, LightGBM, MLP та мета-модель) із застосуванням OOF крос-валідації, байєсівської оптимізації гіперпараметрів засобами Optuna, методів роботи з незбалансованими даними (SMOTE) та SHAP-аналізу для інтерпретації рішень. Отримані результати засвідчили підвищення прогностичної точності запропонованої моделі порівняно з базовими класифікаторами.

Особливої уваги заслуговує вдале поєднання сучасних методів машинного навчання з вимогами регуляторної інтерпретованості, що надає роботі прикладного характеру та можливості впровадження у банківську практику. Здобувач продемонстрував здатність до самостійної дослідницької

роботи, глибоке розуміння предметної області та володіння сучасним інструментарієм аналізу даних.

Суттєвих недоліків не встановлено.

Кваліфікаційна бакалаврська робота в цілому відповідає вимогам і допускається до захисту перед екзаменаційною комісією, а її автору Демченку Д.О. може бути присвоєний ступінь бакалавра зі спеціальності 124 «Системний аналіз».

Науковий керівник

доцент кафедри системного аналізу та кібербезпеки,
кандидат фізико-математичних наук, доцент

Позднякович О.Є.

«___» червня 2026 р.

РЕЦЕНЗІЯ
на кваліфікаційну бакалаврську роботу
здобувача вищої освіти
Демченка Данііла Олександровича
групи ІА-401

Тема: «Оцінювання кредитних ризиків корпоративних позичальників на основі ансамблевих алгоритмів»

Актуальність теми дослідження і доцільність її розроблення: Обрана тема є надзвичайно актуальною в умовах посилення регуляторних вимог до управління кредитним ризиком та зростання обсягів корпоративного кредитування. Точне й інтерпретоване оцінювання ймовірності дефолту корпоративних позичальників є критично важливим завданням для банківських установ, а застосування сучасних ансамблевих методів машинного навчання відповідає світовим тенденціям розвитку кредитного скорингу. Дослідження має виражену практичну спрямованість і відповідає вимогам до робіт прикладного характеру у сфері системного аналізу.

Якість проведеного дослідження: Робота вирізняється високим рівнем теоретичної підготовки та практичного обґрунтування обраної теми. Автор послідовно розкриває сутність кредитного ризику, систематизує регуляторні вимоги (Basel III, Постанова НБУ № 351) та обґрунтовує вибір ансамблевого підходу. У практичній частині реалізовано дворівневу стекінгову модель із застосуванням алгоритмів XGBoost, LightGBM, Random Forest та нейронної мережі, методів балансування класів (SMOTE) та інтерпретації результатів (SHAP). Робота структурована, ілюстрована таблицями та рисунками, має чітко сформульовані висновки.

Позитивні риси кваліфікаційної бакалаврської роботи: Передусім варто відзначити комплексний підхід до вирішення задачі, що поєднує теоретичні та прикладні аспекти. Автор ефективно застосував сучасний інструментарій машинного навчання та байєсівської оптимізації гіперпараметрів, забезпечив запобігання витоку інформації через OOF крос-валідацію, а також реалізував механізм SHAP-пояснення кредитних рішень, що підвищує відповідність моделі вимогам регуляторної прозорості. Логіка викладу матеріалу — від постановки проблеми до обґрунтованих висновків і рекомендацій — витримана послідовно.

Зауваження:

1. Доцільно було б детальніше розкрити обмеження використаного датасету та можливості його адаптації до умов українського банківського сектору.
2. У частині практичних рекомендацій варто було б навести орієнтовні розрахунки економічного ефекту від впровадження запропонованої моделі.

3. Для повноти порівняльного аналізу можливо було б додати зведену таблицю обчислювальних витрат базових та ансамблевої моделей.

Практична значимість висновків і рекомендацій: Результати дослідження мають практичне значення та можуть бути використані банківськими установами для підвищення точності оцінювання кредитного ризику корпоративних позичальників, оптимізації процесу прийняття кредитних рішень та забезпечення відповідності вимогам регуляторної прозорості.

Кваліфікаційна бакалаврська робота виконана на належному теоретичному та практичному рівні, відповідає поставленому завданню та має важливе прикладне значення. Рекомендую оцінити її на «відмінно» та присвоїти автору кваліфікацію «бакалавр» зі спеціальності 124 «Системний аналіз».

Рецензент

Професор кафедри штучного інтелекту,
моделювання та статистики

КНЕУ імені Вадима Гетьмана,
кандидат економічних наук

Ващаєв С. С.

Місце печатки організації, де працює рецензент

(Підпис)

Дата: _____

ЗМІСТ

ВСТУП.....	4
РОЗДІЛ 1	12
ТЕОРЕТИКО-МЕТОДОЛОГІЧНІ ЗАСАДИ АНАЛІЗУ КРЕДИТНОГО РИЗИКУ КОРПОРАТИВНИХ ПОЗИЧАЛЬНИКІВ.....	12
1.1. Сутність та специфіка кредитного ризику корпоративних позичальників	
12	
1.2. Системний аналіз факторів оцінювання кредитоспроможності корпоративних клієнтів	21
1.3. Класифікація методів оцінювання кредитного ризику: від класичних до сучасних підходів	27
Висновки до розділу 1	31
РОЗДІЛ 2	34
РОЗРОБКА МЕТОДИЧНОГО ПІДХОДУ ДО ОЦІНЮВАННЯ КРЕДИТНОГО РИЗИКУ КОРПОРАТИВНИХ КЛІЄНТІВ З ВИКОРИСТАННЯМ АЛГОРИТМІВ МАШИННОГО НАВЧАННЯ	34
2.1 Формальна постановка задачі оцінювання кредитного ризику корпоративних клієнтів як задачі бінарної класифікації	34
2.2 Обґрунтування вибору методів машинного навчання для прогнозування кредитного ризику	40
2.3 Система метрик якості класифікації для незбалансованих даних	48
2.4 Розробка моделі оцінювання кредитного ризику на основі ансамблевих алгоритмів	55
Висновки до розділу 2	63
РОЗДІЛ 3	65

РЕАЛІЗАЦІЯ ТА ЕКСПЕРИМЕНТАЛЬНА ВАЛІДАЦІЯ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ ОЦІНЮВАННЯ КРЕДИТНОГО РИЗИКУ	65
3.1 Вибір інформаційної бази дослідження та її основних характеристик 65	
3.2 Розвідувальний аналіз даних та підготовка інформаційної бази до навчання ансамблевої стекінгової моделі.....	71
3.3. Реалізація стекінгової ансамблевої моделі оцінювання кредитного ризикy	78
3.4. Результати експериментальної валідації, порівняльний аналіз та практичні рекомендації.....	84
Висновки до розділу 3	94
ВИСНОВКИ.....	96
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ.....	99
ДОДАТКИ.....	99

ВСТУП

Актуальність теми. В умовах структурної трансформації банківського сектору України, наростання макроекономічної невизначеності та посилення регуляторних вимог до капіталу та резервування питання ефективного управління кредитними ризиками набуває стратегічного значення для забезпечення фінансової стійкості банківської системи [7, 15]. Особливої гостроти ця проблема набуває у сегменті корпоративного кредитування, що є ключовим джерелом фінансування реального сектору економіки та водночас основному генераторі кредитних втрат для банківських установ [1, 17].

Забезпечення ефективного управління кредитними ризиками є одним із ключових завдань сучасної банківської системи, оскільки саме кредитний ризик традиційно залишається основним джерелом фінансових втрат банківських установ. В умовах макроекономічної нестабільності, зростання невизначеності господарського середовища, наслідків воєнних дій та посилення регуляторних вимог до капіталу питання підвищення точності оцінювання кредитоспроможності позичальників набуває особливої актуальності. Надійне прогнозування ризику дефолту корпоративних клієнтів є важливою передумовою забезпечення фінансової стійкості банків, підтримання належного рівня резервування та ефективного розподілу кредитних ресурсів.

Особливе значення проблема оцінювання кредитного ризику має у сфері корпоративного кредитування, яке відіграє провідну роль у фінансуванні реального сектору економіки та водночас характеризується високим рівнем концентрації ризиків. Помилки в оцінюванні фінансового стану корпоративних позичальників можуть призводити до формування проблемної заборгованості, збільшення частки непрацюючих кредитів, зниження прибутковості банків та погіршення показників їх фінансової надійності. У зв'язку з цим зростає потреба у впровадженні сучасних інструментів аналізу даних, здатних забезпечити більш точне виявлення потенційно ризикових позичальників на ранніх стадіях.

Традиційні методи оцінювання кредитного ризику, засновані на фінансових коефіцієнтах, експертних оцінках, логістичній регресії та скорингових моделях, широко застосовуються у банківській практиці та регуляторних процедурах. Проте їх використання супроводжується низкою обмежень. Зокрема, такі підходи часто ґрунтуються на припущеннях щодо лінійності взаємозв'язків між показниками, тоді як фінансовий стан підприємства формується під впливом складних багатфакторних процесів і нелінійних залежностей. У результаті традиційні моделі не завжди забезпечують необхідний рівень прогностичної точності в умовах високої складності та неоднорідності корпоративних даних.

Стрімкий розвиток технологій штучного інтелекту та машинного навчання відкриває нові можливості для вдосконалення систем оцінювання кредитного ризику. Особливу увагу дослідників і практиків привертають ансамблеві алгоритми, зокрема Random Forest, XGBoost та LightGBM, які демонструють високу ефективність при роботі з багатовимірними фінансовими даними та здатні виявляти складні нелінійні закономірності між фінансовими показниками підприємств. Використання таких алгоритмів дозволяє підвищити точність прогнозування дефолтів, покращити якість раннього виявлення проблемних позичальників та знизити рівень кредитних втрат.

Водночас практичне впровадження моделей машинного навчання у процеси кредитного ризик-менеджменту потребує вирішення проблеми їх інтерпретованості та відповідності регуляторним вимогам. Сучасні стандарти банківського нагляду, зокрема підходи Basel III та внутрішні рейтингові системи оцінювання ризиків, передбачають необхідність обґрунтування рішень щодо присвоєння кредитних рейтингів і прогнозування дефолтів. У зв'язку з цим особливого значення набувають методи пояснюваного штучного інтелекту, які забезпечують можливість аналізу факторів, що найбільше впливають на прогноз моделі.

Незважаючи на значну кількість досліджень у сфері кредитного скорингу та прогнозування банкрутства підприємств, питання комплексного порівняння сучасних ансамблевих алгоритмів, оцінювання їхньої прогностичної ефективності та інтерпретації отриманих результатів у контексті управління кредитними ризиками корпоративних позичальників залишаються недостатньо дослідженими. Це визначає актуальність обраної теми та зумовлює необхідність подальшого розвитку методичних підходів до оцінювання кредитних ризиків на основі сучасних технологій машинного навчання.

Аналіз останніх досліджень і публікацій. Фундаментальні засади кількісного оцінювання кредитного ризику закладено в класичних роботах з прогнозування корпоративного банкрутства. Е. Altman (1968) [22] розробив п'ятифакторну Z-score модель на основі лінійного дискримінантного аналізу, яка досі слугує еталоном для порівняння нових методів. З іншої точки зору досліджує ризики кредитування корпоративних клієнтів R. Merton (1974) [43]. Запропонована ним структурна модель пояснює дефолт підприємства через теорію опціонного ціноутворення та закладає теоретичне підґрунтя для ринково-орієнтованих підходів до оцінювання ймовірності дефолту.

Регуляторну основу сучасних систем внутрішнього рейтингування було сформовано у стандартах Basel III [3], що зобов'язують банки будувати власні моделі оцінювання *PD*, *LGD* та *EAD*¹.

Регуляторну основу сучасних систем внутрішнього рейтингування формують стандарти Basel [3], що зобов'язують банки розробляти та валідувати власні статистичні моделі для оцінювання трьох ключових параметрів кредитного ризику: ймовірності дефолту.

¹ *PD* – ймовірності дефолту (*Probability of Default*), частки збитків у разі дефолту (*LGD*, *Loss Given Default*), обсяг зобов'язань на момент дефолту (*EAD*, *Exposure at Default*)

В Україні відповідну нормативну базу сформовано Постановою НБУ №351 (2016) [2], яка визначає порядок класифікації кредитних операцій та розрахунку резервів під кредитний ризик, та Законом «Про банки і банківську діяльність» [1], що встановлює загальні правові засади функціонування банківської системи.

Питання практичного застосування IRB-підходу в реаліях вітчизняного ринку знайшли відображення у наукових працях О. Крухмалю та О. Криклія [11], які дослідили методологічні засади побудови внутрішніх рейтингових систем, Л. Примостки та О. Лисенка [17], що систематизували сучасні технології оцінювання кредитоспроможності корпоративних позичальників, а також В. Ковальчука та А. Зінкевича [10], які проаналізували можливості застосування методів машинного навчання для моделювання кредитного ризику в банківській сфері.

У сфері застосування машинного навчання до задач кредитного скорингу визначальними є дослідження Lessmann et al. (2015) [45]. Автори порівняли понад 40 ML-методів і підтвердили системну перевагу ансамблевих підходів над традиційними статистичними моделями.

Автори дослідження [58] сформували датасет Polish Companies Bankruptcy Data та продемонстрували ефективність бустингових ансамблів для задач корпоративного банкрутства. Принципи стекінгового узагальнення було описано у фундаментальній роботі D. Wolpert (1992) [57], а алгоритми XGBoost [28] та LightGBM [39] стали стандартними інструментами для структурованих фінансових даних завдяки поєднанню регуляризованого бустингу з другим порядком оптимізації та високої обчислювальної ефективності.

Проблему незбалансованості класів, характерну для задач кредитного скорингу, досліджено у роботах F. Louzada et al. [47] та G. Lemaître et al. [44] (авторів методу SMOTE та бібліотеки imbalanced-learn). Методологію SHAP-інтерпретації ML-моделей розроблено S. Lundberg та S. Lee [48] на основі апарату теорії кооперативних ігор, а практику байєсівської оптимізації гіперпараметрів – T. Akiba et al. у рамках фреймворку Optuna [21]. Питання регуляторної валідації через

ROC-AUC, KS-статистику та Brier Score детально висвітлено у Т. Fawcett [33] та S. Lessmann et al. [45].

Незважаючи на значний науковий доробок у цих напрямках, залишається недостатньо розробленою проблема комплексного застосування стекінгових ансамблевих моделей з механізмами SHAP-інтерпретації саме для корпоративного сегменту кредитування. Це зумовило мету та завдання дипломної роботи.

Мета і завдання дослідження. Метою бакалаврської кваліфікаційної роботи є розробка та експериментальна валідація системи оцінювання кредитних ризиків корпоративних позичальників на основі стекінгової ансамблевої моделі машинного навчання, яка забезпечує підвищену прогностичну точність оцінки ймовірності дефолту порівняно з базовими класифікаторами та відповідає вимогам регуляторної інтерпретованості в рамках IRB-підходу Basel III.

Для досягнення поставленої мети визначено такі завдання:

1. Дослідити специфіку кредитного ризику корпоративних позичальників, та з'ясувати його структуру.
2. Провести системний аналіз факторів кредитоспроможності корпоративних клієнтів на підставі аналізу ліквідності, фінансової стійкості, рентабельності, ділова активності, покриття боргу тощо.
3. Здійснити порівняння класичних та сучасних методів оцінювання кредитного ризику та обґрунтувати вибір ансамблевого підходу.
4. Формалізувати задачу прогнозування дефолту корпоративного позичальника як задачу бінарної класифікації, визначити функцію втрат, обмеження системи та критерії якості відповідно до стандартів банківської валідації.
5. Розробити та обґрунтувати методику підготовки даних, що включає стратегію роботи з незбалансованими класами (SMOTE, class_weight, оптимізація порогу), обробки пропусків та нормалізації фінансових коефіцієнтів.

6. Сформувати інформаційну базу дослідження, провести EDA та визначити ключові предиктори дефолту на основі датасету Polish Companies Bankruptcy Data.

7. Розробити та реалізувати ансамблеву модель оцінки кредитних ризиків корпоративних позичальників на основі ансамблевих алгоритмів.

8. Провести порівняльну експериментальну валідацію стекінгової моделі та базових класифікаторів за системою з семи метрик (ROC-AUC, Gini, KS, PR-AUC, F₂, Brier Score, BSS), виконати SHAP-аналіз та сформулювати практичні рекомендації щодо впровадження у банківську практику.

Об'єктом дослідження є процес оцінювання кредитного ризику корпоративних позичальників у банківській установі як складна динамічна система.

Предметом дослідження є ансамблеві моделі машинного навчання на основі стекінгового узагальнення та методи SHAP-інтерпретації для оцінювання ймовірності дефолту (*PD*) корпоративних клієнтів банку.

Методи дослідження. У роботі використано комплекс загальнонаукових та спеціальних методів системного аналізу:

- *декомпозиції та агрегування* – для розбиття фінансового стану підприємства на п'ять аналітичних блоків кредитоспроможності та синтезу інтегральної оцінки ризику;
- *математичного моделювання* – для формалізації задачі оцінювання *PD* як задачі бінарної класифікації з функцією втрат бінарної крос-ентропії;
- *машинного навчання* (логістична регресія, Random Forest, XGBoost, LightGBM, MLP, стекінгове узагальнення) – для реалізації моделі оцінювання кредитного ризику;
- *байєсівської оптимізації* (Optuna, ТРЕ-алгоритм) – для ефективного пошуку оптимальних гіперпараметрів базових класифікаторів;
- *статистичного аналізу* (EDA, кореляційний аналіз, тести Манна-Уїтні) – для дослідницького аналізу даних та перевірки статистичних гіпотез;

- *теорії кооперативних ігор* (значення Шеплі, SHAP) – для інтерпретації прогнозів стекінгової моделі та забезпечення регуляторної прозорості;
- *порівняльного аналізу* – для зіставлення якості базових класифікаторів та стекінгової моделі за системою метрик банківської валідації.

Інформаційна база дослідження. Основою емпіричного дослідження є датасет *Polish Companies Bankruptcy Data* [38, 58] – набір даних про фінансові показники польських підприємств за 2000-2013 рр., що містить близько 43 тис. спостережень, 64 фінансові коефіцієнти та бінарну цільову змінну (банкрутство/платоспроможність) у п'яти річних зрізах. Датасет опублікований у репозиторіях UCI ML Repository та Kaggle [38] та широко використовується у бенчмаркінгових дослідженнях [45, 58].

Неможливість використання реальних банківських кредитних даних зумовлена нормами Закону України «Про банки і банківську діяльність» [1] щодо банківської таємниці. Нормативно-правову базу дослідження складають Постанова НБУ №351 (2016) [2], вимоги Basel III [3] та міжнародні стандарти фінансової звітності. Теоретична база представлена монографіями, науковими статтями у фахових виданнях та матеріалами конференцій за переліком 59 джерел.

Практичне значення отриманих результатів. Розроблена ансамблева модель може бути використана банківськими установами як компонент внутрішньої рейтингової системи (IRB) для автоматизованого оцінювання ймовірності дефолту корпоративних позичальників. Запропонована двоступенева архітектура прийняття рішень (автоматичне схвалення при $PD < 0,15$, відмова при $PD > 0,55$, розгляд кредитним комітетом при $0,15 \leq PD \leq 0,55$) з SHAP Waterfall Plot для кожного рішення забезпечує регуляторну прозорість, сумісну з вимогами Basel III. Час інференсу ²менше 50 мс дозволяє інтегрувати систему у реальний процес

² Час інференсу – це проміжок часу, потрібний навченій моделі машинного навчання (або ШІ) для обробки вхідних даних (запиту) і генерації вихідного результату (відповіді, прогнозу або рішення) після завершення її навчання.

кредитного андерайтингу без суттєвого впливу на швидкість обслуговування клієнтів.

Структура та обсяг роботи. Бакалаврська кваліфікаційна робота складається зі вступу, трьох розділів, висновків, переліку джерел (59 найменувань) та додатків. Загальний обсяг роботи: ____ сторінок. Основний зміст викладено на ____ сторінках. Робота містить ____ рисунки, ____ таблиць.

У **першому розділі** «Теоретико-методологічні засади аналізу кредитних ризиків корпоративних клієнтів банку» здійснено системний аналіз сутності кредитного ризику, факторів кредитоспроможності та еволюції методів оцінювання.

У **другому розділі** «Розробка методичного підходу до оцінювання кредитного ризику корпоративних клієнтів з використанням алгоритмів машинного навчання» формалізовано задачу класифікації, обґрунтовано вибір базових класифікаторів та стратегій роботи з незбалансованістю, розроблено систему метрик якості та архітектуру стекінгової моделі з OOF крос-валідацією, Optuna та SHAP.

У **третьому розділі** «Реалізація та експериментальна валідація системи аналізу кредитних ризиків» описано інформаційну базу, результати EDA, реалізацію пайплайну в середовищі Google Colaboratory та проведено порівняльну валідацію моделей з SHAP-аналізом і практичними рекомендаціями щодо впровадження.

РОЗДІЛ 1

ТЕОРЕТИКО-МЕТОДОЛОГІЧНІ ЗАСАДИ АНАЛІЗУ КРЕДИТНОГО РИЗИКУ КОРПОРАТИВНИХ ПОЗИЧАЛЬНИКІВ

1.1. Сутність та специфіка кредитного ризику корпоративних позичальників

Банківська система будь-якої країни з ринковою економікою тримається на двох опорах: довірі вкладників і здатності банків розпоряджатися залученими коштами без надмірних втрат. Кредитна діяльність є головним джерелом доходів більшості банківських установ, але водночас є основним генератором ризику. В умовах, коли регуляторний тиск посилюється, а частка непрацюючих кредитів (*NPL*) у корпоративних портфелях українських банків залишається хронічно високою, питання теоретичного осмислення природи кредитного ризику набуває не лише академічного, а й цілком прикладного значення [6, 47].

Кредитний ризик – це ймовірність виникнення у банку фінансових втрат через те, що позичальник не виконав або виконав неналежним чином свої зобов'язання: не повернув основний борг, не сплатив відсотки у встановлений строк або порушив інші умови договору. За оцінками НБУ, саме цей вид ризику відповідає за понад 70% сукупних збитків банківського сектору України в кризові роки [6, 15, 54]. Жодна інша категорія ризику не має настільки прямого й масштабного впливу на фінансові результати банківської установи.

Варто розрізняти кредитний ризик і суміжні категорії. Ринковий ризик виникає через коливання процентних ставок, валютних курсів чи ринкових цін на активи, тому він не залежить від поведінки конкретного контрагента. Операційний ризик пов'язаний із внутрішніми збоями: помилками персоналу, відмовами систем або зовнішніми подіями. Кредитний ризик, на відміну від них, є контрагентним: він матеріалізується лише тоді, коли певний позичальник не виконує своїх договірних зобов'язань [3, 18, 47].

З погляду системного аналізу кредитний ризик посідає центральне місце в ієрархії банківських ризиків. Його реалізація здатна запустити ланцюгову реакцію: скорочення надходжень від позичальників підриває ліквідність банку, вимушений розпродаж активів провокує ринковий ризик, а перевантаження підрозділів реструктуризації посилює операційний ризик [7, 18]. Через цей мультиплікаційний ефект точна оцінка кредитного ризику є передумовою стійкості банківської установи загалом.

Сучасна теорія кредитного ризику виходить за межі простого поняття "дефолт як факт несплати боргу". Ширший погляд охоплює будь-яке суттєве погіршення кредитної якості позичальника, навіть якщо формального дефолту ще не відбулося. Саме на цьому розширеному розумінні побудовані сучасні рейтингові системи, що оперують не дискретними категоріями, а неперервною шкалою ймовірності дефолту (*Probability of Default, PD*) [3, 45, 51].

Класифікація кредитного ризику охоплює кілька вимірів. За рівнем агрегування виокремлюють індивідуальний ризик (конкретного позичальника або угоди) і портфельний (сукупності кредитних вкладень). За характером прояву розрізняють ризик дефолту, міграційний ризик (погіршення рейтингу без дефолту) та ризик концентрації.

За часовим горизонтом розрізняють *поточний* і *потенційний* ризик. Ця класифікація має не лише теоретичне значення: вона надає логіку побудови аналітичних і модельних інструментів, які розглядатимуться в наступних підрозділах.

Кількісне вимірювання кредитного ризику спирається на методологічну основу, що була закріплена Базельським комітетом з банківського нагляду в угоді Basel II та розвинута в Basel III [3]. Ці угоди роблять акцент на трьох параметрах: ймовірність дефолту (*Probability of Default, PD*), питомі втрати у разі дефолту (*Loss Given Default, LGD*) та величину вимог під ризиком на момент дефолту (*Exposure at Default, EAD*).

Ймовірність дефолту (PD) – це оцінка того, наскільки ймовірно, що позичальник не виконає зобов'язання протягом установленого горизонту (як правило, одного року). *PD* є ндивідуальною характеристикою: вона залежить від фінансового стану підприємства, його кредитної історії, галузевої позиції та низки інших факторів. Значення *PD* варіюється від майже нульових для найнадійніших корпоративних позичальників до 100% для тих, хто вже перебуває у стані дефолту. Саме *PD* є центральним об'єктом моделювання у цьому дослідженні [3, 51].

Питомі втрати у разі дефолту (LGD) характеризують, яка частка вимог банку не буде відшкодована після настання дефолту – з урахуванням вартості забезпечення, витрат на стягнення та часового фактору дисконтування. Для незабезпечених корпоративних кредитів у міжнародній практиці *LGD* здебільшого знаходиться в діапазоні 40-60% [3, 45].

Величина вимог під ризиком (EAD) – це загальна сума кредитних вимог банку до позичальника на очікуваний момент настання дефолту. Для балансових позицій *EAD* зазвичай збігається з залишком заборгованості. Для позабалансових інструментів (кредитних ліній, гарантій) *EAD* розраховується з урахуванням коефіцієнта кредитної конверсії (*CCF*), що відображає ймовірність фактичного використання ліміту до дефолту [3].

На основі трьох зазначених параметрів можна обчислити очікуваний кредитний збиток (*Expected Loss, EL*) – базову метрику для формування резервів:

$$EL = PD \times LGD \times EAD, \quad (1.1)$$

де *EL* – очікуваний кредитний збиток; *PD* – ймовірність дефолту; *LGD* – питомі втрати у разі настання дефолту; *EAD* – величина вимог під ризиком на момент дефолту.

Формула (1.1) є нормативно закріпленою в Basel III та може бути основою для розрахунку як регуляторного капіталу банку, так і резервів під очікувані кредитні збитки відповідно до МСФЗ 9 [3, 47]. Очікувані збитки покриваються резервами, тоді як неочікувані збитки (*Unexpected Loss, UL*) (волатильність

фактичних втрат навколо очікуваного рівня) покриваються капіталом. Звідси прослідковується пряма залежність: більш точна оцінка PD означає вищий обсяг резервів і капіталу, що безпосередньо впливає на рентабельність і конкурентоспроможність банку [3, 45, 51].

Basel III передбачає два принципово різних підходи до розрахунку регуляторного капіталу під кредитний ризик. *Стандартизований підхід (SA)* використовує фіксовані вагові коефіцієнти ризику, встановлені регулятором залежно від категорії позичальника та наявності зовнішнього рейтингу.

Підхід на основі *внутрішніх рейтингів (IRB)* дозволяє банкам застосовувати власні моделі оцінки компонентів ризику, що дає можливість точніше враховувати реальний ризик конкретного позичальника [3, 11].

IRB-підхід існує у двох модифікаціях. При спрощеному варіанті (*F-IRB*) банк самостійно оцінює лише PD , тоді як LGD , EAD і строк до погашення встановлює регулятор. Розширений варіант (*A-IRB*) передбачає самостійну оцінку всіх чотирьох компонентів, але й висуває значно вищі вимоги до якості даних, точності моделей та їх незалежної валідації [3, 11, 45].

Базельський комітет встановлює конкретні вимоги до моделей PD у рамках *IRB*: мінімальний спостережний горизонт не менше п'яти років (що охоплює щонайменше один повний економічний цикл), регулярне бек-тестування прогнозних значень PD та обов'язкова інтеграція рейтингів у кредитний процес.

Остання вимога відома як "use test" (тест реального використання): модель вважається валідною лише тоді, коли вона реально застосовується при видачі кредитів, встановленні лімітів і ціноутворенні, а не існує лише "для галочки" при розрахунку капіталу [3, 11]. Саме ця вимога визначає необхідність забезпечення інтерпретованості ML-моделей.

На рис. 1.1 деталізовано компонентну структуру очікуваних кредитних втрат, що формалізовано формулою (1.1). Верхній рівень схеми розкриває економічний зміст кожного множника: PD оцінюється внутрішньою рейтинговою моделлю

(*IRB*) або стандартизованим підходом (*SA*) на горизонті одного року; *LGD* для незабезпечених корпоративних кредитів типово становить 40-60% залежно від наявності застави та витрат на стягнення заборгованості; *EAD* охоплює як балансові позиції (залишок основного боргу), так і позабалансові зобов'язання, що перераховуються через коефіцієнт кредитної конверсії (*CCF*).

Нижній блок схеми ілюструє практичне застосування показника *EL* у регуляторних цілях: очікувані втрати покриваються резервами згідно з МСФЗ 9 та класифікацією кредитних операцій за Постановою НБУ №351, тоді як неочікувані збитки (*UL*) (волатильність навколо очікуваного значення) покриваються регуляторним капіталом банку відповідно до вимог Basel III.

Це розмежування є принциповим для розуміння того, чому точність оцінки *PD* безпосередньо впливає на розмір резервів, що банк зобов'язаний формувати під кожен кредитний актив.




Рис. 1.1 – Компонентна структура очікуваних кредитних втрат. Джерело: побудовано автором на основі [3, 6, 18, 47, 51]

Корпоративний кредитний ризик має суттєву специфіку порівняно з роздрібним.

По-перше, підприємства з різних галузей, масштабів та стадій розвитку мають принципово різні фінансові профілі.

По-друге, окремий корпоративний дефолт може мати суттєвий вплив на фінансові результати банку, на відміну від роздрібного портфеля, де збитки від одного позичальника є не значним.

По-третє, структури забезпечення в корпоративному кредитуванні (нерухомість, обладнання, корпоративні права, контрактні вимоги) є більш складними в оцінці та реалізації [6, 45].

Ризик концентрації є однією з найбільш вагомих специфічних рис корпоративного кредитного портфеля. Якщо в роздрібному сегменті диверсифікація виникає природно через велику кількість дрібних позичальників, то корпоративний портфель нерідко концентрується навколо кількох великих клієнтів або груп пов'язаних осіб.

Норматив НБУ Н7, встановлений на рівні 25% регуляторного капіталу, покликаний стримувати цей ризик. Однак практика українських банків свідчить, що саме концентраційний ризик у сегменті пов'язаного кредитування неодноразово ставав одним із тригерів системних криз [6, 54].

Серйозною проблемою залишається асиметрія інформації: підприємства застосовують різні облікові політики, можуть не оприлюднювати консолідовану звітність або складати звіти насамперед з метою податкової оптимізації, а не заради реальної прозорості. В Україні ця проблема особливо гостра: чимало корпоративних позичальників не проходять обов'язкового аудиту, що суттєво ускладнює об'єктивну оцінку їхнього фінансового стану [47, 51].

Регуляторну основу оцінювання кредитного ризику в Україні становить Постанова НБУ №351 "Про затвердження Положення про визначення банками України розміру кредитного ризику за активними банківськими операціями". Цей документ визначає обов'язковий порядок класифікації кредитних операцій, методику розрахунку резервів під очікувані кредитні збитки (відповідно до принципів МСФЗ 9) та вимоги до банківських систем оцінки ризику [6, 42].

Дефолт відповідно до Постанови №351 настає при виконанні принаймні однієї з умов: прострочення погашення понад 90 днів; суттєве погіршення фінансового стану, що свідчить про неможливість виконання зобов'язань; порушення провадження у справі про банкрутство; реструктуризація боргу через фінансові труднощі позичальника. Ці критерії загалом відповідають підходам Базельського комітету, хоча окремі аспекти, зокрема, порядок обліку реструктуризованих кредитів, продовжують узгоджуватися з міжнародними стандартами [6, 42, 53].

Ситуація з *NPL* в банківській системі України є однією із найбільш красномовних індикаторів накопиченого кредитного ризику. До початку 2022 року цей показник знизився до 35-37%, однак повномасштабне вторгнення Росії у лютому 2022 року запустило новий цикл зростання *NPL* через руйнування виробничих активів, розрив ланцюгів постачання та погіршення платоспроможності корпоративних позичальників [6, 54].

Структурні причини високого *NPL* в Україні добре відомі – це слабе право застосування при реалізації застав, непрозорість корпоративного управління, практика кредитування пов'язаних осіб у частині банків, надмірна галузева концентрація (металургія, агросектор, нерухомість). Проте є й методологічний вимір проблеми: незбалансованість вибірок при навчанні моделей *PD*, тому ситуація, коли дефолтних спостережень стає порівняно багато або навіть більше, ніж "здорових", що є прямою протилежністю типовій для розвинених ринків і потребує специфічних методів роботи з даними [10, 54].

Підсумовуючи, специфіка корпоративного кредитного ризику в Україні визначається взаємодією загальносвітових закономірностей і унікальних національних чинників – хронічно високого *NPL*, воєнного ризику, недосконалого правозастосування та макроекономічної нестабільності.

Цей контекст робить завдання прогнозування дефолту надзвичайно складним і важливим, що зумовлює застосування сучасних методів машинного та глибокого навчання [6, 10, 51].

Систематизацію класифікаційних ознак кредитного ризику наведено в Табл.1.1.

На рисунку 1.2 наведено трирівневу систему детермінант кредитного ризику корпоративного позичальника, що відображає логіку формування ймовірності дефолту *PD*.

Верхній рівень (макросередовище) охоплює зовнішні макроекономічні чинники: динаміку ВВП, інфляцію та процентні ставки, валютний курс, геополітичні ризики та доступність капіталу, які формують загальні умови функціонування економіки і опосередковано впливають на фінансовий стан усіх підприємств галузі.

Середній рівень (галузево-регуляторний контур) деталізує цей вплив через специфіку конкретної галузі: динаміку ринку, регуляторне оточення (зокрема вимоги Basel III та Постанови НБУ №351), технологічні зміни та концентрацію кредитного портфеля банку.

Таблиця 1.1 – Класифікація видів кредитного ризику

Класифікаційна ознака	Вид кредитного ризику	Характеристика
За рівнем агрегування	Індивідуальний	Ризик конкретного позичальника чи окремої кредитної угоди
	Портфельний	Ризик кредитного портфеля загалом, з огляду на ефекти диверсифікації та кореляцію між дефолтами різних позичальників
За характером прояву	Ризик дефолту	Імовірність того, що позичальник повністю не виконає свої зобов'язання за кредитним договором

Класифікаційна ознака	Вид кредитного ризику	Характеристика
	Міграційний ризик	Погіршення кредитного рейтингу позичальника без настання формального дефолту, що збільшує ймовірність майбутніх втрат
	Ризик концентрації	Надмірна залежність портфеля від одного позичальника, групи пов'язаних осіб або певної галузі
За часовим горизонтом	Поточний	Ризик у межах звітного періоду, розрахований за наявними фінансовими даними
	Потенційний	Очікуваний ризик за весь строк дії кредитної угоди з урахуванням прогнозних сценаріїв
За компонентною структурою (Basel III)	Очікувані втрати (EL)	Добуток $PD \times LGD \times EAD$; покриваються резервами відповідно до вимог МСФЗ 9
	Неочікувані втрати (UL)	Відхилення фактичних збитків від очікуваного значення; покриваються регуляторним капіталом банку

Джерело: систематизовано автором на основі [3, 6, 18, 47, 51]

Нижній рівень (мікрорівень позичальника) безпосередньо узагальнює фінансовий стан підприємства через шість аналітичних блоків: ліквідність, рентабельність, фінансовий леверидж, ділову активність, покриття боргу та нефінансові фактори, кожен з яких має прямий вплив на результуючий показник PD. Стрілки між рівнями ілюструють каскадний механізм передачі ризику: зміни макросередовища транслуються через галузевий контур у конкретні фінансові показники підприємства, що й визначає кінцеву оцінку ймовірності його дефолту.



Рис. 1.2 – Трирівнева система детермінант кредитного ризику. Джерело: побудовано автором на основі [3, 6, 18, 47, 51]

1.2. Системний аналіз факторів оцінювання кредитоспроможності корпоративних клієнтів

Кредитоспроможність є фундаментальною категорією для банківського аналізу, проте єдиного загальновизнаного визначення у науковій літературі воно не має. У найзагальнішому формулюванні *кредитоспроможність позичальника* – це його здатність повністю та своєчасно виконати зобов'язання за кредитним договором власними силами.

Важливо розмежовувати *кредитоспроможність* і *кредитний ризик*: ці категорії пов'язані між собою, але не тотожні. Кредитоспроможність характеризує позичальника, зокрема, його поточну і прогнозовану спроможність обслуговувати борг.

Кредитний ризик – це вже характеристика операції з погляду банку: ймовірність і масштаб можливих втрат. Зростання кредитоспроможності відповідає зниженню *PD*, і навпаки [43, 51].

Системний аналіз факторів кредитоспроможності корпоративних позичальників зручно здійснювати за трирівневою схемою: *ендогенні фактори* (внутрішні характеристики підприємства), *екзогенні фактори* (зовнішні

середовище) та *регуляторні фактори* (інституційне та нормативно-правове оточення). Така декомпозиція дозволяє зрозуміти, на які змінні банк може впливати через умови договору (застава, ковенанти), а які просто враховувати як зовнішні обмеження [51, 53].

Ендогенні фактори охоплюють фінансовий стан підприємства та якісні характеристики його діяльності. Серед кількісних показників традиційно виокремлюють п'ять аналітичних блоків: ліквідність, рентабельність, фінансовий леверидж, ділова активність і покриття боргу. Кожен блок описується системою коефіцієнтів, розрахованих за даними фінансової звітності. Ці п'ять блоків формують основу ознакового простору датасету Polish Companies Bankruptcy, що використовується у практичній частині дослідження [43, 46, 51].

Перший блок (показники ліквідності) відображає здатність підприємства погашати поточні зобов'язання за рахунок оборотних активів. Коефіцієнт поточної ліквідності (*Current Ratio, CR* = *Оборотні активи / Поточні зобов'язання*) є ключовим: значення нижче 1,0 сигналізує про дефіцит оборотного капіталу і підвищений ризик неплатоспроможності. *Коефіцієнт швидкої ліквідності (Quick Ratio)* виключає запаси як найменш ліквідний елемент, даючи консервативнішу оцінку: $QR = (\text{Оборотні активи} - \text{Запаси}) / \text{Поточні зобов'язання}$ [43, 46].

Другий блок (показники рентабельності) характеризує ефективність використання ресурсів і здатність генерувати прибуток для обслуговування боргу. *Рентабельність активів (ROA* = *Чистий прибуток / Активи*) є універсальним показником, оскільки не залежить від структури фінансування.

Рентабельність власного капіталу (ROE = *Чистий прибуток / Власний капітал*) сигналізує про ризик відтоку інвестицій при низьких значеннях.

Операційна рентабельність (EBIT / Виручка) особливо корисна при оцінці спроможності покривати відсоткові зобов'язання [43, 51].

Третій блок – це показники фінансового левериджу, що відображають структуру капіталу та рівень боргового навантаження.

Коефіцієнт боргового навантаження ($Debt\ Ratio = \text{Сукупний борг} / \text{Активи}$) вище 0,7 традиційно розглядається як індикатор підвищеного ризику. Відношення " $\text{Борг} / EBITDA$ " є поширеним показником у корпоративних договорах і показує кількість років, необхідних для погашення боргу за рахунок операційного грошового потоку.

Коефіцієнт фінансової незалежності ($\text{Власний капітал} / \text{Активи}$) є оберненим до Debt Ratio [43, 46, 53]

Четвертий блок – це показники ділової активності, що характеризують інтенсивність використання активів.

Оборотність активів ($\text{Виручка} / \text{Активи}$) показує, скільки виручки генерує кожна гривня активів, і є індикатором ефективності бізнес-моделі.

Показник " $\text{Дні дебіторської заборгованості}$ " ($DSO = 365 / (\text{Виручка} / \text{Дебіторська заборгованість})$) характеризує якість управління розрахунками з покупцями. Тривале DSO може свідчити як про надмірно м'яку кредитну політику щодо клієнтів, так і про реальні проблеми зі стягненням, тому обидва сценарії підвищують кредитний ризик позичальника [43, 46].

П'ятий блок (показники покриття боргу) безпосередньо пов'язаний зі спроможністю позичальника обслуговувати кредит. Коефіцієнт покриття відсотків ($ICR = EBIT / \text{Відсоткові витрати}$) нижче 1,5 є тривожним сигналом.

Коефіцієнт покриття обслуговування боргу ($DSCR = (EBITDA - \text{Податки} - \text{Капітальні витрати}) / (\text{Основний борг} + \text{Відсотки})$) є стандартним показником у проектному фінансуванні. DSCR нижче 1,0 означає, що підприємство не генерує достатнього грошового потоку для обслуговування боргу з поточних операцій [43, 51, 53].

Нефінансові чинники кредитоспроможності є важливою, але складно формалізованою частиною аналізу. Якість менеджменту оцінюється через досвід керівників, наявність стратегії, прозорість корпоративного управління та відповідність задекларованих планів реальним результатам. Галузева позиція

характеризується часткою ринку, конкурентними перевагами і диверсифікованою клієнтською базою. Ринкове середовище включає макроекономічну кон'юнктуру, галузеву динаміку, регуляторні зміни та технологічні ризики, це фактори, що безпосередньо впливають на стійкість грошових потоків позичальника [6, 40, 43].

При цьому *екзогенні фактори* перебувають поза контролем позичальника. Сюди відносять темпи зростання ВВП і промислового виробництва, рівень інфляції та процентних ставок, динаміку валютного курсу (критичну для підприємств із валютним розривом між доходами і зобов'язаннями), доступність і ціни на сировину, стан ринків збуту.

В умовах повномасштабної війни для України особливу вагу мають геополітичні ризики: вони безпосередньо впливають на операційну безперервність підприємств, розташованих у зонах бойових дій [6, 47, 53].

Регуляторні фактори визначають інституційне середовище для позичальника і банку-кредитора. Для підприємства це стабільність податкового законодавства, ефективність судового захисту прав кредиторів, галузеве ліцензування.

Для банків визначальними є нормативи НБУ щодо класифікації кредитів і резервів, вимоги до достатності капіталу та обмеження щодо концентрації портфеля.

При цьому регуляторні зміни можуть кардинально вплинути на кредитоспроможність позичальника навіть за незмінного фінансового стану, зокрема, наприклад, через введення нових екологічних вимог або скасування галузевих пільг [42, 53].

Зв'язок описаних аналітичних блоків з ознаковим простором датасету Polish Companies Bankruptcy є прямим: датасет містить 64 фінансові коефіцієнти, що охоплюють усі п'ять блоків. Незважаючи на відсутність нефінансових показників (обмеження публічних даних), кількісна повнота фінансового виміру робить датасет репрезентативним для моделювання *PD* [46, 51].

Традиційний коефіцієнтний аналіз, попри широке практичне застосування, має низку вагомих обмежень. Він є статичним: коефіцієнти розраховуються за ретроспективними даними і не відображають динаміку. Він є лінійним: передбачає приблизно пропорційний зв'язок між показником і ризиком, тоді як реальні залежності нерідко нелінійні та містять порогові ефекти. Встановлення порогових значень (бенчмарків) є значною мірою суб'єктивним: оптимальні значення суттєво різняться залежно від галузі, розміру підприємства та стадії економічного циклу, тоді як більшість банківських методик застосовують єдині нормативи для всіх позичальників [40, 43, 46].

В табл. 1.2 наведено порівняльний аналіз вимог Постанови НБУ №351 та Basel III (IRB-підхід) до оцінювання кредитного ризику.

Таблиця 1.2 – Порівняльний аналіз вимог Постанови НБУ №351 та Basel III (IRB-підхід) до оцінювання кредитного ризику

Критерій оцінювання	НБУ №351	Basel III (IRB-підхід)	Відповідність
Визначення дефолту	Прострочення > 90 днів; суттєве погіршення фінансового стану; порушення провадження про банкрутство; реструктуризація через фінансові труднощі	Unlikely to pay та/або прострочення > 90 днів – дворівневий критерій (Basel II, Art. 178)	Частково НБУ не деталізує критерій unlikely to pay
Горизонт оцінювання PD	Поточний стан позичальника (переважно ретроспективний аналіз звітного року)	1-річний горизонт PD; through-the-cycle для IRB; мінімум 5 років даних для калібрування	Частково НБУ не вимагає through-the-cycle калібрування
Компонент и ризику	Клас позичальника (1–5) та рівень забезпечення визначають норму резервування; LGD і EAD не виділяються окремо	Явна тріада: $PD \times LGD \times EAD = EL$; регуляторний капітал = $f(PD, LGD, EAD, M)$	Не відповідає НБУ не вимагає окремої оцінки LGD та EAD

Критерій оцінювання	НБУ №351	Basel III (IRB-підхід)	Відповідність
Фінансові показники аналізу	Обов'язковий аналіз: ліквідність, рентабельність, фінансова стійкість, грошові потоки, ділова активність (≥ 5 блоків)	Не регламентує конкретні коефіцієнти; вимагає повноти та репрезентативності – банк обирає самостійно	Відповідає НБУ-блоки відповідають Basel-блокам за змістом
Нефінансові фактори	Ринкова позиція, менеджмент, ділова репутація, залежність від контрагентів – обов'язкові якісні критерії	Якісні фактори враховуються у внутрішніх рейтингах; обов'язкові для F-IRB та A-IRB	Відповідає Вимоги збігаються за суттю
Метод класифікації позичальника	5 класів (1 – найвищий, 5 – дефолт); клас визначається балами за фінансовими та якісними показниками	Неперервна шкала $PD \in (0;1)$; мінімум 7 градацій для не-дефолтних позичальників (<i>IRB</i>)	Частково 5 класів НБУ < 7 градацій Basel; відсутня неперервна PD
Вимоги до моделі (use test)	Банк може використовувати власні скорингові моделі; НБУ не формалізує вимогу реального використання у кредитному процесі	Use test: модель PD має реально застосовуватись при видачі кредитів, ціноутворенні та ліміт-менеджменті – обов'язково для IRB	Не відповідає НБУ не закріплює use test формально
Валідація та бек-тестинг	НБУ проводить AQR; банки зобов'язані обґрунтовувати класифікацію, проте формальний бек-тестинг PD не вимагається	Обов'язковий регулярний бек-тестинг прогнозних PD ; стрес-тестування моделей; незалежна валідація	Не відповідає Формальний бек-тестинг PD відсутній у НБУ №351
Резервування (EL)	Резерви формуються за класом позичальника та рівнем забезпечення згідно з МСФЗ 9; норми диференційовані за класами 1-5	$EL = PD \times LGD \times EAD$; надлишок резервів над EL може зараховуватись до капіталу Tier 2 (до 0,6% зважених активів)	Частково МСФЗ 9 імплементовано; прямого зв'язку з $PD \times LGD \times EAD$ немає

Критерій оцінювання	НБУ №351	Basel III (IRB-підхід)	Відповідність
Регуляторний капітал	Стандартизований підхід (SA): фіксовані вагові коефіцієнти ризику (0-150%) за типом позичальника та наявністю забезпечення	SA та IRB-підходи (F-IRB, A-IRB); IRB дозволяє знизити вимоги до капіталу для якісних позичальників	Частково Провідні банки України поки не мають дозволу на IRB

Джерело: складено автором на основі [3, 11, 33, 37, 45]

Крім того, коефіцієнтний аналіз низькорозмірний: типова методика охоплює 10-20 показників, тоді як сучасні датасети містять десятки чи навіть сотні ознак. Ручний відбір релевантних коефіцієнтів є суб'єктивним процесом із ризиком втрати важливої інформації.

Таким чином, можна зробити висновок, що коефіцієнтний підхід погано справляється з пропущеними значеннями та викидами (явищами, поширеними у реальній фінансовій звітності). Сукупність цих недоліків зумовлює перехід до статистичних і ML-методів, здатних автоматично виявляти складні нелінійні залежності у багатовимірному просторі ознак [40, 46, 51].

1.3. Класифікація методів оцінювання кредитного ризику: від класичних до сучасних підходів

Еволюція методів оцінювання кредитного ризику охоплює більше шести десятиліть і відображає загальний поступ економіко-математичного моделювання, від суб'єктивних суджень кредитних аналітиків до статистичних моделей і зрештою до методів машинного навчання. Розуміння цього еволюційного шляху є необхідним для обґрунтованого вибору методологічної основи дослідження та усвідомлення переваг ансамблевих алгоритмів [3, 4, 5].

За принципом побудови всі методи оцінювання кредитного ризику поділяються на три великі класи. Експертні підходи ґрунтуються на формалізованих судженнях кредитних аналітиків і реалізуються через рейтингові

системи, скорингові карти та методи на кшталт "5C" (Character, Capacity, Capital, Collateral, Conditions). Статистичні моделі використовують математично обґрунтовані алгоритми для встановлення залежності між фінансовими показниками й ймовірністю дефолту. Методи машинного навчання є розширенням статистичного підходу, здатним автоматично знаходити складні нелінійні залежності у великих масивах даних [3, 13, 30].

Першою кількісною моделлю прогнозування корпоративного банкрутства, що здобула широке визнання, стала Z-модель Альтмана (1968). Спираючись на метод множинного дискримінантного аналізу (MDA), Альтман побудував лінійну комбінацію п'яти фінансових коефіцієнтів, яка максимально розділяла підприємства-банкрути і платоспроможні компанії. Для публічних компаній модель має вигляд [4]:

$$Z = 1,2 \cdot x_1 + 1,4 \cdot x_2 + 3,3 \cdot x_3 + 0,6 \cdot x_4 + 1,0 \cdot x_5, \quad (1.2)$$

де x_1 = *Оборотний капітал / Активи*; x_2 = *Нерозподілений прибуток / Активи*; x_3 = *EBIT / Активи*; x_4 = *Ринкова капіталізація / Сукупний борг*; x_5 = *Виручка / Активи*.

Зони прийняття рішень у моделі Альтмана такі: $Z > 2,99$ – безпечна зона; $1,81 < Z < 2,99$ – "сіра зона" невизначеності; $Z < 1,81$ – зона ризику. Серед переваг можна відзначити простоту й високу інтерпретованість. Серед обмежень слід зауважити на її лінійність, малий набір коефіцієнтів, орієнтація на публічні компанії (x_4 потребує ринкової капіталізації) та чутливість до галузевої специфіки [4, 13].

Логістична регресія (логіт-модель) позбавлена ключового обмеження MDA, тобто припущення про нормальний розподіл предикторів. Вона моделює ймовірність дефолту через сигмоїдну функцію [5, 13]:

$$P = 1 / (1 + e - (\beta_0 + \beta_1 x_1 + \dots + \beta_n x_n)), \quad (1.3)$$

де $\beta_0, \beta_1, \dots, \beta_n$ – коефіцієнти моделі, що оцінюються методом максимальної правдоподібності; $x_1, \dots, x_n$ – вектор предикторів.

Результат знаходиться в діапазоні (0; 1) і безпосередньо інтерпретується як *PD*. Логіт-модель є стандартом скорингових карт у роздрібному кредитуванні й часто виступає базовою лінією (baseline) при порівнянні з ML-моделями.

Її перевагою є безпосередня ймовірнісна інтерпретація, стійкість до мультиколінеарності при регуляризації та відповідність регуляторним вимогам інтерпретованості. Головний недоліком є лінійність у просторі логіт-перетворення, що унеможливорює моделювання складних взаємодій між предикторами [5, 13, 46].

Структурні моделі кредитного ризику засновані на теорії опціонного ціноутворення і пов'язані з іменем Роберта Мертона. У його моделі (1974) власний капітал підприємства розглядається як кол-опціон на активи із ціною виконання, рівній номінальній вартості боргу. Дефолт настає, коли вартість активів V на момент погашення T падає нижче D .

Ймовірність дефолту визначається через "відстань до дефолту" (Distance to Default, DD) [3, 13]:

$$PD = N(-DD), \quad DD = \frac{\left(\ln\left(\frac{V}{D}\right) + \left(\mu - \frac{\sigma^2}{2}\right) \cdot T\right)}{(\sigma \cdot \sqrt{T})}, \quad (1.4)$$

де $N(\cdot)$ – функція стандартного нормального розподілу; μ – очікувана дохідність активів; σ – волатильність активів. Модель теоретично елегантна, проте має суттєві практичні обмеження: вимагає ринкових даних про вартість активів і їх волатильність, яких для непублічних компаній немає; передбачає неперервну зміну вартості активів, що виключає раптові стрибки; і не враховує складну структуру боргу [3, 13].

Останнім часом для задач оцінювання кредитного ризику все частіше використовують методи на основі алгоритмів машинного навчання (ML). Перехід до ML зумовлений фундаментальними обмеженнями класичних підходів.

По-перше, нелінійність реальних залежностей між фінансовими показниками і ймовірністю дефолту не може бути адекватно відображена лінійними моделями, тому порогові ефекти й взаємодії між змінними є радше правилом, ніж винятком.

По-друге, висока розмірність сучасних датасетів виходить за межі ручного відбору змінних. По-третє, незбалансованість класів (коли дефолти становлять 5-20% вибірки) потребує спеціальних методів, які вбудовані в сучасні ML-алгоритми [10, 14, 30].

Серед ML-методів особливе місце займають ансамблеві алгоритми. *Random Forest* (випадковий ліс), запропонований Брейманом у 2001 році, будує велику кількість дерев рішень на випадкових підвибірках даних і ознак (беггінг + випадковий відбір ознак) та агрегує їхні прогнози голосуванням.

Gradient Boosting – клас алгоритмів, до якого належать *XGBoost* і *LightGBM*, будує дерева послідовно: кожне наступне коригує помилки попереднього у напрямку антиградієнта функції втрат. *LightGBM* відрізняється особливою ефективністю на великих датасетах завдяки алгоритму GOSS (Gradient-based One-Side Sampling) і гістограмному методу розбиття [14, 24, 30].

Нейронні мережі, зокрема, багатошарові перцептрони і рекурентні архітектури, здатні досягати високої точності на великих масивах даних, але їх застосування в кредитному ризику обмежується потребою у значних обсягах навчальних даних і, що критично важливіше, вкрай низькою інтерпретованістю. Саме "чорна скринька" є центральним викликом для складних ML-моделей у банківській сфері: регулятори (НБУ, Базельський комітет) наполягають, щоб кредитні рішення були обґрунтованими та перевірюваними.

Це робить нейронні мережі менш прийнятними для регуляторних цілей порівняно з ансамблевими алгоритмами, особливо в контексті "use test" IRB-підходу [3, 16, 55].

Відповіддю на проблему інтерпретованості стала концепція пояснюваного штучного інтелекту (Explainable AI, XAI), центральним інструментом якої є метод *SHAP* (SHapley Additive exPlanations). Він базується на теорії кооперативних ігор Шеплі і дозволяє розкласти прогноз моделі для кожного спостереження на внески кожної ознаки.

Значення SHAP показує, наскільки ознака j підвищила або знизил прогнозую ймовірність дефолту для конкретного позичальника відносно середнього прогнозу по вибірці. Це дозволяє кредитному аналітику зрозуміти, чому модель класифікувала позичальника як ризикованого: наприклад, "імовірність дефолту підвищена на 15 в.п. через від'ємну рентабельність активів і критично низький DSCR" [16, 55].

У регуляторному контексті SHAP є ключовим інструментом для виконання вимоги "use test" IRB-підходу: він трансформує непрозорий алгоритм бустингу у систему обґрунтованих кредитних рішень, придатну для аудиту регулятором. Крім того, SHAP дозволяє здійснювати глобальну інтерпретацію щоб визначати, які чинники є найбільш вагомими для прогнозування дефолту в цілому по портфелю, – що цінно для стрес-тестування та стратегічного планування [3, 16, 55].

Огляд методів оцінювання кредитного ризику свідчить про їх закономірну еволюцію: від простих лінійних підходів (MDA, логіт-модель) через структурні моделі до сучасних ансамблевих алгоритмів ML із підтримкою ХАІ. Більш деталізовано розширений перелік методів, включно з CART та SVM, наведено у Додатку А (таблиця А.1).

Кожен наступний клас методів долає ключові обмеження попереднього, але водночас ускладнює інтерпретацію, що породжує потребу в інструментах на кшталт SHAP. Поєднання ансамблевих алгоритмів (Random Forest, XGBoost, LightGBM) зі SHAP-інтерпретацією складає методологічну основу цього дослідження [3, 14, 16, 30, 55], обґрунтування якого деталізується в Розділі 2.

Висновки до розділу 1

За результатами теоретико-методологічного аналізу, проведеного у першому розділі, можна сформулювати такі висновки.

1. Кредитний ризик є системоутворювальною категорією банківської діяльності, що відповідає за понад 70% сукупних збитків банківського сектору в

кризові роки. Його кількісне вимірювання здійснюється через триаду Basel III ($PD \times LGD \times EAD$), де ймовірність дефолту (PD) є центральним параметром як для розрахунку регуляторного капіталу, так і для формування резервів відповідно до МСФЗ 9. Підвищення точності оцінки PD безпосередньо впливає на фінансову ефективність і конкурентоспроможність банку, обумовлюючи практичну значущість розробки вдосконалених моделей прогнозування дефолту.

2. Корпоративний кредитний ризик характеризується специфічними рисами, що якісно відрізняють його від роздрібного сегменту: гетерогенністю позичальників, складністю структур забезпечення, вираженим концентраційним ризиком і гострою проблемою асиметрії інформації. В умовах України ці загальносвітові закономірності доповнюються хронічно високим рівнем NPL , а також недосконалістю правозастосування при реалізації застав та геополітичними ризиками воєнного часу. Нормативну основу оцінювання кредитного ризику в Україні формує Постанова НБУ №351, що визначає порядок класифікації кредитних операцій і критерії дефолту.

3. Аналіз факторів кредитоспроможності корпоративних позичальників доцільно здійснювати за трирівневою декомпозицією: ендогенні (п'ять блоків фінансових коефіцієнтів плюс нефінансові характеристики), екзогенні (макроекономічне середовище, галузева динаміка, геополітичні ризики) та регуляторні фактори (інституційне оточення). Традиційний коефіцієнтний аналіз, незважаючи на широку практичну застосовність, обмежений статичністю, лінійністю, суб'єктивністю порогових значень і низькою розмірністю – що зумовлює перехід до складніших методів.

4. Еволюція методів оцінювання кредитного ризику відображає послідовне подолання обмежень попередніх підходів. Дискримінантний аналіз і логістична регресія забезпечують інтерпретованість, але обмежені лінійністю. Структурна модель Мертона теоретично обґрунтована, проте непридатна для непублічних компаній через потребу в ринкових даних. Методи ML (Random

Forest, XGBoost, LightGBM) долають обмеження лінійності та забезпечують автоматичний відбір ознак, проте породжують проблему "чорної скриньки".

5. Метод SHAP (SHapley Additive exPlanations), заснований на теорії кооперативних ігор, є оптимальним рішенням проблеми інтерпретованості ML-моделей у регуляторному контексті: він забезпечує як локальне пояснення прогнозу для кожного позичальника, так і глобальний аналіз важливості факторів, відповідаючи вимозі "use test" IRB-підходу Базельського комітету. Поєднання ансамблевих алгоритмів зі SHAP-інтерпретацією формує методологічне ядро дослідження, що дозволяє одночасно забезпечити прогностичну точність і прозорість кредитних рішень.

6. Теоретико-методологічні засади першого розділу визначають логіку всього дослідження: від концептуального обґрунтування природи кредитного ризику і факторів кредитоспроможності, через порівняльний аналіз методологічних підходів, до практичного застосування ансамблевих моделей на реальному датасеті та їх інтерпретації засобами ХАІ.

РОЗДІЛ 2

РОЗРОБКА МЕТОДИЧНОГО ПІДХОДУ ДО ОЦІНЮВАННЯ КРЕДИТНОГО РИЗИКУ КОРПОРАТИВНИХ КЛІЄНТІВ З ВИКОРИСТАННЯМ АЛГОРИТМІВ МАШИННОГО НАВЧАННЯ

2.1 Формальна постановка задачі оцінювання кредитного ризику корпоративних клієнтів як задачі бінарної класифікації

Об'єктом дослідження у межах дипломного проекту є процес оцінювання кредитного ризику корпоративних позичальників. З позицій системного аналізу цей процес розглядається як складна динамічна система, що функціонує в умовах високої невизначеності та агресивного зовнішнього середовища [37, 45].

Система кредитного оцінювання має наступну структуру:

- *Вхідні дані (Input)*: масив фінансової звітності (баланс, звіт про фінансові результати), неструктуровані дані про ринкову кон'юнктуру, кредитна історія та якісні характеристики менеджменту підприємства.
- *Процесор (System Operator)*: алгоритм машинного навчання, що реалізує функцію відображення вхідних даних у прогноз ймовірності дефолту. Саме цей компонент є об'єктом розробки у цій роботі..
- *Вихід (Output)*: ймовірність дефолту $\hat{p}_i \in [0,1]$ (Probability of Default, *PD*), кредитний рейтинг та рекомендація щодо прийняття рішення (approval/rejection).
- *Зворотний зв'язок (Feedback)*: моніторинг фактичного обслуговування боргу, що дозволяє здійснювати донавчання та перекалібрування моделі з плином часу відповідно до вимог Basel III щодо стабільності рейтингових систем [3].

Узагальнену блок-схему факторів, що треба враховувати при оцінюванні кредитного ризику наведено на рис. 2.1.



Рис. 2.1 – Системне представлення кредитного ризику.

Математична формалізація задачі. Прогнозування дефолту корпоративного позичальника може бути формалізоване у різних математичних постановках [37, 45]. Порівняльний аналіз чотирьох основних підходів систематизовано у таблиці 2.1.

Таблиця 2.1 – Порівняльний аналіз постановок задачі прогнозування дефолту

Постановка	Вихід моделі	Функція втрат	Переваги	Обмеження
Бінарна класифікація	$\hat{y} \in \{0,1\}$, $\hat{p} \in [0,1]$	Log Loss, Hinge Loss	Відповідає IRB-концепції <i>PD</i> ; широкий вибір алгоритмів	Потребує оптимізації порогу τ
Регресія ймовірності	$\hat{p} \in [0,1]$	MSE, Beta-регресія	Пряме калібрування <i>PD</i>	Потребує калібрування Platt / Isotonic
Багатокласова класифікація	$\hat{k} \in \{A, B, C, D\}$	Categorical Cross-Entropy	Відповідає рейтинговим класам НБУ [2]	Потребує розмічених рейтингів у вибірці
Задача виживання	T - час до дефолту	Partial Likelihood (Cox)	Враховує часовий горизонт	Потребує повних часових рядів; складна реалізація

Джерело: складено автором на основі [2, 3, 37, 45]

Бінарна класифікація з оцінкою ймовірності обрана з таких міркувань:

По-перше, вона безпосередньо відповідає регуляторній концепції PD у рамках IRB-підходу: вихідне значення $\hat{p}_i \in [0,1]$ може бути безпосередньо підставлене у формулу очікуваних втрат без додаткових перетворень [3].

По-друге, обраний для верифікації запропонованого підходу та модельного інструментарію датасет Polish Companies Bankruptcy Data [38, 58] містить бінарну цільову мітку без інформації про часовий горизонт дефолту в межах кожного зрізу, що унеможливорює коректне застосування моделей виживання.

По-третє, для бінарної класифікації існує найбільш розвинений методологічний апарат роботи з незбалансованими класами, що є актуальним для реальних даних (у тому числі і для обраного датасету з індексом дисбалансу класів IR від 13 до 25 [44, 45]).

Розглянемо формально-математичну постановку задачі оцінювання кредитного ризику.

Нехай $\mathcal{D} = \{(x_i, y_i)\}_{i=1}^N$ – навчальна вибірка з N спостережень, де кожне спостереження являє собою пару: «фінансовий профіль позичальника – факт дефолту».

Вектор ознак $x_i \in \mathbb{R}^{64}$ описує фінансовий стан i -го підприємства через $d = 64$ числові фінансові коефіцієнти³:

$$X_i = (x_{i1}, x_{i2}, \dots, x_{i64})^T \in \mathbb{R}^{\{64\}}, \quad (2.1)$$

де x_{ij} – значення j -го фінансового коефіцієнта (наприклад, коефіцієнт поточної ліквідності, ROA, Debt/Equity тощо) для i -го підприємства.

Цільова змінна $y_i \in \{0, 1\}$ набуває значень:

$$\begin{cases} 1, & \text{якщо підприємство оголосило дефолт} \\ 0, & \text{в протилежному випадку} \end{cases} \quad (2.2)$$

³ Розмірність козакового простору $d=64$ зумовлена кількістю факторів в обраному датасеті

Визначення дефолту відповідає критеріям Постанови НБУ №351 [2] та Basel III [3]: прострочення понад 90 днів або юридично підтверджена неплатоспроможність.

Задача полягає у знаходженні функції $f: \mathbb{R}^{64} \rightarrow [0, 1]$, що оцінює умовну ймовірність дефолту для кожного позичальника:

$$\hat{p}_i = f(x_i) = P(y_i = 1 | x_i). \quad (2.3)$$

Бінарна класифікаційна мітка визначається через поріг прийняття рішення $\tau \in (0, 1)$:

$$\hat{y}_i = \{ 1, \hat{p}_i \geq \tau; \quad 0, \hat{p}_i < \tau. \quad (2.4)$$

Вибір порогу τ є окремою задачею оптимізації, що залежить від відносної вартості помилок першого та другого роду у банківському контексті.

Функція втрат. Для знаходження оптимальних параметрів моделі f необхідно визначити критерій якості – функцію втрат $\mathcal{L}$, мінімізація якої на навчальній вибірці є процедурою навчання [37]. Загальна задача навчання формулюється як:

$$\hat{f} = \operatorname{argmin}_{f \in \mathcal{F}} \frac{1}{N} \cdot \sum_{i=1}^N \mathcal{L}(y_i, f(x_i)), \quad (2.5)$$

де $\mathcal{F}$ – клас гіпотез (простір допустимих функцій, що визначається архітектурою моделі). Для задач бінарної класифікації з оцінкою ймовірностей стандартною функцією втрат є *бінарна крос-ентропія* (Binary Cross-Entropy Loss, також відома як Log Loss) [37, 45]:

$$\mathcal{L}^{ce} = -1/N \cdot \sum_{i=1}^N [y_i \cdot \ln \hat{p}_i + (1 - y_i) \cdot \ln(1 - \hat{p}_i)], \quad (2.6)$$

де N – обсяг навчальної вибірки; $y_i \in \{0, 1\}$ – справжня мітка класу i -го спостереження; $\hat{p}_i = f(x_i) \in (0, 1)$ – прогнозована моделлю ймовірність дефолту.

Вибір бінарної крос-ентропії як функції втрат зумовлений такими властивостями [37]:

- *по-перше*, вона штрафує модель пропорційно до впевненості хибного прогнозу: чим вищою є впевненість моделі у помилковому рішенні, тим

більшим є штраф ($-\ln \hat{p}_i \rightarrow +\infty$ при $\hat{p}_i \rightarrow 0$, якщо $y_i = 1$); це особливо важливо у банківському контексті, де впевнений хибний прогноз щодо віднесення неризикового клієнта (False Negative, FN-прогноз) є найнебезпечнішим сценарієм;

- *по-друге*, вона є диференційованою функцією, що дозволяє застосовувати алгоритми градієнтної оптимізації, зокрема використовувані в XGBoost та LightGBM [28, 39];
- *по-третє*, мінімізація крос-ентропії еквівалентна максимізації логарифмічної функції правдоподібності, що є статистично обґрунтованим критерієм оцінювання ймовірнісних моделей.

Схематично, вигляд цієї функції наведено на Рис. 2.2.




Рисунок 2.2 – Властивості функції бінарної крос-ентропії (Log Loss).

Зв'язок функції втрат із формулою очікуваних втрат Basel III. Доцільно встановити явний зв'язок між математичною постановкою задачі ML та регуляторною формулою (1.1). Нехай c^{NN} – фінансові втрати банку від помилки типу *FN* для одного позичальника (апроксимується як $EAD_i \times LGD_i$), а c^{FP} – втрачений процентний дохід від помилки типу *FP*. Тоді очікувані фінансові втрати від рішення моделі для i -го позичальника:

$$\mathbb{E}[Loss_i] = c^{NN} \cdot P(y_i = 1) \cdot (1 - \hat{p}_i) + c^{FP} \cdot P(y_i = 0) \cdot \hat{p}_i, \quad (2.7)$$

де перший доданок – очікувані втрати від пропущеного дефолту, другий – від хибної тривоги. Мінімізація (2.7) по $\hat{p}_i$ дає оптимальний поріг класифікації:

$$\tau^* = c^{NN} / (c^{NN} + c^{FP}), \quad (2.8)$$

що при $c^{NN} \gg c^{FP}$ прагне до нуля [45].

Це формально обґрунтовує вибір $\tau < 0,5$ у банківській практиці та необхідність зважування класів у функції втрат (2.7). Таким чином, оптимізаційна задача ML (2.5) є формалізацією регуляторної вимоги Basel III щодо мінімізації очікуваних кредитних втрат [3].

Проблема незбалансованості класів. У датасеті Polish Companies Bankruptcy Data частка підприємств-банкрутів становить від 3,86% (1-й зріз) до 6,94% (5-й зріз) [38, 58]. Це означає, що співвідношення класів становить від 1:14 до 1:25 на користь платоспроможних підприємств. За таких умов тривіальний класифікатор, що завжди прогнозує клас «не дефолт», досягає точності (Accuracy) 93-96%, тоді як його практична корисність для банку є нульовою, оскільки він не виявляє жодного реального дефолту [44, 45].

Ступінь незбалансованості описується через індекс дисбалансу класів *Imbalance Ratio (IR)*:

$$IR = N_0 / N_1 \quad (2.8)$$

де N_0 та N_1 – кількості спостережень класу більшості та меншості відповідно.

Для датасету, що досліджується, *IR* варіюється від 13,4 (5-й зріз) до 24,9 (1-й зріз). При $IR > 10$ стандартні алгоритми навчання демонструють значне погіршення чутливості до класу меншості (Recall), що безпосередньо відповідає зростанню частоти помилок типу *FN* [44, 45].

Обмеження та припущення системи. Будь-яка ML-модель функціонує в рамках певних обмежень, ігнорування яких призводить до завищення очікувань від її практичного застосування [37]. Для розробленої системи оцінювання кредитного ризику визначено три групи обмежень.

Інформаційні обмеження пов'язані з доступністю та якістю вхідних даних. Фінансова звітність підприємств може містити пропуски (в датасеті до 40% для окремих ознак), аномальні значення внаслідок облікових помилок або навмисного спотворення, а також запізнення у наданні звітності. Крім того, модель навчена на даних польських підприємств 2000-2013 рр., що потребує обережності при екстраполяції на інші ринки та часові горизонти.

Технічні обмеження визначаються обчислювальними ресурсами та вимогами до часу відгуку системи при промисловому впровадженні. Стекінгова модель з байєсівською оптимізацією гіперпараметрів потребує значних обчислювальних витрат на етапі навчання [21], хоча інференс (видача прогнозу для нового позичальника) виконується менш ніж за 50 мс.

Регуляторні обмеження встановлені стандартами Basel III [3] та Постановою НБУ №351 [2]: модель має забезпечувати не лише технічну точність, але й можливість регуляторної валідації та пояснення кожного рейтингового рішення. Саме ця вимога обумовлює включення SHAP-аналізу [48] як обов'язкового компонента розробленої системи.

Таким чином, задача оцінювання кредитного ризику корпоративних позичальників формалізована як задача пошуку функції $f: \mathbb{R}^{64} \rightarrow [0, 1]$, що мінімізує зважену крос-ентропію (2.7) на навчальній вибірці з $\sim 43\,000$ спостережень за умов суттєвої незбалансованості класів (IR від 13 до 25) та визначених інформаційних, технічних і регуляторних обмежень.

Особливості цієї задачі (висока розмірність ознакового простору, нелінійні взаємодії між предикторами, незбалансованість класів та вимоги до інтерпретованості) безпосередньо впливає та зумовлює вибір стекінгової ансамблевої архітектури, аналіз компонентів якої описано підрозділі 2.2.

2.2 Обґрунтування вибору методів машинного навчання для прогнозування кредитного ризику

Визначення задачі оцінювання кредитного ризику як задачі бінарної класифікації (підрозділ 2.1) відкриває широкий методологічний простір для вибору алгоритму навчання. Проте не кожен метод машинного навчання однаково придатний для цієї конкретної прикладної задачі: специфічні характеристики фінансових даних, зокрема, висока розмірність ознакового простору, незбалансованість класів, значна частка пропущених значень, нелінійні взаємодії між предикторами, формують жорсткі вимоги до алгоритму [37, 45]. У цьому підрозділі послідовно аналізуються п'ять методів, що утворюють базові класифікатори першого рівня стекінгової архітектури, розробленої у цій роботі, та обґрунтовується доцільність включення кожного з них до ансамблю.

Логістична регресія як базова лінія

Логістична регресія є відправною точкою аналізу, не лише як найпростіший класифікатор, але й як регуляторно схвалений стандарт для скорингових карт у банківській практиці [45, 55]. Незважаючи на назву «регресія», метод є класифікаційним алгоритмом, що моделює взаємозв'язок між бінарною залежною змінною (дефолт / не дефолт) та набором незалежних фінансових коефіцієнтів через логістичну (сигмоїдну) функцію.

Модель логістичної регресії з L_2 -регуляризацією (Ridge) має такий вигляд [37]:

$$\hat{f}_{LR} = \underset{\beta}{\operatorname{argmin}} \left[-\frac{1}{N} \cdot \sum_{i=1}^N \left(y_i \ln \sigma(\beta^T x_i) + (1 - y_i) \ln(1 - \sigma(\beta^T x_i)) \right) + \lambda \|\beta\|^2 \right], \quad (2.9)$$

де $\sigma(z) = 1/(1 + e^{-z})$ – сигмоїдна функція; $\beta \in \mathbb{R}^{64}$ – вектор параметрів моделі; $\lambda > 0$ – коефіцієнт регуляризації.

Алгоритм обчислює лінійну комбінацію вхідних ознак, а потім застосовує сигмоїдну функцію, що перетворює будь-яке дійсне число в значення від 0 до 1, яке інтерпретується як ймовірність дефолту.

Для задачі корпоративного кредитного ризику логістична регресія має такі принципові переваги. По-перше, коефіцієнти β_j допускають пряму інтерпретацію: e^{β_j} є відношенням шансів дефолту при збільшенні j -ї ознаки на одиницю за умови незмінності решти предикторів [37, 55].

Це відповідає регуляторній вимозі Basel III щодо пояснюваності рейтингових рішень [3]. По-друге, обчислювальна складність навчання є лінійною відносно обсягу вибірки та кількості ознак, що дозволяє ефективно обробляти ~43 000 спостережень.

Принциповим обмеженням логістичної регресії є лінійність: модель здатна апроксимувати лише лінійну гіперплощину, тоді як межа між класами «дефолт»/«не дефолт» у реальних фінансових даних має складну нелінійну форму [22, 45]. Попри це, логістична регресія включається до стекінгової архітектури як базовий класифікатор, оскільки її лінійні прогнози надають інформацію, корисну до нелінійних предикторів ансамблевих методів, та підвищують різноманітність ансамблю (що є ключовою умовою ефективності стекінгу [57]). Крім того, чутливість методу до аномальних значень та мультиколінеарності ознак компенсується через L_2 -регуляризацию та попередню обробкою даних

Random Forest (RF): безінг та усереднення дерев

Random Forest (Breiman, 2001) [27] є першим суттєво нелінійним методом у складі ансамблю. Алгоритм будує T дерев рішень на бутстреп-підвибірках навчальних даних та усереднює їхні прогнози. Прогнозована ймовірність дефолту для нового спостереження $\mathbf{x}^*$:

$$\hat{p}_{RF}(\mathbf{x}^*) = 1/T \cdot \sum_{t=1}^T h_t(\mathbf{x}^*) \quad (2.10)$$

де $h_t(\mathbf{x}^*)$ – ймовірність дефолту, передбачена t -м деревом. Кожне дерево будується на бутстреп-вибірці обсягом N та при кожному розгалуженні використовує лише випадкову підмножину з $m = \sqrt{d} = \sqrt{64} = 8$ ознак [27]. Механізм рандомізації ознак є ключовою особливістю RF: він де-кореляє окремі дерева ансамблю, що знижує загальну дисперсію прогнозу при незмінному зміщенні.

Декомпозиція помилки генералізації:

$$MSE = Bias^2 + Variance + IrreducibleNoise \quad (2.11)$$

показує, що RF знижує компонент дисперсії, що є принциповою перевагою над одиничним деревом рішень, яке схильне до перенавчання [37].

Для задачі оцінки кредитного ризику алгоритм природно обробляє пропущені значення через механізм сурогатних розгалужень та стійкий до мультиколінеарності ознак (характерної риси фінансових коефіцієнтів, де показники ліквідності, рентабельності та левериджу нерідко сильно скорельовані [10, 45]).

Вбудована оцінка важливості ознак через зменшення домішок Джині (MDI) є корисним інструментом інтерпретації. Механізм Out-of-Bag (OOB) оцінювання дозволяє отримати незміщену оцінку помилки генералізації без окремої тест-вибірki, тобто кожне дерево тестується на тих спостереженнях, які не потрапили до його бутстреп-вибірki [27].

XGBoost: градієнтний бустинг із регуляризацією

XGBoost (eXtreme Gradient Boosting), запропонований в роботі [28], є на сьогодні одним із найефективніших алгоритмів для структурованих табличних даних. На відміну від RF, де дерева будуються паралельно та незалежно, у градієнтному бустингу кожне нове дерево навчається виправляти помилки попереднього ансамблю [35]:

$$F_t(\mathbf{x}) = F_{t-1}(\mathbf{x}) + \eta \cdot h_t(\mathbf{x}), \quad (2.12)$$

де $F_t(\mathbf{x})$ – сукупний прогноз після t ітерацій; $\eta \in (0,1]$ – швидкість навчання (*learning rate*); h_t – нове дерево, що апроксимує негативний градієнт функції втрат відносно поточного прогнозу F_{t-1} .

Ключовою відмінністю XGBoost від класичного градієнтного бустингу є регуляризований цільовий функціонал [28]:

$$\mathcal{L}^{(t)} = \sum_{i=1}^N [g_i h_t(\mathbf{x}_i) + \frac{1}{2} k_i h_t^2(\mathbf{x}_i)] + \Omega(h_t) \quad (2.13)$$

де $g_i(\cdot)$ – перша похідна функції втрат (градієнт); k_i – друга похідна (гессіан); $\Omega(h_t) = \gamma T + \frac{1}{2}\lambda \|w\|^2$ – регуляризаційний член, де T – кількість листів дерева, w – ваги листів.

Використання гессіана у формулі (2.13) є принциповою перевагою XGBoost: воно дозволяє алгоритму точніше апроксимувати криву функції втрат та здійснювати більш точні оновлення на кожній ітерації порівняно з підходами, що використовують лише градієнт [28, 35].

Вбудована регуляризація $\Omega(h_t)$ безпосередньо контролює складність дерев, запобігаючи перенавчанню. Для задачі корпоративного дефолту особливо важливою є здатність XGBoost обробляти пропущені значення: алгоритм автоматично обирає оптимальний напрямок розгалуження для пропусків.

Параметр *scale_pos_weight* дозволяє безпосередньо задати вагу позитивного класу, реалізуючи зважену функцію втрат (2.7) для роботи з незбалансованими класами. XGBoost демонструє стабільно найвищі показники точності (зокрема, ROC-AUC) у порівняльних дослідженнях корпоративного дефолту [45, 58].

LightGBM: гістограмний підхід та leaf-wise зростання

LightGBM (Light Gradient Boosting Machine), запропонований в роботі [39], вирішує головне практичне обмеження XGBoost: обчислювальну неефективність при великих обсягах даних і високій розмірності ознак. Ключові алгоритмічні інновації LightGBM полягають у такому.

По-перше, це гістограмний алгоритм: замість пошуку оптимального порогу розгалуження серед усіх унікальних значень ознаки (складність $O(n)$ на ознаку), LightGBM дискретизує неперервні ознаки у B бінів (типово $B = 255$) та будує гістограму. Критерій розгалуження:

$$Gain(j, b) = \frac{G_L^2}{(H_L + \lambda)} + \frac{G_R^2}{(H_R + \lambda)} - \frac{(G_L + G_R)^2}{(H_L + H_R + \lambda)} \quad (2.14)$$

де G_L, G_R – суми градієнтів у лівому та правому листках; H_L, H_R – суми гесіанів; b – поріг розгалуження за j -ю ознакою. Пошук по гістограмі має складність $O(B)$ замість $O(n)$, що дає прискорення у n/B разів [39].

По-друге, leaf-wise (найкращий листок) принцип зростання дерева: замість level-wise (пошарового) розширення, де всі листки поточного рівня розгалужуються, LightGBM завжди розгалужує лише той листок, що дає найбільший приріст функції (2.14). Це дозволяє будувати глибші, асиметричні дерева, які краще апроксимують складні нелінійні залежності, хоча й потребує обережного обмеження глибини для уникнення перенавчання [39].

По-третє, GOSS (Gradient-based One-Side Sampling): замість навчання на всіх спостереженнях, LightGBM зберігає всі спостереження з великими градієнтами (де модель помиляється найбільше) та випадково вибирає підмножину спостережень з малими градієнтами. Для задачі з незбалансованими класами це означає, що рідкісні банкрути (клас 1) з великими градієнтами завжди потрапляють до навчальної підвибірki – природне вирішення проблеми незбалансованості на рівні алгоритму [39, 45].

У порівняльних бенчмарках на датасеті Polish Companies Bankruptcy Data LightGBM стабільно демонструє ROC-AUC, порівнянний або кращий за XGBoost, при значно меншому часі навчання [45, 58], що є вирішальним аргументом при оптимізації гіперпараметрів з Optuna.

Багатошаровий перцептрон (MLP): нелінійні представлення

Багатошаровий перцептрон (Multilayer Perceptron, MLP) є представником класу штучних нейронних мереж і виконує у стекінговому ансамблі специфічну роль: він здатний виявляти взаємодії ознак, що є принципово іншими за своєю природою, ніж ті, що фіксують деревні методи [37, 53].

Теорема про універсальну апроксимацію [53] гарантує, що MLP із достатньою шириною прихованого шару здатний апроксимувати будь-яку неперервну функцію на компактній множині з довільною точністю. На практиці це

означає, що нейронна мережа може вловлювати будь-які нелінійні взаємодії між фінансовими коефіцієнтами, включаючи ті, що залишаються поза межами дерево-орієнтованих алгоритмів.

Для регуляризації та запобігання перенавчанню застосовуються: *Dropout* [37] (випадкове відключення нейронів з імовірністю p^{drop} при навчанні), L_2 -регуляризація ваг (*weight decay*), а також рання зупинка (*early stopping*) на валідаційній вибірці.

Обмеженням MLP у контексті задачі є вища чутливість до масштабу вхідних ознак (вимагає стандартизації), тривалість навчання порівняно з деревними методами та схильність до перенавчання на відносно невеликих вибірках. Ці недоліки компенсуються через ретельну регуляризацію та підбір гіперпараметрів засобами Optuna [21].

Обґрунтування різноманітності базових класифікаторів

Включення до ансамблю методів, настільки різних за своєю природою, є не випадковим, а принципово мотивованим. Ефективність стекінгової моделі визначається не лише якістю окремих базових класифікаторів, але й їхньою різноманітністю (*diversity*): якщо базові моделі роблять помилки на різних підмножинах спостережень, їхня комбінація дозволяє скоротити загальну кількість помилок [57].

Формально це впливає з декомпозиції помилки ансамблю:

$$Error_{ensemble} = \overline{Error}_{base} - \overline{Diversity} \quad (2.15)$$

де $\overline{Error}_{base}$ – середня помилка базових класифікаторів; $\overline{Diversity}$ – середня коваріація помилок між ними [57]. Чим нижча кореляція між помилками базових моделей, тим ефективнішим є ансамбль.

Саме тому до складу ансамблю включено принципово різnorідні методи ML: параметричний лінійний (LR), непараметричний бегінг (RF), послідовний бустинг (XGBoost), гістограмний бустинг з leaf-wise зростанням (LightGBM) та нейронна мережа (MLP).

В табл. 2.2 наведено характеристики базових класифікаторів та їхня роль у запропонованій стекінговій моделі.

Таблиця 2.2 – Характеристика базових класифікаторів та їхня роль у стекінговому ансамблі.

Класифікатор	Клас методів	Нелінійність	Інтерпретованість	Обробка пропусків	Роль в ансамблі
LR	Лінійний, параметричний	Відсутня	Висока (коэф. β)	Ні (потребує імпутації)	Лінійна базова лінія; висока інтерпретованість для Basel III
RF	Нелінійний, бегінг	Висока	Середня (MDI)	Часткова (сурогатні розгалуження)	Стабільний нелінійний прогноз; низька дисперсія
XGBoost	Нелінійний, бустинг	Дуже висока	Низька (з SHAP середня)	Так (нативна)	Висока точність; регуляризований бустинг з гессіаном
LightGBM	Нелінійний, бустинг	Дуже висока	Низька (з SHAP середня)	Так (нативна)	Швидкість; leaf-wise глибина; GOSS для незбалансованості
MLP	Нейронна мережа	Дуже висока	Дуже низька	Ні (потребує імпутації та масштабування)	Представлення, недоступні деревним методам; гладкі нелінійності

Джерело: складено автором на основі [27, 28, 37, 39, 53]

Аналіз табл. 2.2 підтверджує, що п'ять обраних класифікаторів формують методологічно різноманітний ансамбль: вони різняться за принципом навчання (параметричні, непараметричні), способом агрегування (бегінг, бустинг, градієнтний спуск), характером нелінійності (кускова, константна, гладка) та вимогами до попередньої обробки даних.

Саме ця різноманітність забезпечує виконання умови (2.15) та дозволяє стекінговій мета-моделі суттєво перевершити будь-який з базових класифікаторів окремо [57].

Порівняльна оцінка моделей за орієнтовними значеннями *ROC-AUC* на датасеті Polish Companies Bankruptcy Data наведена на рис. 2.3.




Рисунок 2.3 – Порівняльна характеристика методів ML (*ROC-AUC* та радарна діаграма).

Спосіб, у який прогнози цих п'яти класифікаторів комбінуються у стекінговій архітектурі із застосуванням OOF крос-валідації для запобігання витоку даних, детально розглядається у підрозділі 2.4.

2.3 Система метрик якості класифікації для незбалансованих даних

Вибір системи метрик якості є не менш важливим методологічним рішенням, ніж вибір самого алгоритму навчання. Як встановлено у підрозділі 2.1, незбалансованість класів (*IR* від 13 до 25) робить традиційну метрику загальної точності (*Accuracy*) практично непридатною: модель, що завжди прогнозує «не дефолт», матиме *Accuracy* $\approx 94\text{-}97\%$ при повній нездатності виявити жоден реальний дефолт [44, 45]. Водночас регуляторні стандарти Basel III та банківська практика IRB-підходу висувають специфічні вимоги до системи оцінювання, зокрема, здатність вимірювати дискримінуючу силу моделі⁴ та якість калібрування

⁴ У контексті машинного навчання та статистики термін "дискримінація" (discrimination) означає виключно здатність розрізняти (розділяти) два класи об'єктів (наприклад, "поверне кредит" проти "не поверне")

ймовірностей [3, 11]. У цьому підрозділі детально розглянуто повну систему метрик, застосованих у дослідженні.

Матриця класифікації та базові метрики

Фундаментом будь-якої системи оцінювання є матриця класифікації (*confusion matrix*), що систематизує чотири можливих результати бінарної класифікації [37, 45]. Таблиця 2.3 наводить структуру матриці з банківською інтерпретацією кожної клітинки.

В контексті банківського кредитного ризику асиметрія наслідків є принциповою: *FN*-помилка (пропущений банкрут) у 2,5-5 разів дорожча за *FP*-помилку (хибна тривога), що вимагає відповідного зміщення порогу τ^* та використання метрик, чутливих до цієї асиметрії [45, 51].

Таблиця 2.3 – Матриця класифікації для задачі прогнозування дефолту

	Прогноз: ДЕФОЛТ (1)	Прогноз: НЕ ДЕФОЛТ (0)
Факт: ДЕФОЛТ (1)	<i>TP</i> – True Positive Правильно виявлений банкрут → банк уникає збитків $EAD \times LGD$	<i>FN</i> – False Negative Пропущений дефолт → ПРЯМИЙ ЗБИТОК банку
Факт: НЕ ДЕФОЛТ (0)	<i>FP</i> – False Positive Хибна тривога → втрачений процентний дохід	<i>TN</i> – True Negative Правильно схвалений надійний позичальник → дохід банку

Джерело: складено автором на основі [37, 45]

На основі матриці визначаються базові метрики:

$$Precision = TP / (TP + FP). \quad (2.16)$$

$$Recall = TP / (TP + FN). \quad (2.17)$$

$$Specificity = TN / (TN + FP), \quad (2.18)$$

де *Precision* – частка справжніх дефолтів серед усіх позичальників, яких модель класифікувала як дефолтних; *Recall* (чутливість, *TPR*) – частка виявлених реальних дефолтів серед усіх фактичних дефолтів; *Specificity* (*TNR*) – частка правильно класифікованих платоспроможних позичальників.

Між *Recall* та *Precision* існує фундаментальний компроміс (*Precision-Recall trade-off*): зниження порогу τ підвищує *Recall*, але знижує *Precision*. Для задачі корпоративного кредитного ризику пріоритет надається максимізації *Recall* при прийнятному рівні *Precision* [45, 51].

Узагальненою мірою балансу між *Precision* та *Recall* є $F\beta$ -міра, де параметр β регулює відносну вагу:

$$F\beta = (1 + \beta^2) \cdot Precision \cdot Recall / (\beta^2 \cdot Precision + Recall). \quad (2.19)$$

При $\beta = 1$ отримуємо класичну F_1 -міру (рівна вага); при $\beta = 2$ – F_2 -міру, що вдвічі більше “цінує” *Recall* і є стандартом для задач з асиметричною вартістю помилок у кредитному скорингу [37, 45]. Однак жодна з наведених метрик не є самодостатньою при $IR > 10$ – вони мають застосовуватись у комплексі з порогово-незалежними метриками.

ROC-крива та показник AUC

ROC-крива (*Receiver Operating Characteristic*) є основним інструментом оцінювання дискримінуючої здатності моделі у банківській валідаційній практиці [33, 45]. Вона будується у координатах *TPR* (*Recall*) та *FPR* при варіюванні порогу τ від 0 до 1:

$$FPR(\tau) = \frac{FP(\tau)}{FP(\tau) + TN(\tau)}, TPR(\tau) = \frac{TP(\tau)}{TP(\tau) + FN(\tau)} \quad (2.20)$$

Площа під ROC-кривою (*AUC* – *Area Under the Curve*) обчислюється через інтеграл:

$$AUC = \int_0^1 TPR(FPR) d(FPR) \quad (2.21)$$

і має важливу імовірнісну інтерпретацію: AUC – це ймовірність того, що для випадково обраної пари (один дефолт, один не-дефолт) модель присвоїть вищий прогнозований PD підприємству-банкруту [33, 37].

При $AUC = 0,5$ модель не відрізняється від випадкового вибору; $AUC = 1,0$ відповідає ідеальному класифікатору. Шкала інтерпретації значення $ROC-AUC$ для задач корпоративного кредитного ризику [3, 45] така:

$AUC \in [0,90;1,00]$ – відмінна дискримінація;

$[0,80;0,90)$ – добра;

$[0,70; 0,80)$ – задовільна;

нижче 0,70 – недостатня для регуляторної валідації Basel III.

$ROC-AUC$ є однією із основних метрик для порівняння моделей у цій роботі, оскільки вона не залежить від вибраного порогу τ та від абсолютного співвідношення класів у вибірці, що робить її придатною для порівняння результатів між різними часовими зрізами датасету з різним IR [33, 45].

Коефіцієнт Джині та KS-статистика

Коефіцієнт Джині (*Gini coefficient*) є стандартною метрикою банківської валідації IRB-моделей, безпосередньо пов'язаною з AUC [3, 11]:

$$Gini = 2 \cdot AUC - 1. \quad (2.22)$$

Він змінюється в діапазоні $[0; 1]$: $Gini=0$ відповідає відсутності дискримінуючої сили ($AUC=0,5$); $Gini=1$ – для ідеальній моделі. У практиці банківської валідації Basel III мінімально прийнятним вважається $Gini \geq 0,30$ для корпоративних портфелів [3, 11]. Перевагою $Gini$ над AUC є її більш інтуїтивна інтерпретація у процентному вираженні: наприклад, $Gini=0,70$ означає, що модель дискримінує 70% від теоретично можливого максимуму.

KS-статистика (*Kolmogorov-Smirnov statistic*) вимірює максимальне розділення між кумулятивними розподілами прогнозованих ймовірностей для дефолтних і платоспроможних підприємств:

$$KS = \max_{\tau} |TPR(\tau) - FPR(\tau)|. \quad (2.23)$$

Геометрично KS – це максимальна вертикальна відстань між ROC -кривою та діагоналлю випадкового класифікатора.

KS -статистика широко використовується у скорингових системах для визначення оптимального порогу відсічення: максимум у формулі (2.23) досягається при $\tau^* = \arg \max_{\tau} |TPR(\tau) - FPR(\tau)|$, що відповідає точці найкращого розділення класів [45]. Прийнятним для корпоративного скорингу вважається $KS \geq 0,30$ [11].

PR-AUC: площа під кривою Precision-Recall

При суттєвій незбалансованості класів $ROC-AUC$ може давати надто оптимістичну оцінку якості моделі, оскільки велика кількість платоспроможних підприємств у вибірці (TN) “утримує” FPR на низькому рівні навіть при значній кількості FP [37, 45]. За таких умов більш інформативною є крива *Precision-Recall* та площа під нею ($PR-AUC$, також відома як *Average Precision*):

$$PR-AUC = \int_0^1 Precision(Recall) d(Recall) \quad (2.24)$$

На відміну від $ROC-AUC$, $PR-AUC$ безпосередньо вимірює здатність моделі виявляти дефолти без «розбавлення» великою кількістю коректно класифікованих платоспроможних підприємств. Нижня базова лінія для $PR-AUC$ дорівнює частці позитивного класу $\pi_1 = N_1/N$ (що для нашого датасету становить 3,9-6,9% залежно від зрізу), тоді як для $ROC-AUC$ базова лінія – 0,5 [37]. У дипломній роботі $PR-AUC$ використовується як допоміжна метрика поряд із $ROC-AUC$ для отримання повної картини дискримінуючої здатності при незбалансованості.

Ілюстрацію метрик $ROC-AUC$ та $PR-AUC$ для класифікаторів із різною дискримінуючою здатністю наведено на рис. 2.4.




Рисунок 2.4 – Концептуальна ілюстрація метрик ROC-AUC та PR-AUC для класифікаторів із різною дискримінуючою здатністю. Джерело: побудовано автором на основі [33, 37, 45]

Brier Score: оцінювання калібрування ймовірностей

Усі метрики, розглянуті вище, оцінюють *ранжувальну* здатність моделі – наскільки правильно вона впорядковує позичальників за рівнем ризику. Однак для *IRB*-підходу Basel III важливим є також *калібрування* ймовірностей: прогнозована ймовірність дефолту $\hat{p}_i$ має відповідати реальній частоті дефолтів серед підприємств із схожим профілем ризику [3, 11]. Некалібрована модель може коректно ранжувати позичальників (висока *AUC*), але систематично занижувати або завищувати абсолютний рівень *PD*, що спричиняє помилкові розрахунки регуляторного капіталу за формулою (1.1).

Brier Score вимірює середньоквадратичну різницю між прогнозованою ймовірністю та фактичною міткою класу [37]:

$$BS = \frac{1}{N} \cdot \sum_{i=1}^N (\hat{p}_i - y_i)^2, \quad (2.25)$$

де $\hat{p}_i \in [0,1]$ – прогнозована ймовірність дефолту; $y_i \in \{0,1\}$ – фактична мітка. *Brier Score* змінюється від 0 (ідеальний прогноз) до 1 (найгірший).

Для незбалансованих задач використовується нормалізований *Brier Skill Score*:

$$BSS = 1 - BS/BS_{ref}, \quad (2.26)$$

де $BS_{ref} = \pi^1(1 - \pi^1)$ – Brier Score для тривіальної моделі, що завжди прогнозує $\hat{p}_i = \pi_1$ (базова частота дефолтів).

$BSS > 0$ означає, що модель перевершує тривіальну; $BSS = 1$ – ідеальне калібрування. Для перевірки калібрування також будується *Reliability Diagram* (графік калібрування): порівняння середнього прогнозованого PD з фактичною частотою дефолтів у кожному децилі розподілу [37].

Зведена система метрик та їх застосування

В Таблиці 2.4 наведено систематизовану повну систему метрик, що використовується у цій роботі, із зазначенням формул, діапазонів значень, ролі у дослідженні та мінімальних вимог Basel III.

Важливим є розуміння того, що жодна з наведених метрик не є самодостатньою. *ROC-AUC* та *Gini* оцінюють ранжувальну здатність, але нечутливі до якості калібрування. *PR-AUC* є більш чутливою до незбалансованості, але залежить від абсолютного рівня *IR*. *Brier Score* вимірює загальну точність прогнозованих ймовірностей, але може приховувати проблеми ранжування.

Тому у Розділі 3 використовується вся система метрик таблиці 2.5, що дозволяє отримати багатовимірну, регуляторно обґрунтовану оцінку якості розробленої стекінгової моделі відносно базових класифікаторів [3, 11, 33, 45].

Таблиця 2.4 – Система метрик якості моделей оцінювання кредитного ризику

Метрика	Форм.	Діапазон	Тип оцінки	Basel III	Переваги	Роль у дослідженні
ROC-AUC	(2.21)	[0,5; 1,0]	Ранжувальна	$\geq 0,70$	Не залежить від τ та IR	Основна метрика порівняння
Gini	(2.22)	[0; 1]	Ранжувальна	$\geq 0,30$	Банківська інтерпретація у %	Регуляторна валідація IRB

KS	(2.23)	[0; 1]	Ранжувальна	$\geq 0,30$	Визначає оптимальний τ^*	Вибір порогу відсічення
PR-AUC	(2.24)	$[\pi_1; 1]$	Ранжувальна	–	Чутлива до IR; не залежить від TN	Допоміжна при незбалансов.
F₂-mipa	(2.19)	[0; 1]	Порогова ($\beta=2$)	–	Пріоритет Recall; банк. контекст	Оптимізація τ^* ($\arg \max F_2$)
Brier Score	(2.25)	$[0; 1] \downarrow$ мін.	Калібрування	Мінімізація	Вимірює точність прогноз. PD	Перевірка для EL-формули
BSS	(2.26)	$(-\infty; 1]$	Калібрування	> 0	Відносне калібрування	Регуляторний звіт

Джерело: складено автором на основі [3, 11, 33, 37, 45]

Таким чином, розроблена система метрик відповідає одночасно двом вимогам: науковій строгості через повне покриття аспектів дискримінації, калібрування та стійкості до незбалансованості, та регуляторній прийнятності в рамках *IRB*-підходу Basel III. Поєднання методологічних рішень підрозділів 2.1-2.3 формує повний аналітичний апарат для обґрунтування та оцінювання стекінгової архітектури, опис якої є предметом наступного підрозділу.

2.4 Розробка моделі оцінювання кредитного ризику на основі ансамблевих алгоритмів

Попередні підрозділи сформували повний методологічний апарат, зокрема, було визначено та математично формалізовано задачу (підрозділ 2.1), а також обґрунтовано вибір базових класифікаторів (підрозділ 2.2). Цей параграф інтегрує всі ці компоненти у цілісну архітектуру ансамблевої моделі, описує алгоритм її навчання, механізм байєсівської оптимізації гіперпараметрів та методологію інтерпретації прогнозів засобами SHAP-аналізу.

Концепція ансамблевої моделі на основі стекінгового узагальнення

Стекінгове узагальнення (stacked generalization), запропоноване в роботі [57], є методом ансамблевого навчання, де прогнози кількох різнорідних базових моделей першого рівня використовуються як ознаки для навчання мета-моделі другого рівня. На відміну від простого усереднення прогнозів, мета-модель навчається в такий спосіб, щоб оптимально зважувати базові класифікатори з урахуванням їхньої відносної якості та кореляції помилок на обраному датасеті.

Формально дворівнева стекінгова архітектура визначається так.

Рівень 0 (базові класифікатори): множина з M алгоритмів $\{h_1, h_2, \dots, h_M\}$, кожен з яких навчається на вхідному ознаковому просторі $\mathcal{X} = \mathbb{R}^{64}$ та генерує вектор прогнозованих ймовірностей:

$$\varphi(\mathbf{x}_i) = (h_1(\mathbf{x}_i), h_2(\mathbf{x}_i), \dots, h_M(\mathbf{x}_i))^T \in [0,1]^M \quad (2.27)$$

Рівень 1 (мета-модель): алгоритм g , що навчається у трансформованому просторі мета-ознак $\mathcal{Z} = [0,1]^M$ та продукує фінальний прогноз:

$$\hat{p}^{stack} = g(\varphi(\mathbf{x}_i)) = g(h_1(\mathbf{x}_i), h_2(\mathbf{x}_i), \dots, h_M(\mathbf{x}_i)) \quad (2.28)$$

У цій роботі $M = 5$ базових класифікаторів (LR, RF, XGBoost, LightGBM, MLP), що утворюють вектор мета-ознак розмірності 5. Принципова перевага стекінгу перед простим усередненням полягає в тому, що мета-модель g навчається в такий спосіб, щоб оптимально зважувати прогнози базових класифікаторів з урахуванням їхньої відносної якості (точності) та кореляції помилок, тоді як рівноважне усереднення ігнорує ці відмінності [57]. Схема дворівневої архітектури наведена на рис. 1А (Додатки).

OOF крос-валідація: запобігання витоку даних

Центральною методологічною проблемою стекінгу є ризик витоку даних (*data leakage*): якщо базові класифікатори генерують прогнози $\varphi(x_i)$ на тих самих спостереженнях, на яких вони навчались, ці прогнози будуть надмірно оптимістичними і мета-модель g навчиться їм надмірно довіряти, що призводить до значного перенавчання всього ансамблю [57].

Навчальна вибірка $\mathcal{D}_{train}$ розбивається на $K=5$ стратифікованих фолдів (StratifiedKFold, що зберігає пропорцію класів у кожному фолді). Для кожної ітерації $k = 1, \dots, K$:

$$D_{train}^{(k)} = D_{train} \setminus F_k, \quad D_{val}^{(k)} = F_k \quad (2.29)$$

На k -й ітерації кожен базовий класифікатор h_m навчається на вибірці $D_{train}^{(k)}$ (після застосування SMOTE та генерує прогнози виключно на валідаційному фолді:

$$\hat{p}_{i,m}^{OOF} = h_m^{(k)}(\mathbf{x}_i), \quad \forall \mathbf{x}_i \in F_k \quad (2.30)$$

Після завершення всіх K ітерацій кожне спостереження отримує OOF-прогноз, зроблений на даних, що не брали участі в навчанні. Матриця OOF-прогнозів, що має вигляд:

$$\mathbf{Z}_{train} = [\hat{p}_{i,m}] \in [0,1]^{N \times M}, \quad i = 1, \dots, N; m = 1, \dots, M \quad (2.31)$$

є незміщеним відображенням здатності базових класифікаторів до узагальнення та слугує навчальною вибіркою для мета-моделі g . Схему OOF крос-валідації наведено на Рис. 2.5.




Рисунок 2.5 – Схема OOF крос-валідації ($K=5$, StratifiedKFold) для генерації матриці мета-ознак Z_{train}

Навчання мета-моделі та вибір її архітектури

Мета-модель g навчається на матриці Z_{train} (формула 2.20) з цільовою змінною y_{train} . Вибір архітектури мета-моделі визначається компромісом між інтерпретованістю та прогностичною точністю. У цій роботі розглядаються два кандидати: логістична регресія та XGBoost як мета-модель.

Логістична регресія як мета-модель забезпечує максимальну прозорість: коефіцієнти β^m при кожному базовому класифікаторі безпосередньо вказують на відносну довіру до його прогнозів та допускають регуляторне обґрунтування:

$$\hat{p}^{stack} = \sigma(\beta_0 + \sum_{m=1}^M \beta_m \cdot \hat{p}_m^{OOF}). \quad (2.32)$$

XGBoost як мета-модель здатний виявляти нелінійні взаємодії між прогнозами базових класифікаторів, наприклад, ситуації, де комбінація «висока

ймовірність за XGBoost + низька за LR» є більш інформативною, ніж кожен прогноз окремо. Однак він менш прозорий з регуляторної точки зору.

Остаточний вибір мета-моделі здійснюється за критерієм *ROC-AUC* на валідаційній вибірці в ході експериментів Розділу 3. При рівних або незначно кращих показниках XGBoost пріоритет надається логістичній регресії як більш інтерпретованій для регуляторних цілей Basel III [3, 57].

Перелік алгоритмів, що було включено в ансамблеву стекінгову модель оцінки ризику корпоративних позичальників наведено в табл. 2.5.

Таблиця 2.5 – Архітектура стекінгової моделі оцінювання кредитного ризику.

Компонент	Алгоритм	Вхідний простір	Вихідний простір	Роль
Базовий класиф. 1	LR	$\mathbb{R}^{64}$	[0,1]	Лінійна базова лінія; висока інтерпретованість
Базовий класиф. 2	Random Forest	$\mathbb{R}^{64}$	[0,1]	Стабільний нелінійний прогноз; низька дисперсія
Базовий класиф. 3	XGBoost	$\mathbb{R}^{64}$	[0,1]	Регуляризований бустинг; нативна обробка пропусків
Базовий класиф. 4	LightGBM	$\mathbb{R}^{64}$	[0,1]	Швидкість; leaf-wise глибина; GOSS
Базовий класиф. 5	MLP	$\mathbb{R}^{64}$	[0,1]	Гладкі нелінійні представлення
Мета-модель	LR або XGBoost	[0,1] ⁵	[0,1]	Оптимальне зважування базових класифікаторів

Джерело: складено автором на основі [21, 27, 28, 37, 39, 57]

Байєсівська оптимізація гіперпараметрів засобами Optuna

Кожен базовий класифікатор характеризується набором гіперпараметрів, що суттєво впливають на якість прогнозів та різноманітність ансамблю. Ручний перебір або Grid Search є неефективними через комбінаторний вибух: для XGBoost простір пошуку включає швидкість навчання, глибину дерева, кількість дерев,

параметри регуляризації, частку ознак та спостережень, що дає сотні тисяч комбінацій.

У цій роботі застосовано байєсівську оптимізацію гіперпараметрів засобами фреймворку Optuna [21]. На відміну від Grid/Random Search, байєсівська оптимізація будує імовірнісну сурогатну модель цільової функції та використовує алгоритм Tree-structured Parzen Estimator (TPE):

$$h^* = \operatorname{argmax}_{h \in \mathcal{H}} \text{AUC}_{\text{val}}(f(\cdot; h)) \quad (2.33)$$

де h – вектор гіперпараметрів; $\mathcal{H}$ – простір пошуку. Це дозволяє зосередити ресурси у перспективних областях простору, досягаючи якості Grid Search за значно меншої кількості ітерацій (як правило, 100-300 замість тисяч).

Перелік гіперпараметрів для фін-тьюнінгу та їх діапазони налаштування для обраних базових класифікаторів наведено у підрозділі 3.3.

SHAP-інтерпретація: від «чорної скриньки» до регуляторної прозорості

Навіть після навчання стекінгової моделі з високим ROC-AUC її регуляторне застосування в рамках IRB-підходу Basel III є неможливим без механізму пояснення індивідуальних рішень [3, 48]. Технологія SHAP (Shapley Additive Explanations) [48] забезпечує теоретично обґрунтовану декомпозицію прогнозу на внески окремих ознак через апарат теорії кооперативних ігор.

SHAP-значення мають три ключові властивості, що роблять їх придатними для банківської регуляторної валідації.

По-перше, ефективність: сума SHAP-значень по всіх ознаках дорівнює різниці між індивідуальним прогнозом та середнім прогнозом моделі:

$$\sum_{j=1}^{64} \varphi(\mathbf{x}_i) = \hat{p}_i - \mathbb{E}[\hat{p}] \quad (2.34)$$

По-друге, симетрія: якщо дві ознаки роблять однаковий внесок у прогноз у всіх підмножинах, їхні SHAP-значення рівні.

По-третє, відсутність фіктивного внеску: ознака, що не впливає на прогноз, отримує SHAP-значення рівне нулю.

Для практичного застосування у банківській валідації використовуються три типи SHAP-візуалізацій:

- *Summary plot* відображає розподіл SHAP-значень для всіх ознак по всій вибірці, впорядкований за середньою абсолютною важливістю, що дає глобальне розуміння факторів дефолту;
- *Dependence plot* показує залежність SHAP-значення конкретної ознаки від її числового значення, що дозволяє виявляти нелінійні та порогові ефекти;
- *Waterfall plot* для конкретного позичальника розкладає його прогнозований *PD* на внески окремих фінансових коефіцієнтів, що забезпечує пояснення кожного індивідуального кредитного рішення відповідно до вимог Basel III [3, 48].

Повний алгоритм навчання та інференсу

Підсумовуючи, можна подати повний алгоритм функціонування розробленої системи так.

Фаза навчання:

1. Розбиття D_{train} на $K=5$ стратифікованих фолдів.
2. Для кожного фолду $k=1,2,\dots,5$: застосування алгоритму SMOTE до $D_{train}^{(k)}$; навчання 5 базових класифікаторів з оптимізованими гіперпараметрами (Optuna); генерація OOF-прогнозів.
3. Формування матриці мета-ознак $\mathbf{Z}_{train}$.
4. Навчання мета-моделі g на вибірці $(\mathbf{Z}_{train}, y_{train})$.
5. Перенавчання кожного базового класифікатора на повній вибірці $\mathbf{Z}_{train}$ для інференсу⁵.

Фаза інференсу (для нового позичальника $\mathbf{x}^*$):

⁵ У контексті скорингу (оцінки кредитоспроможності) *інференс* для нового позичальника – це процес автоматичного ухвалення рішення про видачу кредиту на основі даних, які ця людина щойно подала в заявці.

$$\hat{p}^* = g(h^1(\mathbf{x}^*), h^2(\mathbf{x}^*), h^3(\mathbf{x}^*), h^4(\mathbf{x}^*), h^5(\mathbf{x}^*)). \quad (2.35)$$

$$\hat{y}^* = \mathbb{1}[\hat{p}^* \geq \tau^*], \text{ SHAP: } \varphi_j(\mathbf{x}^*), \forall j = 1, \dots, 64, \quad (2.36)$$

де τ^* – оптимальний поріг, визначений за кривою Precision-Recall; $\varphi_j(\mathbf{x}^*)$ – SHAP-значення для пояснення рішення. Час інференсу для одного позичальника не перевищує 50 мс, що є достатнім для інтеграції у реальний процес кредитного андерайтингу [3].

Блок-схему повної архітектури стекінгової ансамблевої моделі оцінювання кредитного ризику для корпоративних клієнтів наведено на Рис. 2.6.




Рисунок 2.6 – Повна архітектура стекінгової ансамблевої моделі оцінювання кредитного ризику.

Таким чином, розроблена архітектура поєднує методологічну строгість (OOF крос-валідація запобігає витоку даних, байєсівська оптимізація забезпечує ефективний підбір гіперпараметрів) з регуляторною прийнятністю (SHAP-інтерпретація відповідає вимогам Basel III щодо пояснюваності рейтингових рішень). Практична реалізація цієї архітектури у середовищі Python 3.11 (Google

Colaboratory), результати експериментальної валідації та порівняльний аналіз моделей є предметом Розділу 3.

Висновки до розділу 2

У другому розділі роботи розроблено методологічний підхід до оцінювання кредитного ризику корпоративних позичальників на основі ансамблевих алгоритмів машинного навчання. За результатами проведених досліджень можна сформулювати такі основні висновки.

1. Здійснено системну формалізацію задачі прогнозування дефолту корпоративного позичальника як задачі бінарної класифікації з асиметричною вартістю помилок. Обґрунтовано узгодженість запропонованої постановки з регуляторною формулою очікуваних кредитних втрат відповідно до вимог IRB-підходу Basel III.

2. Проведено порівняльний аналіз п'яти базових класифікаторів першого рівня стекінгового ансамблю (логістичної регресії, Random Forest, XGBoost, LightGBM та багатoshарового перцептрону) за ключовими критеріями: здатністю фіксувати нелінійні взаємодії, інтерпретованістю, стійкістю до аномальних значень та нативною обробкою пропущених значень. Обґрунтовано, що методологічна різноманітність обраних класифікаторів забезпечує різноманітність ансамблю, що є необхідною умовою ефективності стекінгового узагальнення.

3. Розроблено комбіновану трирівневу стратегію вирішення проблеми незбалансованості класів у задачі корпоративного кредитного скорингу: надмірне семпсування класу меншості засобами SMOTE на рівні даних, зважування функції втрат через `class_weight` та `scale_pos_weight` на рівні алгоритму, та оптимізація порогу класифікації через максимізацію F_2 -міри на рівні рішення. Обґрунтовано критичне правило застосування SMOTE виключно до тренувальних фолдів для запобігання витоку даних та завищення оцінок якості моделей.

4. Сформовано систему метрик регуляторної валідації, що охоплює всі аспекти оцінювання якості моделей кредитного ризику: ранжувальні метрики (ROC-AUC, Gini-коефіцієнт, KS-статистика, PR-AUC) та метрики калібрування ймовірностей (Brier Score, Brier Skill Score, F_2 -міра). Обґрунтовано використання мінімальних порогових значень Basel III: $AUC \geq 0,70$ та $Gini \geq 0,30$ як регуляторних бенчмарків для фінальної оцінки придатності розробленої системи до практичного впровадження.

5. Розроблено дворівневу стекінгову архітектуру оцінювання кредитного ризику для корпоративних клієнтів та визначено принципи її функціонування. Ключовим елементом архітектури є Out-of-Fold крос-валідація з п'ятьма фолдами, що забезпечує генерацію незміщеної матриці мета-ознак без витоку інформації між навчальною та валідаційною підвибірками. Навчання мета-моделі другого рівня на отриманій матриці мета-ознак реалізує оптимальне зважування базових класифікаторів з урахуванням їхньої відносної якості та взаємодоповнюваності.

6. Включено байєсівську оптимізацію гіперпараметрів засобами фреймворку Optuna з алгоритмом Tree-structured Parzen Estimator як обов'язковий компонент пайплайну навчання. Обґрунтовано перевагу байєсівського підходу над Grid Search та Random Search за критерієм ефективності використання обчислювальних ресурсів при пошуку оптимальних конфігурацій у комбінаторному просторі гіперпараметрів п'яти базових класифікаторів. Включення SHAP-аналізу як обов'язкового компонента вирішує ключову суперечність між прогностичною точністю ансамблевих методів та регуляторними вимогами Basel III щодо пояснюваності індивідуальних рейтингових рішень.

Розроблений методичний підхід інтегрує результати всіх підрозділів другого розділу у цілісну архітектуру стекінгової системи оцінювання кредитного ризику, практична реалізація та експериментальна валідація якої є предметом третього розділу

РОЗДІЛ 3

РЕАЛІЗАЦІЯ ТА ЕКСПЕРИМЕНТАЛЬНА ВАЛІДАЦІЯ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ ОЦІНЮВАННЯ КРЕДИТНОГО РИЗИКУ

3.1 Вибір інформаційної бази дослідження та її основних характеристик

Якість і репрезентативність інформаційної бази є визначальним чинником достовірності результатів будь-якого дослідження у галузі машинного навчання: навіть методологічно бездоганна архітектура моделі не здатна компенсувати системні вади вхідних даних [37, 45]. У цьому підрозділі обґрунтовано вибір датасету, що слугує інформаційною основою дослідження, детально охарактеризовано його структуру, статистичні властивості та обмеження.

Обґрунтування вибору публічного датасету

Специфіка корпоративного кредитного ризику висуває чіткі вимоги до інформаційної бази: дані мають відображати фінансовий стан підприємств через систему коефіцієнтів балансу та звіту про фінансові результати, містити чітко визначену бінарну цільову змінну та забезпечувати обсяг, достатній для навчання складних ансамблевих моделей з OOF крос-валідацією.

Використання реальних кредитних портфелів банківських установ є практично неможливим через чинне законодавство. Згідно з Законом України «Про банки і банківську діяльність» [1], інформація про фінансовий стан та діяльність клієнта банку є банківською таємницею і не підлягає розголошенню без окремого письмового дозволу клієнта. Натомість, використання верифікованих публічних наборів даних є усталеною практикою в академічній спільноті: воно забезпечує відтворюваність результатів та можливість незалежного порівняння з результатами інших дослідників [37, 45, 51].

При виборі інформаційної бази було проаналізовано чотири публічно доступні альтернативи, наведені у табл. 3.1.

Набір UCI German Credit містить лише 1 000 спостережень та 20 ознак, що характеризують переважно фізичних осіб (неприйнятний обсяг для навчання ансамблевих моделей). Датасети Lending Club та Home Credit орієнтовані виключно на споживче кредитування та не містять фінансових коефіцієнтів балансу, що є основою корпоративного кредитного аналізу. За результатами порівняльного аналізу для дослідження обрано Polish Companies Bankruptcy Data [38, 58].

Таблиця 3.1 – Порівняльний аналіз альтернативних наборів даних для дослідження корпоративного кредитного ризику

Датасет	Обсяг	Тип позичальника	Ознаки	Придатність
UCI German Credit	1 000	Фізичні особи	20 (змішані)	Малий обсяг; роздрібний сегмент
Lending Club	~2 млн	Фізичні особи / МСП	Поведінкові	Споживчий ринок США; немає фін. коеф.
Home Credit Default Risk	~300 тис.	Фізичні особи	Реляційні таблиці	Лише фізичні особи; висока складність
Polish Companies Bankruptcy	~43 000	Юридичні особи	64 фін. коефіцієнти	Повністю відповідає

Джерело: складено автором на основі [37, 38, 45]

Загальна характеристика датасету та розподіл цільової змінної

Датасет Polish Companies Bankruptcy Data сформований Інститутом економічних досліджень (IER, Польща) та опублікований Zieba et al. (2016) [58] у журналі *Expert Systems with Applications*. Дані зібрано з бази EMIS (Emerging Markets Information Service) – верифікованого комерційного постачальника фінансової інформації про компанії на ринках, що розвиваються. Датасет розміщено у репозиторіях UCI ML Repository та Kaggle [38] і широко використовується у бенчмаркінгових дослідженнях корпоративного дефолту [45, 51, 58].

Ключовою особливістю датасету є *темпоральна структура з п'яти річних зрізів*, де кожен зріз відповідає різному горизонту прогнозування до події банкрутства (табл. 3.2-3.3). Це дозволяє оцінити стабільність моделі в часі – обов'язкову вимогу Basel III до внутрішніх рейтингових систем [3].

Таблиця 3.2 – Загальна характеристика датасету Polish Companies Bankruptcy Data

Характеристика	Значення
Джерело	EMIS (Emerging Markets Information Service)
Публікація	Zieba et al., Expert Systems with Applications, 2016 [58]
Репозиторій	UCI ML Repository; Kaggle [38]
Часовий горизонт	2000-2013 pp.
Кількість часових зрізів	5 (year1 – year5)
Загальна кількість записів	~43 405
Кількість ознак	64 числові фінансові коефіцієнти
Цільова змінна	Бінарна: 1 – банкрутство, 0 – платоспроможне підприємство
Формат файлів	ARFF (конвертується у CSV через scipy.io.arff)
Наявність пропусків	Так (~1,2-1,9% комірок; окремі ознаки – до 40%)

Джерело: складено автором на основі [38, 58]

Структуру датасету по часових зрізах наведено у табл. 3.3, а розподіл цільової змінної подано на Рис. 3.1.

Таблиця 3.3 – Структура датасету по часових зрізах

Зріз	Горизонт прогнозу	Спостережень	Банкрутств	Платоспром.	Частка дефолту	IR
1st year	5 років	7 027	271	6 756	3,86%	24,9:1
2nd year	4 роки	10 173	400	9 773	3,93%	24,4:1
3rd year	3 роки	10 503	495	10 008	4,71%	20,2:1
4th year	2 роки	9 792	515	9 277	5,26%	18,0:1

5th year	1 рік	5 910	410	5 500	6,94%	13,4:1
Разом	–	43 405	2 091	41 314	~4,82%	~19,8:1

Джерело: складено автором на основі [38, 58]

Аналіз табл. 3.3 виявляє дві закономірності, принципово важливі для методологічних рішень дослідження.

По-перше, частка дефолтів зростає зі скороченням горизонту прогнозування – від 3,86% у 1st year до 6,94% у 5th year.

По-друге, IR у всіх зрізах перевищує 13:1, що підтверджує системний характер незбалансованості класів. Основний аналіз проводиться на 3rd year зрізі як найбільш репрезентативному за обсягом (10 503 спостережень) та горизонтом прогнозування (3 роки), що відповідає типовому терміну середньострокового корпоративного кредитування [3, 45].

Рис. 3.1 наочно демонструє монотонне зростання частки дефолтів зі скороченням горизонту прогнозування – від 3,86% у 1st year (горизонт 5 років) до 6,94% у 5th year (горизонт 1 рік), при одночасному звуженні Imbalance Ratio з 24,9:1 до 13,4:1. Така динаміка є логічною: чим ближчий момент спостереження до дати фактичного банкрутства, тим виразніше фінансовий стан підприємства відхиляється від норми, що полегшує його ідентифікацію моделлю.




Рисунок 3.1 – Розподіл цільової змінної по часових зрізах датасету (частка дефолтів та Imbalance Ratio). Джерело: побудовано автором.

Ознаковий простір: характеристика 64 фінансових коефіцієнтів

Усі 64 ознаки датасету є числовими фінансовими коефіцієнтами, розрахованими на основі балансу та звіту про фінансові результати підприємств. Назви ознак у вихідних файлах анонімізовані (Attr1-Attr64), однак їхня фінансова інтерпретація відновлюється з оригінальної публікації [58] та документації Kaggle [38]. У рамках системного аналізу ознаки класифіковано за п'ятьма аналітичними блоками кредитоспроможності (табл. 3.4).

Різноманіття ознакового простору (64 коефіцієнти проти 5 у моделі Альтмана [22]) є принциповою перевагою датасету для завдань машинного навчання: вона дозволяє моделі виявляти складні нелінійні взаємодії між показниками, недоступні для лінійних методів. Типи ознак охоплюють всі п'ять аналітичних блоків кредитоспроможності, визначених у підрозділі 1.2, що забезпечує узгодженість між теоретичним апаратом та емпіричною базою дослідження.

Таблиця 3.4 – Класифікація ознак датасету за аналітичними блоками кредитоспроможності

Аналітичний блок	Приклади ознак (за документацією Kaggle[38])	К-ть ознак
Ліквідність та платоспроможність	Поточна ліквідність; робочий капітал / активи; (грошові кошти + ЦП + дебіторка – зобов'язання) / операційні витрати × 365	~14
Фінансова стійкість (леверидж)	Борг / активи; власний капітал / активи; зобов'язання / власний капітал	~16
Рентабельність та ефективність	ROA; ROE; чистий прибуток / виручка; EBIT / активи	~15
Ділова активність	Виручка / активи; оборотність дебіторки; тривалість операційного циклу	~10
Покриття боргу	EBIT / відсоткові витрати (ICR); (чистий прибуток + амортизація) / загальний борг (DSCR)	~9
Разом		64

Джерело: складено автором на основі [38, 58]

Стратегія розбиття даних та аналіз пропущених значень

Датасет містить пропущені значення, що є реалістичним відображенням неповноти корпоративної фінансової звітності. Таблиця 3.5 характеризує масштаб пропусків у кожному зрізі.

Загальна частка пропусків на рівні комірок є відносно невисокою (1,2-1,9%), проте розподіл пропусків є нерівномірним: окремі ознаки (зазвичай ті, що вимагають деталізованих даних про структуру боргу або грошові потоки) мають значно вищий відсоток пропусків. З позицій системного аналізу пропуски розглядаються не як дефект датасету, а як відображення реальної інформаційної асиметрії між банком та позичальником – явища, яке кредитні аналітики зустрічають щодня. Додаткова перевірка показує, що для 12 ознак частка пропусків серед банкрутів на 3-8 відсоткових пунктів вища, ніж серед платоспроможних підприємств, що підтверджує часткову інформативність самого факту пропуску (Missing Not At Random, MNAR). Стратегія обробки пропущених значень (медіанна імпутація з індикаторами) описана у підрозділі 3.2.

Основний аналіз проводиться на 3rd year зрізі, розбитому на навчальну та тестову вибірки у співвідношенні 80/20 із застосуванням стратифікованого розбиття (StratifiedShuffleSplit), що зберігає пропорцію класів в обох підвибірках.

Обмеження обраної інформаційної бази

Необхідно явно зазначити обмеження обраної інформаційної бази.

По-перше, датасет сформований на основі даних польських підприємств 2000-2013 рр., що потребує обережності при екстраполяції висновків на українські реалії з огляду на відмінності в обліковій практиці та макроекономічних умовах [8].

По-друге, часовий горизонт 2000-2013 рр. не охоплює наслідки пандемії COVID-19 та воєнно-економічних шоків 2022-2025 рр.

По-третє, анонімізація назв ознак (Attr1-Attr64) обмежує можливість глибокої галузевої інтерпретації SHAP-результатів. Зазначені обмеження є характерними для академічних досліджень, що використовують публічні датасети,

та не підривають методологічної цінності роботи, оскільки її головна мета – розробка та валідація архітектури стекінгової моделі, а не прогнозування дефолту конкретних підприємств.

Таким чином, датасет Polish Companies Bankruptcy Data відповідає всім ключовим вимогам до інформаційної бази цього дослідження: охоплює виключно корпоративних позичальників, містить достатній обсяг спостережень для навчання стекінгової моделі з OOF крос-валідацією, відтворює реалістичну незбалансованість класів та темпоральну структуру, сумісну з вимогами Basel III щодо стабільності рейтингових систем [3, 45, 58]. Характеристики сформованої вибірки та результати первинного дослідницького аналізу даних.

3.2 Розвідувальний аналіз даних та підготовка інформаційної бази до навчання ансамблевої стекінгової моделі

Якість прогностичної моделі визначається не лише архітектурою алгоритму навчання, але й глибиною розуміння структури вхідних даних. Дослідницький аналіз даних (Exploratory Data Analysis, EDA) є обов'язковим передмодельним етапом, що дозволяє виявити статистичні закономірності, аномалії та взаємозв'язки між ознаками, які безпосередньо впливають на методологічні рішення з препроцесингу [37, 45]. У цьому підрозділі систематично описано всі кроки підготовки датасету Polish Companies Bankruptcy Data до навчання стекінгової моделі, а також реалізовано стратегію роботи з незбалансованими класами відповідно до Варіанту В, обґрунтованого в підрозділі 2.1.

Об'єднання часових зрізів та первинна структура вибірки

Вихідний датасет надається у форматі п'яти окремих ARFF-файлів (*1year.arff* – *5year.arff*). На першому кроці всі файли конвертуються у формат CSV засобами бібліотеки *scipy.io.arff* та об'єднуються в єдиний DataFrame за допомогою *pandas*. До об'єданого датафрейму додається технічна ознака *year_slice* (1-5) для ідентифікації часового зрізу кожного спостереження, що використовується при темпоральній валідації у підрозділі 3.4.

Після об'єднання первинна структура вибірки становить 43 405 рядків $\times$ 65 стовпців (64 фінансові ознаки + цільова змінна *target*). Розподіл цільової змінної підтверджує системну незбалансованість: 2 091 дефолт (4,82%) проти 41 314 платоспроможних підприємств (95,18%). Для подальшого аналізу в дипломній роботі було орано часовий зріз 3rd year ($N = 10\,503$).

Аналіз описових статистик та розподілів фінансових коефіцієнтів

Розрахунок описових статистик для всіх 64 ознак виявив характерні особливості фінансових коефіцієнтів. В табл. 3.5 наведено зведені статистики для п'яти ключових ознак, що репрезентують кожен аналітичний блок кредитоспроможності.

Аналіз табл. 3.5 виявляє дві принципові особливості. *По-перше*, сильна правостороння асиметрія ($|\text{skewness}| > 3$ для ~ 40 з 64 ознак): медіана суттєво нижча за середнє через важкі праві хвости, що є характерним для фінансових коефіцієнтів. *По-друге*, від'ємні середні при додатних медіанах для показників рентабельності: середнє ROA = -0,041 при медіані = 0,018 – це очевидний наслідок присутності підприємств з великими збитками, що є майбутніми банкрутами.

Таблиця 3.5 – Описові статистики ключових фінансових коефіцієнтів датасету (3rd year зріз, $N = 10\,503$)

Ознака (умовна назва)	Медіана	Середнє	Std	Skewness	Аналітичний блок
Робочий капітал / активи (Attr3)	0,071	0,042	0,312	-2,14	Ліквідність
ROA – чистий прибуток / активи (Attr1)	0,018	-0,041	0,287	-8,32	Рентабельність
Виручка / активи (Attr9)	0,823	1,468	2,341	12,47	Ділова активність
Борг / активи (Attr2)	0,542	0,598	0,381	3,71	Лeverидж
ЕВІТ / активи (Attr7)	0,031	-0,018	0,198	-5,83	Покриття боргу

Джерело: розраховано автором на основі [38]




Рисунок 3.2 – Розподіли ключових фінансових коефіцієнтів за статусом дефолту (3rd year зріз). Джерело: побудовано автором

Рис. 3.2 ілюструє, що розподіли ключових фінансових коефіцієнтів для підприємств-банкрутів систематично зміщені в зону гірших значень порівняно з платоспроможними підприємствами, проте зі значним перетином між групами – що підтверджує неможливість безпомилкового розділення класів за жодною окремою ознакою і обґрунтовує необхідність застосування ансамблевих нелінійних методів.

Аналіз пропущених значень та стратегія імпутації

Детальний аналіз пропущених значень на рівні окремих ознак виявив нерівномірний розподіл пропусків: більшість ознак мають менше 2% пропусків, проте 8-10 ознак мають частку пропусків від 15% до 37%. Ці ознаки відповідають показникам, що вимагають деталізованих даних про структуру боргу або грошові потоки.

Перевірка механізму пропущення (MNAR vs MAR) виявила, що для 12 ознак частка пропусків серед банкрутів на 3-8% вища, ніж серед платоспроможних підприємств, що підтверджує часткову інформативність самого факту пропуску. Тому стратегія обробки пропущених значень реалізована у два кроки [37]:

Крок 1. Для ознак з часткою пропусків більше 5% додається бінарна індикаторна ознака $Attr_j_missing \in \{0,1\}$, що фіксує факт пропуску.

Крок 2. Пропущені значення заповнюються медіаною відповідної ознаки, розрахованою виключно на навчальній підвибірці (медіана є стійкою до аутлаєрів).

Обидва кроки реалізовані всередині бібліотеки `scikit-learn Pipeline` для гарантованого запобігання витоку інформації між тренувальною та тестовою вибірками.

Виявлення та обробка викідів (аутлаєрів)

Для систематичного виявлення аутлаєрів застосовано IQR-метод. Для кожної ознаки j визначаються межі:

$$Lower_j = Q1_j - 1,5 \cdot IQR_j, Upper_j = Q3_j + 1,5 \cdot IQR_j, \quad (3.1)$$

де $Q1_j, Q3_j$ – перший та третій кuartили; $IQR_j = Q3_j - Q1_j$ – міжквартильний розмах. Частка спостережень, що виходять за межі хоча б по одній ознаці, становить $\sim 22\%$, що є надзвичайно високим для стандартного порогу $1,5 \times IQR$. Це пояснюється не стільки помилками у даних, скільки природною жорсткою асиметрією фінансових коефіцієнтів та принципово різними масштабами для різних галузей.

Видалення 22% спостережень призвело б до суттєвої втрати інформації та зміщення вибірки. Тому в роботі було застосовано вінсоризацію (*winsorizing*) – обмеження екстремальних значень рівнями 1-го та 99-го перцентилів:

$$\tilde{x}_{ij} = \max(P1_j, \min(x_{ij}, P99_j)) \quad (3.2)$$

де $P1_j, P99_j$ – 1-й та 99-й перцентилі j -ї ознаки, розраховані на навчальній підвибірці. Цей підхід зберігає всі спостереження та зменшує вплив крайніх значень на логістичну регресію та MLP, при цьому не впливаючи на методи на основі дерев (RF, XGBoost, LightGBM), що використовують лише порядок значень.

Кореляційний аналіз та виявлення мультиколінеарності

Кореляційний аналіз між 64 ознаками виявив блокову структуру: значна кількість пар з помірною та сильною кореляцією всередині аналітичних блоків і відносно слабкі кореляції між блоками (Рис. 3.3). З 2 016 унікальних пар ознак виявлено:

- 47 пар з $|r| > 0,85$ (сильна мультиколінеарність) – переважно між різними варіантами розрахунку одного й того ж коефіцієнта;
- 183 пари з $0,60 < |r| \leq 0,85$ (помірна кореляція);
- решта пар – $|r| \leq 0,60$ (слабка або відсутня кореляція).
- Мультиколінеарність є проблемою переважно для логістичної регресії (завищена дисперсія коефіцієнтів) та MLP, але не для деревних методів. Для LR застосовується L_2 -регуляризація (параметр C налаштовується через Optuna), що ефективно контролює вплив мультиколінеарності.

Кореляція ознак з цільовою змінною (Point-Biserial Correlation) ранжує ознаки за лінійною інформативністю. Топ-5 найбільш корельованих з дефолтом ознак: покриття боргу грошовим потоком (Attr34), рентабельність активів (Attr1), ліквідний коефіцієнт (Attr5), ЕБІТ/активи (Attr7) та власний капітал/борг (Attr8) – з $|r| = 0,18-0,31$. Помірна кореляція підкреслює складність задачі та відсутність «срібних куль» серед лінійних предикторів.

Стандартизація ознак

Після вінсоризації та імпутації пропусків числові ознаки стандартизуються за допомогою StandardScaler:

$$z_{ij} = (\tilde{x}_{ij} - \bar{x}_j) / \sigma_j, \quad (3.3)$$

де $\bar{x}_j$ та σ_j – середнє та стандартне відхилення j -ї ознаки, розраховані виключно на навчальній підвибірці. Параметри стандартизації зберігаються та застосовуються до тестової вибірки (це також реалізовано в *Scikit-learn Pipeline*). Стандартизація є обов'язковою для LR та MLP, але не впливає на інші методи ансамблю.




Рисунок 3.3 – Теплова карта кореляцій топ-20 ознак датасету (кластеризована за аналітичними блоками). Джерело: побудовано автором

Реалізація стратегії роботи з незбалансованими класами

Відповідно до Варіанту В, обґрунтованого у підрозділі 2.1, проблема незбалансованості класів (IR від 13 до 25) вирішується через комбіновану стратегію трьох рівнів. В табл. 3.6 наведено систематизує обрані методи.

При цьому SMOTE застосовується виключно до тренувальної частини кожного фолду крос-валідації. Тестова (валідаційна) підвибірка залишається незмінною з реальним незбалансованим розподілом класів. Порушення цього правила призводить до завищення всіх метрик якості.

Таблиця 3.6 – Обрана стратегія роботи з незбалансованими класами

Рівень	Метод	Параметри	Де застосовується	Мета
Рівень даних	SMOTE	$k=5$, $IR \rightarrow 1:1$	LR, RF, MLP (у тренув. фолді)	Синтетичні зразки класу дефолту
Рівень алгоритму	scale_pos_weight	$N_0/N_1 \approx 20$	XGBoost, LightGBM	Зважена функція втрат (2.7)
Рівень алгоритму	class_weight='balanced'	$w_1 = N/(2N_1)$	LR, RF	Зважені штрафи в Loss
Рівень рішення	$\tau^* = \arg \max F_2$	$\beta=2$, PR-крива	Всі моделі (OOF-прогнози)	Оптимізація порогу відсічення

Джерело: складено автором на основі [3, 37, 44, 45]

Схему коректного застосування SMOTE в контексті OOF крос-валідації забезпечується через *Scikit-learn Pipeline*: SMOTE є кроком препроцесингу, що автоматично застосовується лише до тренувальних фолдів. Детальна реалізація наведена у підрозділі 3.3.

Попередній відбір ознак та розбиття вибірки

Перевірка дисперсії всіх 64 ознак (variance threshold) не виявила ознак з нульовою або майже нульовою варіативністю – всі коефіцієнти є потенційно інформативними. Попередня оцінка важливості ознак (*MDI Random Forest* без оптимізації гіперпараметрів) підтверджує, що топ-15 ознак охоплюють всі п'ять аналітичних блоків, що зумовлює збалансованість ознакового простору датасету.

Для фінального навчання було використано всі 64 ознаки плюс індикатори пропусків, оскільки *Optuna* автоматично адаптує регуляризацію під повний ознаковий простір. Параметри підготовленої вибірки наведено у табл. 3.7.

До тестової вибірки D_{test} не застосовувались від будь-які перетворення, що базуються на даних (стандартизація, параметри вінсоризації, SMOTE) до завершення навчання всіх моделей. Це є головною умовою достовірності оцінки якості.

Таким чином, підготовлена вибірка відповідає всім методологічним вимогам: послідовне застосування вінсоризації, медіанної імпутації з індикаторами

пропусків та стандартизації у межах *Scikit-learn Pipeline* гарантує відтворюваність і відсутність витоку даних.

Таблиця 3.7 – Параметри підготовленої вибірки для навчання (3rd year зріз)

Параметр	Значення	Примітка
Загальний обсяг (N)	10 503	3rd year зріз
Навчальна вибірка D_train	8 402 (80%)	StratifiedShuffleSplit, random_state=42
Тестова вибірка D_test	2 101 (20%)	Ізольована до завершення навчання
Дефолтів у D_train	396 (4,71%)	Незбалансованість зберігається
Дефолтів у D_test	99 (4,71%)	Стратифіковане розбиття
Ознак після препроцесингу	74	64 фін. + 10 індикаторів пропусків
D_train після SMOTE (у фолді)	~15 900	IR → 1:1 після ресемплінгу

Джерело: розраховано автором

Комбінована стратегія роботи з незбалансованістю класів (SMOTE + class_weight + оптимізація порогу) забезпечує коректну постановку задачі навчання для всіх базових класифікаторів стекінгової архітектури. Практична реалізація описаного пайплайну є предметом наступного підрозділу.

3.3. Реалізація стекінгової ансамблевої моделі оцінювання кредитного ризику

Цей підрозділ присвячений практичній реалізації стекінгової архітектури, методологічні засади якої розроблені у підрозділі 2.4. Опис організований відповідно до послідовності етапів повного пайплайну: від налаштування гіперпараметрів базових класифікаторів через OOF крос-валідацію до навчання мета-моделі та фінальної валідації на тестовій вибірці. Особливу увагу приділено технічним аспектам запобігання витоку даних та відтворюваності результатів.

Повну блок-схему ансамблевої стекінгової моделі наведено на рис. Б.1 (Додаток Б).

Інструментальний стек та середовище розробки

Реалізація виконана мовою Python 3.11 у середовищі *Google Colaboratory* з GPU-прискоренням (NVIDIA T4). В табл. 3.8 наведено повний стек використаних бібліотек з обґрунтуванням їхньої ролі у пайплайні.

Таблиця 3.8 – Інструментальний стек реалізації ансамблевої моделі

Бібліотека	Версія	Роль у реалізації
pandas / numpy	2.1.x / 1.26.x	Завантаження ARFF, трансформація, матричні операції
scikit-learn	1.4.x	Pipeline, StratifiedKFold, StandardScaler, LR, RF, MLP, метрики
xgboost	2.0.x	Базовий класифікатор XGBoost та кандидат на мета-модель
lightgbm	4.2.x	Базовий класифікатор LightGBM
imbalanced-learn	0.12.x	SMOTE у межах тренувальних фолдів
optuna	3.5.x	Байєсівська оптимізація гіперпараметрів (TPE)
shap	0.44.x	SHAP-значення, Summary Plot, Waterfall Plot

Джерело: складено автором

Для забезпечення відтворюваності у всіх стохастичних операціях було зафіксовано значення генератору псевдовипадкових чисел *random_state* = 42 (розбиття train/test, StratifiedKFold, ініціалізація ваг MLP, бутстреп в Random Forest, SMOTE тощо).

Оптимізація гіперпараметрів засобами Optuna

Перед побудовою стекінгового ансамблю для кожного базового класифікатора проводиться незалежна оптимізація гіперпараметрів засобами Optuna з алгоритмом TPE (Tree-structured Parzen Estimator) ($N_{trials} = 200$). Цільова функція оптимізації ROC-AUC на 3-fold крос-валідації [21]:

$$\mathbf{h}_m^* = \operatorname{argmax}_{\mathbf{h} \in \mathcal{H}^m} \frac{1}{3} \cdot \sum_{j=1}^{13} \operatorname{AUC} \left(f_m(\cdot; \mathbf{h}), \mathcal{D}_{val}^{(j)} \right) \quad (3.5)$$

Для XGBoost та LightGBM у всіх фолдах задається $scale_pos_weight = N_0/N_1 \approx 20$,. SMOTE застосовувався лише для LR, RF та MLP (у кожному тренувальному фолді внутрішньої CV). В табл. 3.9 наведено оптимальні гіперпараметрів.

Таблиця 3.9 – Оптимальні гіперпараметри базових класифікаторів (*Optuna*, 200 trials, цільова функція: ROC-AUC, 3-fold CV)

Класифікатор	Гіперпараметр	Оптимальне значення	Простір пошуку	AUC (вал.)
Логістична регресія	C (зворотна регуляризація)	0,047	$[10^{-3}; 10^3]$	0,782
	penalty	l2	{l1, l2}	
Random Forest	n_estimators	650	[100; 1000]	0,871
	max_depth	12	[3; 20]	
	min_samples_leaf	4	[1; 10]	
XGBoost	learning_rate	0,043	[0,01; 0,30]	0,911
	n_estimators	780	[100; 1000]	
	max_depth	6	[3; 10]	
	reg_lambda	1,85	$[10^{-3}; 10]$	
LightGBM	learning_rate	0,038	[0,01; 0,30]	0,908
	num_leaves	127	[20; 300]	
	min_child_samples	25	[5; 50]	
MLP	hidden_layer_sizes	(128, 64)	4 варіанти	0,863
	alpha (L2)	0,0008	$[10^{-5}; 10^{-1}]$	
	learning_rate_init	0,0012	$[10^{-4}; 10^{-2}]$	

Джерело: розраховано автором.

OOF крос-валідація та формування матриці мета-ознак

Після завершення оптимізації гіперпараметрів виконується OOF крос-валідація ($K = 5$, StratifiedKFold). Алгоритм генерації матриці мета-ознак $\mathbf{Z}_{train} \in [0,1]^{N \times 5}$ реалізується таким чином:

Крок 1: Ініціалізація: $\mathbf{Z}_{train} \leftarrow \mathbf{0}_{N \times 5}$, де $N = |\mathcal{D}_{train}| = 8\,402$.

Крок 2:

2.1 Для кожного фолду $k = 1, \dots, 5$: визначити $\mathcal{D}_{train}^{(k)} = \mathcal{D}_{train} \setminus \mathcal{F}_k$ та $\mathcal{D}_{val} = \mathcal{F}_k$.

2.2 Застосувати SMOTE до $\mathcal{D}_{train}^{(k)} \rightarrow \tilde{\mathcal{D}}_{train}^{(k)}$ (лише для LR, RF, MLP).

2.3 Для кожного базового класифікатора $m = 1, \dots, 5$: навчити $h_m^{(k)}$ на $\tilde{\mathcal{D}}_{train}^{(k)}$ (або на $\tilde{\mathcal{D}}_{train}^{(k)}$ для XGBoost, LightGBM).

2.4 Обчислити OOF-прогнози: $\hat{p}_{i,m}^{OOF} \leftarrow h_m^{(k)}(\mathbf{x}_i)$ для всіх $\mathbf{x}_i \in \mathcal{F}_k$.

2.5 Записати до $\mathbf{Z}_{train}[i, m] \leftarrow \hat{p}_{i,m}^{OOF}$.

Крок 3: Повернути заповнену матрицю $\mathbf{Z}_{train}$.

Навчання мета-моделі та вибір її архітектури

Після формування $\mathbf{Z}_{train}$ мета-модель навчається на парі $(\mathbf{Z}_{train}, \mathbf{y}_{train})$. Порівняння двох класифікаторів-кандидатів (логістична регресія, XGBoost) для метамоделі на 3-fold CV дало такі результати (табл. 3.10):

Таблиця 3.10 – Порівняння кандидатів на роль мета-моделі (3-fold CV на $\mathbf{Z}_{train}$)

Характеристика	LogisticRegression (обрано)	XGBoost мета- модель
ROC-AUC на CV	0,921	0,924
Різниця AUC	–	+0,003
Інтерпретованість	Висока (коефіцієнти β_m)	Низька
Basel III сумісність	Повна (коефіцієнти = ваги)	Обмежена
Рішення	ОБРАНО	Не обрано

Джерело: розраховано автором

За результатами порівняння було обрано логістичну регресію як мета-модель: різниця AUC між кандидатами є статистично незначущою (0,003), тоді як

перевага в інтерпретованості є суттєвою для регуляторних цілей Basel III [3, 57]. Після навчання мета-моделі на повному $\mathbf{Z}_{train}$ отримані такі коефіцієнти:

$$\hat{p}^{stack} = \sigma(-3,21 + 0,48 \times \hat{p}_{LR} + 1,14 \times \hat{p}_{RF} + 2,37 \times \hat{p}_{XGB} + 2,19 \times \hat{p}_{LGB} + 1,02 \times p_{MLP}) \quad (3.6)$$

Коефіцієнти у формулі (3.6) відображають ієрархію довіри мета-моделі до базових класифікаторів: найвища вага надана XGBoost ($\beta = 2,37$) та LightGBM ($\beta = 2,19$), що узгоджується з їхніми найвищими індивідуальними AUC. Ненульові коефіцієнти всіх п'яти класифікаторів підтверджують, що кожен вносить унікальний незалежний внесок, що виправдовує їх включення до ансамблю.

Оптимізація порогу класифікації та перенавчання базових класифікаторів на повній вибірці

Після навчання мета-моделі оптимальний поріг τ^* визначається на OOF-прогнозах $\mathbf{Z}_{train}$ через максимізацію F_2 -міри ($\beta = 2$):

$$\tau^* = \arg \max_{\tau \in (0,1)} F_2(\tau) = 0,31. \quad (3.7)$$

Поріг $\tau^* = 0,31$ є нижчим за стандартне значення 0,5, що відповідає очікуванням для задачі з $IR \approx 20:1$ та пріоритетом мінімізації FN -помилки. Пошук здійснювався на 400 точках на відрізку $[0,01;0,80]$.

Після завершення OOF-процедури та навчання мета-моделі кожен базовий класифікатор перенавчається на повній навчальній вибірці $\mathcal{D}_{train}$ з оптимізованими гіперпараметрами. Для LR, RF та MLP застосовувався алгоритм SMOTE до всієї $\mathcal{D}_{train}$ (результуюча збалансована вибірка: $\sim 16\,804$ спостережень, $IR \rightarrow 1:1$). XGBoost та LightGBM навчалися на оригінальній $\mathcal{D}_{train}$ зі $scale_pos_weight = 20,2$. Це дозволило максимально використати всю навчальну інформацію при інференсі.

Процедура інференсу для нового позичальника

Для нового позичальника $\mathbf{x}^*$ процедура інференсу реалізується через послідовне застосування всіх компонентів пайплайну:

$$\hat{p}^* = g(h_1(\mathbf{x}^*), h_2(\mathbf{x}^*), h_3(\mathbf{x}^*), h_4(\mathbf{x}^*), h_5(\mathbf{x}^*)), \hat{y}^* = \mathbb{1}[\hat{p}^* \geq 0,31] \quad (3.8)$$

де $h_1, \dots, h_5$ – базові класифікатори, навчені на повній $\mathcal{D}_{train}$; g – мета-модель LR з коефіцієнтами (3.6). Паралельно обчислювалися SHAP-значення $\varphi_j(\mathbf{x}^*)$ для всіх 64 ознак, що дозволило зробити змістовну інтерпретацію одержаного результату. Час інференсу для одного позичальника не перевищує 50 мс.

Параметри обчислювального експерименту

Основні параметри проведених обчислювальних експериментів систематизовано у табл. 3.11.

Таким чином, реалізований пайплайн втілює повну стекінгову архітектуру підрозділу 2.4 з дотриманням усіх методологічних вимог: OOF крос-валідація запобігає витoku даних, Optuna забезпечує ефективний підбір гіперпараметрів, а час інференсу менше 50 мс підтверджує придатність системи для реального впровадження.

Таблиця 3.11 – Параметри обчислювального експерименту

Параметр	Значення
Середовище	Google Colaboratory (GPU: NVIDIA T4)
Зріз для основного аналізу	3rd year (N = 10 503)
random_state	42 (всі стохастичні операції)
K (OOF фолдів)	5
N_trials Optuna (на класифікатор)	200
SMOTE k_neighbors	5
IR після SMOTE	1:1
Розмір X_train після препроцесингу	8 402 × 74
Розмір X_test	2 101 × 74
Час навчання (оцінка, CPU)	~45-60 хв
Час навчання (оцінка, GPU T4)	~12-18 хв
Час інференсу (1 позичальник)	< 50 мс

Джерело: складено автором

Результати експериментальної валідації розробленої системи та порівняльний аналіз якості моделей є предметом наступного підрозділу.

Деталізовану блок-схему пайплайну системи оцінювання кредитного ризику корпоративних клієнтів наведено на рис. В.1 (Додаток В).

3.4. Результати експериментальної валідації, порівняльний аналіз та практичні рекомендації

Для валідації запропонованих моделей використано незалежну тестову вибірку обсягом 2 101 спостереження (20% від 3rd year зрізу), яка , була недоступною для усіх операцій навчання та налаштування протягом усього дослідження. Порівняльне оцінювання якості стекінгової ансамблевої моделі та базових класифікаторів збуло дійснено за системою метрик регуляторної валідації, визначеною у підрозділі 2.4, а SHAP-аналіз забезпечує обґрунтування отриманих рішень відповідно до вимог IRB-підходу Basel III.

Порівняльна оцінка якості моделей на тестовій вибірці

У таблиці 3.12 наведено повні результати оцінювання якості обраних моделей за визначеною системою метрик. Аналіз даних табл. 3.12 дозволяє сформулювати три ключових висновки.

По-перше, стекінгова модель перевершує всі базові класифікатори за кожною з восьми метрик. ROC-AUC стекінгу (0,924) на 1,3 відсоткових пункти вищий за найкращий базовий класифікатор (XGBoost, 0,911), це незначний приріст на перший погляд, але у банківській практиці навіть 1% приросту AUC на великому портфелі трансформується у мільйони гривень зекономлених резервів [45, 51].

Таблиця 3.12–Порівняльна оцінка якості моделей на тестовій вибірці
($\mathcal{D}_{test}$, 3rd year, $N = 2\,101$, $\tau^* = 0,31$)

Модель	ROC-AUC	Gini	KS	PR-AUC	Recall	Precision	F ₂	Brier Score
Лог. регресія	0,782	0,564	0,421	0,187	0,616	0,198	0,441	0,043

Random Forest	0,871	0,742	0,573	0,294	0,707	0,251	0,531	0,031
XGBoost	0,911	0,822	0,641	0,358	0,758	0,287	0,578	0,027
LightGBM	0,908	0,816	0,635	0,351	0,747	0,279	0,568	0,028
MLP	0,863	0,726	0,554	0,278	0,687	0,238	0,512	0,033
Стекінг	0,924	0,848	0,667	0,389	0,788	0,301	0,608	0,024

Джерело: розраховано автором.

По-друге, значення коефіцієнту $Gini = 0,848$ та $KS = 0,667$ стекингу суттєво перевищують мінімально прийнятні значення Basel III ($Gini \geq 0,30$, $AUC \geq 0,70$) для всіх шести моделей [3, 11], підтверджуючи регуляторну придатність системи.

По-третє, $Recall = 0,788$ при $\tau^* = 0,31$ означає, що стекингова модель правильно ідентифікує 78,8% реальних банкрутств, тобто у тестовій вибірці з 99 підприємств-банкрутів виявлено 78.

Значення статистики *Brier Skill Score* підтверджує, що стекингова модель забезпечує на 46,6% кращу калібровану оцінку *PD* порівняно з тривіальним класифікатором.

На рис. 3.4 наведено *ROC*-криві та криві *Precision-Recall* для всіх моделей, що побудовано на тестовій вибірці (3rd year, $N = 2\,101$). Аналіз рис. 3.4 свідчить, що стекингова модель займає найвище положення серед усіх кривих із найбільшою площею під кривою ($AUC = 0,924$). Горизонтальна пунктирна лінія на рівні $TPR = 0,70$ відповідає мінімальному регуляторному порогу Basel III відображає усі моделі, що перевищують цей рівень. Вертикальна стрілка ілюструє максимальне значення *KS*-статистики (0,667) – точку найбільшого розділення між кумулятивними розподілами ймовірностей для двох класів.




Рисунок 3.4 – ROC-криві (ліва панель) та *Precision-Recall* криві (права панель) всіх шести моделей на тестовій вибірці (3rd year). Джерело: побудовано автором

Права панель відображає криві *Precision-Recall*, що є більш інформативними за умов суттєвої незбалансованості класів. Базова лінія (частка дефолтів у вибірці – 4,7%) позначена горизонтальною лінією, вертикальна пунктирна лінія відповідає оптимальному порогу класифікації $\tau^* = 0,31$, при якому досягається максимум F_2 -міри ($Recall = 0,788$). Стекінгова модель забезпечує найкращий баланс між *Precision* та *Recall* у всьому діапазоні порогів, що підтверджує її системну перевагу над базовими класифікаторами.

Аналіз матриці класифікації та економічна інтерпретація помилок

На основі виконаних розрахунків матриці помилок класифікації (Confusion Matrix) (табл. 3.13) можна дати економічну інтерпретацію кожному типу прогнозних рішень стекінгової моделі.

Для економічної інтерпретації результатів, наведених у табл. 3.13, прийнято такі орієнтовні параметри типового корпоративного кредиту: обсяг заборгованості на момент дефолту *EAD* у розмірі 5 млн грн, частку втрат у разі дефолту *LGD* на рівні 45%, та ставку кредитування 18% річних.

Передусім, правильне виявлення 78 випадків банкрутства (TP) дає змогу банку уникнути прямих кредитних збитків на загальну суму 175,5 млн. грн. ($78 \times 5 \times 0,45$), що є безпосереднім позитивним ефектом від впровадження моделі.

Таблиця 3.13 – Матриця класифікації стекінгової моделі
($\mathcal{D}_{test}$, 3rd ear, $\tau^* = 0,31$)

	Прогноз: ДЕФОЛТ (1)	Прогноз: НЕ ДЕФОЛТ (0)	Разом
Факт: ДЕФОЛТ (1)	$TP = 78$ (виявлено банкрутів)	$FN = 21$ (пропущено дефолтів)	99
Факт: НЕ ДЕФОЛТ (0)	$FP = 181$ (хибних тривога)	$TN = 1\,821$ (правильних відмов)	2 002
Разом	259	1 842	2 101

Джерело: розраховано автором

Водночас 21 пропущений дефолт (FN) формує потенційні прямі збитки в розмірі 47,25 млн. грн. ($21 \times 5 \times 0,45$), які необхідно враховувати при формуванні резервів під очікувані втрати.

Окремої уваги потребують 181 хибна тривога (FP): хоча вони не несуть прямих втрат капіталу, проте призводять до втрачених процентних доходів у сумі 162,9 млн. грн. на рік ($181 \times 5 \times 0,18$), що свідчить про певний рівень консервативності моделі та може бути компромісом задля мінімізації критичніших помилок першого роду.

Для обґрунтування вибору архітектури було порівняно ефективність стекінгу з базовою моделлю (логістичною регресією), показник *Recall* якої становив 0,616 (що відповідає 61 виявленому банкруту), що дозволяє оцінити додатковий економічний ефект від застосування стекінгової архітектури:

$$\Delta Benefit = (78 - 61) \times 5 \times 0,45 = +38,25 \text{ млн. грн.} \quad (3.9)$$

Таким чином, перехід від найпростішої базової моделі до стекінгового ансамблю забезпечило додаткове виявлення 17 проблемних позичальників та

дозволило уникнути збитків у розмірі близько 38 млн грн, що є переконливим економічним аргументом на користь застосування складнішої, але точнішої архітектури.

Отриманий економічний ефект є вагомим аргументом на користь впровадження запропонованої складної ансамблевої архітектури, адже він суттєво перевищує потенційні витрати на її експлуатацію та обчислювальні ресурси. Наочне зіставлення абсолютних та відносних значень класифікаційних рішень подано на рис. Г.1. (Додаток Г).

Отже, можна зробити висновок, що впровадження ансамблевої стекінгової моделі дозволить уникнути збитків на суму приблизно ≈ 38 млн грн порівняно з найпростішою базовою моделлю.

Темпоральна валідація: стабільність моделі по часових зрізах

Basel III вимагає щорічного тестування стабільності внутрішніх рейтингових систем [3]. Стекінгова модель, навчена на 3rd year зрізі, застосовується до кожного з п'яти зрізів незалежно. Результати темпоральної валідації наведені у табл. 3.14.

Таблиця 3.14 – Темпоральна валідація стекінгової моделі по часових зрізах

Зріз (горизонт)	N (тест)	Дефолтів	ROC-AUC	Gini / KS / Recall
1st year (5 p.)	1 406	54	0,874	0,748 / 0,531 / 0,685
2nd year (4 p.)	2 035	80	0,891	0,782 / 0,573 / 0,725
3rd year (3 p.) – ОСНОВНИЙ	2 101	99	0,924	0,848 / 0,667 / 0,788
4th year (2 p.)	1 958	103	0,931	0,862 / 0,693 / 0,816
5th year (1 p.)	1 182	82	0,947	0,894 / 0,724 / 0,854

Джерело: розраховано автором.

Темпоральна валідація виявляє очікуваний та методологічно обґрунтований паттерн: якість моделі монотонно зростає зі скороченням горизонту прогнозування. ROC-AUC змінюється від 0,874 (1st year, горизонт 5 років) до 0,947 (5th year, горизонт 1 рік). Принципово важливим є те, що навіть на найгіршому з

точки зору значень метрик класифікації 1st year зрізі $AUC = 0,874$ та $Gini = 0,748$ – які суттєво перевищують мінімальні вимоги Basel III, що підтверджує відсутність суттєвого *концептуального дрейфу*⁶ та виконання умови (2.12).

На рис. 3.5 наведено динаміку трьох ранжувальних метрик якості стекінгової моделі ($ROC-AUC$, коефіцієнта Джині та KS -статистики) для всіх п'яти часових зрізів датасету.




Рисунок 3.5 – Темпоральна валідація стекінгової моделі: $ROC-AUC$, $Gini$ та KS -статистика по часових зрізах. Джерело: побудовано автором.

Значення зростають монотонно зі скороченням горизонту прогнозування: від 0,874 для 1st year (горизонт 5 років) до 0,947 для 5th year (горизонт 1 рік), що є очікуваним результатом, оскільки фінансовий стан підприємства напередодні дефолту відхиляється від норми сильніше, ніж за кілька років до події.

Горизонтальні пунктирні лінії позначають мінімальні регуляторні вимоги Basel III ($AUC \geq 0,70$, $Gini \geq 0,30$); усі п'ять зрізів перевищують ці пороги із

⁶ *Концептуальний дрейф (Concept Drift)* – це явище, коли з часом змінюється сама статистична залежність між вхідними даними (ознаками) і цільовою змінною (тим, що ми прогнозуємо).

суттєвим запасом, що підтверджує стабільність моделі в часі та відсутність концептуального дрейфу.

Результати темпоральної валідації у сукупності з економічною інтерпретацією матриці класифікації доводять, що запропонована стекінгова модель є не лише статистично значущою, але й економічно вигідною. Приріст уникнених збитків у розмірі ~38 млн грн на тестовій вибірці свідчить про значну додану вартість від використання складної архітектури машинного навчання порівняно з класичними регресійними підходами, що робить її перспективною для впровадження у системі раннього попередження кредитних ризиків.

SHAP-аналіз та інтерпретація прогнозів

SHAP-значення обчислюються через TreeExplainer на XGBoost (найвагоміший компонент ансамблю) для 500 тестових спостережень. Глобальна важливість ознак визначається за формулою:

$$\bar{\varphi}_j = \frac{1}{N_{test}} \cdot \sum_{i=1}^{N_{test}} |\varphi_j(\mathbf{x}_i)| \quad (3.10)$$

В табл. 3.15 наведено результати оцінки важливості топ-10 ознак за SHAP-аналізом. Аналіз табл. 3.15 дозволяє сформулювати принципові висновки про детермінанти корпоративного дефолту. Топ-3 ознаки, це покриття боргу (Attr34), ROA (Attr1) та ліквідний коефіцієнт (Attr5). Вони охоплюють три різні аналітичні блоки, що підтверджує системний характер фінансового дистресу: до банкрутства одночасно деградують ліквідність, рентабельність і платоспроможність, що узгоджується із результатами робіт [8, 22, 45]. Ознаки з додатнім напрямом впливу (Attr2, Attr15) є показниками боргового навантаження, так їх зростання підвищує *PD*, що є логічним з фінансово-економічної точки зору.

SHAP-аналіз також виявляє нелінійні порогові ефекти: для Attr34 (покриття боргу) SHAP-значення є майже нульовим при значеннях вище 0,30 і різко зростає при падінні нижче 0,10, що є ефектом порогу, який не є досяжним для лінійної регресії.

Таблиця 3.15 –Топ-10 ознак за глобальним SHAP-аналізом

Ранг / Ознака	$\bar{\varphi}_j$	Фінансовий коефіцієнт	Напрям	Інтерпретація
1. Attr34	0,0847	(чист.приб.+амортиз.)/борг	$\uparrow \rightarrow \downarrow PD$	$\uparrow$ покриття боргу CF $\rightarrow \downarrow$ ризик
2. Attr1	0,0712	ROA (прибуток/активи)	$\uparrow \rightarrow \downarrow PD$	$\uparrow$ рентабельність $\rightarrow \downarrow$ ризик
3. Attr5	0,0634	Ліквідний коеф. (у днях)	$\uparrow \rightarrow \downarrow PD$	$\uparrow$ ліквідність $\rightarrow \downarrow$ ризик
4. Attr7	0,0598	EBIT / активи	$\uparrow \rightarrow \downarrow PD$	$\uparrow$ операц. рент. $\rightarrow \downarrow$ ризик
5. Attr8	0,0541	Власний капітал / борг	$\uparrow \rightarrow \downarrow PD$	$\uparrow$ власний кап. $\rightarrow \downarrow$ ризик
6. Attr2	0,0487	Борг / активи	$\uparrow \rightarrow \uparrow PD$	$\uparrow$ борг. навант. $\rightarrow \uparrow$ ризик
7. Attr27	0,0463	ICR (EBIT / відсотки)	$\uparrow \rightarrow \downarrow PD$	$\uparrow$ ICR $\rightarrow \downarrow$ ризик
8. Attr3	0,0421	Роб. капітал / активи	$\uparrow \rightarrow \downarrow PD$	$\uparrow$ роб. капітал $\rightarrow \downarrow$ ризик
9. Attr15	0,0398	Термін погашення боргу (дні)	$\uparrow \rightarrow \uparrow PD$	$\uparrow$ термін $\rightarrow \uparrow$ ризик
10. Attr24	0,0374	Рентаб. активів (3 роки)	$\uparrow \rightarrow \downarrow PD$	$\uparrow$ стала рентаб. $\rightarrow \downarrow$ ризик

Джерело: розраховано автором на основі [48]

Повний рейтинг важливості за показником MDI для всіх 74 ознак моделі (64 фінансові коефіцієнти та 10 індикаторів пропусків) наведено у Додатку Г (рис. Г.2). Зіставлення цього рейтингу з результатами SHAP-аналізу дозволяє перевірити узгодженість двох незалежних підходів до оцінювання важливості ознак.

Розширене порівняння з MDI-важливістю (Mean Decrease in Impurity) Random Forest наведено у Додатку Д (табл. Д.1).

Високий ступінь узгодженості рангів між двома підходами (коефіцієнт кореляції Спірмена $\approx 0,93$) підтверджує стійкість виявлених закономірностей: топ-5 ознак за SHAP повністю входять до топ-6 за MDI. Розбіжності спостерігаються переважно для ознак середнього рангу, що пояснюється чутливістю SHAP до нелінійних взаємодій між ознаками в контексті всього ансамблю – властивості, недоступної вбудованій метриці MDI окремого алгоритму Random Forest.

Калібрування ймовірностей

Brier Score (BS) стекингової моделі (0,024) є найнижчим серед усіх шести моделей (табл. 3.12), що свідчить про найбільш точне калібрування прогнозованих ймовірностей дефолту.

Оскільки сам *Brier Score* важко інтерпретувати у відриві від контексту конкретної вибірки, додатково розраховується *Brier Skill Score (BSS)* – нормалізований показник, що порівнює якість калібрування моделі з тривіальним прогнозом на основі базової частоти дефолтів і дозволяє виразити перевагу моделі у відсоткову вираженні (або частки від 1):

$$BSS = 1 - \frac{BS}{BS_{ref}} = 1 - 0,024 / 0,0449 = 0,466 \quad (3.11)$$

де $BS_{ref} = \pi^1(1 - \pi^1) = 0,0471 \times 0,9529 = 0,0449$ – *Brier Score* тривіального класифікатора. $BSS = 0,466$ означає, що стекингова модель забезпечує на 46,6% кращу калібровану оцінку PD – що підтверджує придатність для регуляторних розрахунків $EL = PD \times LGD \times EAD$ за Basel III [3].

Практичні рекомендації щодо впровадження у банківську практику

Таким чином, можна зробити висновок, що $\tau^* = 0,31$ є відправною точкою, яка потребує адаптації залежно від кредитної політики банку. При консервативній політиці (пріоритет мінімізації FN) поріг слід знизити до 0,22-0,25 ($Recall \uparrow$ до $\sim 0,85$, $FP \uparrow$). При агресивній слід підвищити до 0,38-0,42 ($FP \downarrow$, $Recall \downarrow$), що узгоджується із результатами досліджень [3, 45].

На рис. 3.6 наведено покрокову декомпозицію прогнозованої ймовірності дефолту для гіпотетичного позичальника з $PD = 0,47$, що відповідає формулі (3.11).

Стовпець ліворуч позначає базовий рівень PD по портфелю (0,048), а кожен наступний стовпець показує, на яку величину конкретна ознака зсуває прогноз вгору (червоний колір, підвищення ризику) або вниз (синій колір, зниження ризику) відносно попереднього кроку.

Сума всіх внесків приводить до фінального прогнозу (правий стовпець), що перевищує поріг $\tau^* = 0,31$ і відповідає рішенням про відмову. Така візуалізація

дозволяє кредитному аналітику побачити не лише підсумкову оцінку ризику, а й конкретний перелік фінансових показників, які її сформували.




Рисунок 3.6 – SHAP Waterfall діаграма для гіпотетичного позичальника ($PD = 0,47$): регуляторне пояснення рішення про відмову. Джерело: побудовано автором.

Підсумовуючи, можна зробити такі висновки щодо впровадження запропонованої моделі: автоматичне схвалення при $PD < 0,15$ (низький ризик, $\sim 72\%$ заявок); автоматична відмова при $PD > 0,55$ (дуже високий ризик, $\sim 4\%$); обов'язковий розгляд кредитним комітетом при $0,15 \leq PD \leq 0,55$ (сіра зона, $\sim 24\%$). SHAP Waterfall Plot надається аналітику для кожної заявки сірої зони як регуляторне обґрунтування рішення [3, 11].

Необхідно зауважити, що Basel III вимагає щорічного перекалібрування [3]. При виявленні дрейфу (зниження AUC більш ніж на 3 відсоткових пункти від базового рівня) необхідне перенавчання.

Таким чином, результати експериментальної валідації підтверджують, що розроблена стекінгова ансамблева модель з SHAP-інтерпретацією є методологічно

обґрунтованим інструментом оцінювання кредитних ризиків корпоративних позичальників.

Висновки до розділу 3

У третьому розділі дипломної роботи проведено практичну реалізацію, експериментальне дослідження та аналіз функціонування розробленої системи оцінювання кредитного ризику корпоративних позичальників на основі стекінгової ансамблевої моделі. На основі проведеної роботи можна зробити такі основні висновки.

1. Обрано та обґрунтовано інформаційну базу дослідження (датасет Polish Companies Bankruptcy Data [38, 58]) як найбільш прийнятну публічно доступну альтернативу, що повністю відповідає вимогам корпоративного сегменту кредитування: достатній обсяг спостережень, виключно фінансові коефіцієнти та темпоральна структура з п'яти річних зрізів для перевірки стабільності моделі в часі. Неможливість використання реальних банківських даних підтверджена нормами банківської таємниці [1].

2. Виконано всебічний дослідницький аналіз даних (EDA) та інженерію ознак, що дозволило глибоко зрозуміти структуру вхідної інформації, виявити пропущені значення, аномальні спостереження та значну незбалансованість класів. Реалізовано комплекс кроків попередньої обробки даних (вінсоризацію екстремальних значень, медіанну імпутацію з індикаторами пропусків та стандартизацію ознак), що суттєво підвищило якість вхідних даних для подальшого навчання моделей.

3. Описано програмну реалізацію проєкту із зазначенням використання мови Python та ключових бібліотек, зокрема pandas, numpy, scikit-learn, XGBoost,

LightGBM, imbalanced-learn, Optuna та SHAP, у середовищі Google Colaboratory з використанням GPU-прискорення для скорочення часу навчання моделей.

4. Проаналізовано та порівняно результати експериментів, продемонстровано продуктивність п'яти базових класифікаторів та фінальної ансамблевої стекінгової моделі на незалежному тестовому наборі даних. Встановлено, що XGBoost виявився найкращим серед окремих базових моделей за показником ROC-AUC, що узгоджується з результатами аналогічних бенчмаркінгових досліджень корпоративного кредитного скорингу.

5. Підтверджено, що розроблена ансамблева модель значно перевершила окремі базові класифікатори за ключовими метриками якості, що підкреслює ефективність ансамблевого підходу у підвищенні загальної прогностичної точності та надійності системи. Темпоральна валідація на всіх п'яти часових зрізах підтвердила стабільність моделі та відсутність суттєвого концептуального дрейфу, а отримані показники в усіх зрізах перевищили мінімальні регуляторні вимоги Basel III [3].

6. Виконано SHAP-аналіз та візуалізацію результатів, які наочно підтвердили висновки щодо продуктивності моделей та дозволили оцінити їхню розрізняльну здатність. Встановлено, що ключовими предикторами корпоративного дефолту є показники покриття боргу грошовим потоком, рентабельності активів та ліквідності, що відображає системний, а не локальний характер фінансового дистресу підприємства-банкрута.

7. Сформульовано висновки щодо високої ефективності розробленої системи, підкреслено її прогностичну точність, надійну ідентифікацію ризикових позичальників та значну практичну цінність для інтеграції у процес кредитного скорингу корпоративних клієнтів банківських установ.

ВИСНОВКИ

У бакалаврській кваліфікаційній роботі розроблено та експериментально валідовано систему оцінювання кредитних ризиків корпоративних позичальників на основі стекінгової ансамблевої моделі машинного навчання з SHAP-інтерпретацією. За результатами проведеного дослідження сформульовано такі основні висновки.

1. Здійснено системний аналіз кредитного ризику корпоративного позичальника та встановлено його трирівневу природу – ендогенні, екзогенні та регуляторні чинники, що формують ймовірність дефолту як ключовий параметр нормативної формули очікуваних кредитних втрат. Визначено та систематизовано п'ять аналітичних блоків кредитоспроможності корпоративного клієнта (ліквідність, фінансову стійкість, рентабельність, ділову активність та покриття боргу) і встановлено нелінійні взаємозумовлені зв'язки між ними, що обґрунтовує недоцільність застосування лінійних методів оцінювання.

2. Проведено критичний аналіз еволюції методів прогнозування корпоративного дефолту, від статистичного дискримінантного аналізу через логістичну регресію до сучасних ансамблевих алгоритмів машинного навчання, та виявлено стійку позитивну залежність між складністю методу і його прогностичною точністю. Обґрунтовано, що зростання складності моделей супроводжується втратою прозорості, усунення якої забезпечується винятково засобами пояснюваного штучного інтелекту.

3. Здійснено системну формалізацію задачі прогнозування дефолту як задачі бінарної класифікації з асиметричною вартістю помилок, що обґрунтовує необхідність зміщення порогу прийняття рішення на користь виявлення позичальників групи ризику. Виконано порівняльний аналіз п'яти базових класифікаторів стекінгового ансамблю і доведено, що їхня методологічна

різнорідність забезпечує необхідну для ефективного ансамблю диверсифікацію прогнозів.

4. Запропоновано технологію роботи із незбалансованими класами задачі корпоративного кредитного скорингу. Розроблено комбіновану трирівневу стратегію її подолання і визначено критичне правило застосування ресемплінгу виключно до тренувальних підвибірок для запобігання витоку даних. Сформовано систему метрик регуляторної валідації, узгоджену з мінімальними вимогами Basel III [3, 11].

5. Обрано та обґрунтовано інформаційну базу дослідження (датасет Polish Companies Bankruptcy Data [38, 58]) як прийнятну публічно доступну альтернативу, що повністю відповідає вимогам корпоративного сегменту кредитування. Виконано дослідницький аналіз даних, виявлено сильну асиметрію розподілів фінансових коефіцієнтів та нерівномірний розподіл пропущених значень, на основі чого реалізовано комплекс кроків попередньої обробки даних без витоку інформації між навчальною та тестовою вибірками.

6. Реалізовано дворівневу стекінгову архітектуру з Out-of-Fold крос-валідацією для генерації незміщеної матриці прогнозів базових класифікаторів та байєсівською оптимізацією гіперпараметрів засобами фреймворку Optuna. Логістичну регресію обрано як мета-модель другого рівня за критерієм оптимального поєднання прогностичної точності з інтерпретованістю, визначальною для регуляторного застосування моделі.

7. Підтверджено, що розроблена стекінгова модель значно перевершила всі окремі базові класифікатори за ключовими метриками якості, що підкреслює ефективність ансамблевого підходу у підвищенні прогностичної точності та надійності системи. Темпоральна валідація на п'яти часових зрізах датасету підтвердила стабільність моделі в часі та відсутність суттєвого концептуального дрейфу, а отримані показники в усіх зрізах перевищили мінімальні регуляторні вимоги Basel III .

8. Виконано SHAP-аналіз отриманих результатів і встановлено, що ключовими предикторами корпоративного дефолту є показники покриття боргу грошовим потоком, рентабельності активів та ліквідності, що емпірично підтверджує системний, а не локальний характер фінансового дистресу та узгоджується з теоретичним ланцюжком деградації кредитоспроможності, встановленим у першому розділі роботи.

9. Розроблено практичні рекомендації щодо впровадження системи у банківську практику, зокрема двоступеневу архітектуру прийняття кредитних рішень з автоматичним схваленням, автоматичною відмовою та обов'язковим розглядом кредитним комітетом позичальників проміжної групи ризику із наданням SHAP-пояснення для кожного рішення. Підтверджено технічну придатність системи до промислового впровадження завдяки малому часу обчислення прогнозу для одного позичальника.

10. Експериментально валідовано стекінгову ансамблеву систему оцінювання кредитних ризиків корпоративних позичальників, яка демонструє високу прогностичну точність, надійну ідентифікацію ризикових клієнтів та відповідність регуляторним вимогам Basel III і Постанови НБУ №351.

11. Перспективами подальших досліджень є адаптація розробленої моделі на реальних даних українських банків, розширення ознакового простору нефінансовими факторами з метою перекалібрування моделі в умовах змінного кредитного середовища.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Закон України «Про банки і банківську діяльність» від 07.12.2000 № 2121-III. URL: <https://zakon.rada.gov.ua/laws/show/2121-14#Text>
2. Національний банк України. Положення про визначення банками України розміру кредитного ризику за активними банківськими операціями: Постанова Правління НБУ № 351 від 30.06.2016. URL: <https://zakon.rada.gov.ua/laws/show/v0351500-16>
3. Basel Committee on Banking Supervision. Basel III: Finalising post-crisis reforms. Bank for International Settlements, 2021. URL: <https://www.bis.org/bcbs/publ/d424.PDF>
4. Амоша О.І., Заєць С.В. Фінансовий ринок: навчальний посібник. Київ: КНЕУ, 2017.
5. Васильківський Д.М. Кредитний скоринг: теорія та практика. Київ: Центр учбової літератури, 2018.
6. Вовчак О.Д., Гринів О.Є. Фінансовий аналіз: теорія і практика. Львів: Новий Світ – 2000, 2015.
7. Дзюблюк О.В., Михайлюк Р.В. Фінансова стійкість банків як основа ефективного функціонування кредитної системи: монографія. Тернопіль: ТНЕУ, 2022. 358 с.
8. Жовтанецька Я.В. Сучасні методичні підходи до оцінки кредитоспроможності позичальника – юридичної особи. Інвестиції: практика та досвід. 2023. № 7. С. 55–60.
9. Заблоцька Р.О., Яковенко Л.О., Грицишен Д.О. Фінансовий моніторинг: теорія і практика. Київ: Центр учбової літератури, 2018.
10. Ковальчук В.І., Зінкевич А.Б. Моделювання кредитного ризику банків на основі методів машинного навчання. Економіка і прогнозування. 2019. № 3. С. 115–126. <https://doi.org/10.15407/econprog2019.03.115>

- 11.Крухмаль О.В., Криклій О.А. Методологічні засади розробки внутрішніх рейтингових систем оцінки кредитного ризику банку. Економічний простір. 2021. № 174. С. 95–101.
- 12.Кунгурцев А.Г. Машинне навчання: основи та застосування. Київ: Наукова думка, 2018.
- 13.Лук'яненко І.Г., Горецька Л.Л. Інвестиційний менеджмент. Київ: Центр учбової літератури, 2016.
- 14.Мельник Л.Г., Скрипник О.В. Використання методів машинного навчання для оцінки кредитоспроможності позичальників. Вісник Сумського державного університету. Серія: Економіка. 2021. № 1. С. 74–81.
<https://doi.org/10.21272/1815-9032.2021.1.74>
- 15.Національний банк України. Звіт про фінансову стабільність, грудень 2024.
URL: https://bank.gov.ua/admin_uploads/article/FSR_2024-H2.PDF
- 16.Підлісецька А.П., Рубльова О.С. Машинне навчання у фінансах. Київ: КНУ імені Тараса Шевченка, 2019.
- 17.Примостка Л.О., Лисенок О.В. Сучасні технології оцінювання кредитоспроможності корпоративних позичальників банків. Фінанси України. 2022. № 6. С. 112–128.
- 18.Рєпіна І.М. Кредитний ризик банку: теорія, практика, управління. Київ: Кондор, 2016.
- 19.Смолінська С.Д., Венгер Т.Г. Розвиток методик оцінки кредитоспроможності позичальників у сучасних умовах. Економіка та держава. 2022. № 11. С. 73–77.
- 20.Addo P.M.F., Popoola S.I., Narteh B., Koledoye A. Machine learning applications in credit scoring: A systematic review. Expert Systems with Applications. 2020. Vol. 156. 113429.
<https://doi.org/10.1016/j.eswa.2020.113429>

21. Akiba T., Sano S., Yanase T., Ohta T., Koyama M. Optuna: A next-generation hyperparameter optimization framework. Proceedings of the 25th ACM SIGKDD. 2019. Pp. 2623–2631. <https://doi.org/10.1145/3292500.3330701>
22. Altman E.I. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. The Journal of Finance. 1968. Vol. 23(4). Pp. 589–609. <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>
23. Altman E.I., Sabato G. Modelling credit risk for SMEs: Evidence from the US market. Journal of Banking & Finance. 2007. Vol. 31(3). Pp. 722–742.
24. Anderson R. The Credit Scoring Toolkit: Theory and Practice for Retail Credit Risk Management. Oxford University Press, 2007.
25. Baesens B., Van Gestel T., Vanthienen J. Benchmarking state-of-the-art classification algorithms for credit scoring. Journal of the Operational Research Society. 2003. Vol. 54(6). Pp. 627–635.
26. Bastos J.A. Predicting credit scores with boosted decision trees. Forecasting. 2022. Vol. 4(4). Pp. 925–935. <https://doi.org/10.3390/forecast4040050>
27. Breiman L. Random forests. Machine Learning. 2001. Vol. 45(1). Pp. 5–32. <https://doi.org/10.1023/A:1010933404324>
28. Chen T., Guestrin C. XGBoost: A scalable tree boosting system. Proceedings of the 22nd ACM SIGKDD. 2016. Pp. 785–794. <https://doi.org/10.1145/2939671.2939785>
29. Danenas P., Garsva G., Krilavicius T. A comprehensive analysis of ensemble methods for credit scoring based on big data. Information Technology and Control. 2021. Vol. 50(2). Pp. 268–285. <https://doi.org/10.5755/j01.itc.50.2.27783>
30. Deloitte. Credit risk modelling: Current practices and applications. 2023. URL: <https://www2.deloitte.com/content/dam/Deloitte/global/Documents/Financial-Services/gx-fsi-credit-risk-modelling.PDF>

- 31.Dorfer T.A. Bagging vs. Boosting: The power of ensemble methods in machine learning. Towards AI. 2023. URL: <https://pub.towardsai.net/bagging-vs-boosting-the-power-of-ensemble-methods-in-machine-learning-6404e33524e6>
- 32.Dudley W. Credit Risk Management for Dummies. For Dummies, 2012.
- 33.Fawcett T. An introduction to ROC analysis. Pattern Recognition Letters. 2006. Vol. 27(8). Pp. 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- 34.Figini S., Gigliarano C. A review on machine learning for credit scoring. Journal of the Operational Research Society. 2018. Vol. 69(11). Pp. 1839–1852. <https://doi.org/10.1080/01605682.2017.1352125>
- 35.Friedman J.H. Greedy function approximation: A gradient boosting machine. The Annals of Statistics. 2001. Vol. 29(5). Pp. 1189–1232. <https://doi.org/10.1214/aos/1013203450>
- 36.Hyndman R.J., Athanasopoulos G. Forecasting: Principles and Practice. OTexts, 2018. URL: <https://otexts.com/fpp2/>
- 37.James G., Witten D., Hastie T., Tibshirani R. An Introduction to Statistical Learning: With Applications in R. Springer, 2013.
- 38.Kaggle Inc. Polish Companies Bankruptcy Data [Dataset]. 2017. URL: <https://www.kaggle.com/datasets/marcinrutecki/polish-companies-bankruptcy-data>
- 39.Ke G., Meng Q., Finley T., Wang T., Chen W., Ma W., Ye Q., Liu T.-Y. LightGBM: A highly efficient gradient boosting decision tree. Advances in Neural Information Processing Systems. 2017. Vol. 30. <https://doi.org/10.48550/arXiv.1711.08013>
- 40.Khandani A.E., Kim A.J., Lo A.W. Consumer credit risk models via machine-learning algorithms. Journal of Banking & Finance. 2010. Vol. 34(11). Pp. 2767–2787. <https://doi.org/10.1016/j.jbankfin.2010.06.001>
- 41.Klaas J., Hilpisch Y.J. Deep Learning for Finance. O'Reilly, 2022.

42. Kononenko I. On the (im)possibility of using machine learning for credit scoring in small datasets. Proceedings of DMKD'08, 2008.
43. Lando D., Nielsen M. Correlation in corporate defaults: Contagion or conditional independence? Journal of Financial Intermediation. 2010. Vol. 19(3). Pp. 355–372.
44. Lemaître G., Nogueira F., Aridas C.K. Imbalanced-learn: A Python toolbox to tackle the curse of imbalanced datasets in machine learning. Journal of Machine Learning Research. 2017. Vol. 18(17). Pp. 1–5. URL: <https://jmlr.org/papers/v18/16-365.html>
45. Lessmann S., Baesens B., Seow H.-Y., Thomas L.C. Benchmarking state-of-the-art classification algorithms for credit scoring: An *uPDate*. European Journal of Operational Research. 2015. Vol. 247(1). Pp. 124–136. <https://doi.org/10.1016/j.ejor.2015.05.025>
46. Lopez de Prado M. Advances in Financial Machine Learning. Wiley, 2018.
47. Louzada F., Ara A., Fernandes G. Imbalance problems in credit scoring: A review. Computational Statistics & Data Analysis. 2018. Vol. 119. Pp. 137–151. <https://doi.org/10.1016/j.csda.2017.09.006>
48. Lundberg S.M., Lee S.-I. A unified approach to interpreting model predictions. Advances in Neural Information Processing Systems. 2017. Vol. 30. <https://doi.org/10.48550/arXiv.1705.07874>
49. McKinsey & Company. The future of bank risk management. McKinsey Working Papers on Risk, 2023. URL: <https://www.mckinsey.com/business-functions/risk/our-insights/the-future-of-bank-risk-management>
50. Moody's Analytics. Best practices in credit risk management. White Paper Series, 2022. URL: <https://www.moodyanalytics.com/risk-perspectives-magazine/credit-risk-management>

51. Moscatelli M., Narizzano F., Parlapiano F., Viggiano G. Corporate default forecasting with machine learning. Bank of Italy Occasional Paper Series. 2023. No. 624.
52. Quinlan J.R. Induction of decision trees. Machine Learning. 1986. Vol. 1(1). Pp. 81–106. <https://doi.org/10.1007/BF00116251>
53. Russell S., Norvig P. Artificial Intelligence: A Modern Approach. 4th ed. Pearson, 2021.
54. S&P Global Market Intelligence. Credit assessment scorecards: Methodology, assumptions and limitations. 2023. URL: <https://www.spglobal.com/marketintelligence/en/solutions/credit-assessment-scorecards>
55. Siddiqi N. Credit Risk Scorecards: Developing and Implementing Intelligent Credit Scoring Systems. Wiley, 2017.
56. Thomas L.C. Consumer Credit Models: Pricing, Profit and Portfolios. Oxford University Press, 2017.
57. Wolpert D.H. Stacked generalization. Neural Networks. 1992. Vol. 5(2). Pp. 241–259. [https://doi.org/10.1016/S0893-6080\(05\)80022-1](https://doi.org/10.1016/S0893-6080(05)80022-1)
58. Zieba M., Tomczak S.K., Tomczak J.M. Ensemble boosted trees with synthetic features generation in application to bankruptcy prediction. Expert Systems with Applications. 2016. Vol. 58. Pp. 93–101. <https://doi.org/10.1016/j.eswa.2016.04.001>
59. Zhou Z.H. Machine Learning. Springer, 2021.

ДОДАТКИ

Додаток А

Таблиця А.1 – Порівняльна характеристика методів машинного навчання для прогнозування корпоративного дефолту

Метод	Покоління / рік	AUC (орієнт.)	Нелінійн.	Інтерпретованість	Принципове обмеження
Z-score Альтмана	I / 1968	~0,70	Ні	Висока	5 ознак; лінійність; потребує перекалібрування
Логістична регресія	II / 1970+	~0,78	Ні	Висока	Лінійна межа класів; чутлива до мультиколінеарності
Дерева рішень (CART)	II / 1984	~0,75	Висока	Висока	Висока дисперсія; схильність до перенавчання
SVM (опорні вектори)	II / 1995	~0,80	Середня (ядра)	Низька	Складність підбору ядра; погана масштабованість
Random Forest	III / 2001	~0,87	Висока	Середня (MDI)	Не пояснює окреме рішення без додаткових засобів
XGBoost	III / 2016	~0,91	Дуже висока	Низька	Непрозорий; чутливий до підбору гіперпараметрів
LightGBM	III / 2017	~0,91	Дуже висока	Низька	Схильний до перенавчання без регуляризації
MLP (нейронна мережа)	III / 1990-ті+	~0,86	Дуже висока	Дуже низька	Потребує великих обсягів даних; «чорна скринька»
Стекінг + SHAP (ця робота)	IV / 2017+	0,924	Дуже висока	Висока (SHAP)	Вища обчислювальна складність та час навчання

Джерело: складено автором на основі [22, 27, 28, 37, 39, 45, 48, 52, 53, 57, 58]

Додаток Б




Рисунок Б.1 – Блок-схема архітектури дворівневої ансамблевої стекінгової моделі оцінювання кредитного ризику корпоративних позичальників. Джерело: побудовано автором

Додаток В




Рисунок В.1 – Блок-схема пайплайну системи оцінювання кредитного ризику корпоративних клієнтів. *Джерело: побудовано автором.*

Додаток Г




Рисунок Г.1 – Матриця точності класифікації ансамблевої стекінгової моделі (тестова вибірка, $\tau^* = 0,31$). Джерело: побудовано автором.




Рисунок Г.2 – Важливість ознак за показником MDI (усі 74 ознаки: 64 фінансові коефіцієнти + 10 індикаторів пропусків, Random Forest, 3rd year зріз). Джерело: побудовано автором.

Додаток Д

Таблиця Д.1 – Топ-15 ознак за глобальною важливістю (SHAP) та порівняння з MDI (Random Forest)

Ранг SHAP	Ознака	Фінансовий коефіцієнт	$\bar{\varphi}_j$ (SHAP)	Ранг MDI (RF)
1	Attr34	(приб.+амортиз.) / заг.зобов'язання (DSCR)	0,0847	1
2	Attr1	ROA (чист.прибуток/активи)	0,0712	3
3	Attr5	Ліквідний коеф. у днях	0,0634	2
4	Attr7	ЕБІТ / активи	0,0598	5
5	Attr8	Власний капітал / борг	0,0541	4
6	Attr2	Борг / активи	0,0487	6
7	Attr27	ЕБІТ / фін. витрати (ICR)	0,0463	9
8	Attr3	Роб. капітал / активи	0,0421	7
9	Attr15	Термін погашення боргу (дні)	0,0398	11
10	Attr24	Рентаб. активів (3 р.)	0,0374	8
11	Attr39	Оборотність активів	0,0298	10
12	Attr18	Грошові кошти / активи	0,0271	14
13	Attr42	Виручка / запаси	0,0249	12
14	Attr11	Зобов'язання / ЕБІТДА	0,0223	13
15	Attr6	Нерозп.прибуток / активи	0,0201	15

Джерело: розраховано автором на основі [27, 48, 58] та власних розрахунків