

УДК 336.64:004.8

DOI: <https://doi.org/10.32782/2415-3583/39.10>**Смерічевський С.Ф.**доктор економічних наук, професор,
професор кафедри маркетингу

Державний університет «Київський авіаційний інститут»

ORCID: <https://orcid.org/0000-0003-2102-1524>**Біличенко М.М.**

аспірант

Державний університет «Київський авіаційний інститут»

ORCID: <https://orcid.org/0000-0003-4657-1039>

ЗАСТОСУВАННЯ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ АНАЛІЗУ ФІНАНСОВОЇ БЕЗПЕКИ ПІДПРИЄМСТВА

У статті запропоновано та апробовано пояснюваний підхід до прогнозування банкрутства підприємств України на основі сучасних методів штучного інтелекту. Основою моделювання стало 17 фінансово-економічних показників і три цифрові індикатори, що дозволило врахувати не лише традиційні економічні фактори, а й вплив цифрової трансформації на фінансову безпеку компаній. У зв'язку з тим, що більшість сучасних моделей штучного інтелекту є «чорними скриньками», у роботі застосовано інструменти пояснюваного штучного інтелекту (XAI), зокрема оцінювання важливості ознак та графіки часткової залежності (PDP). Ці методи дозволили не лише визначити ключові фактори ризику, які найбільше впливають на ймовірність банкрутства, але й кількісно оцінити напрям та характер їх впливу у всьому діапазоні значень. Такий підхід сприяє кращому розумінню логіки роботи моделі та підвищує її практичну цінність для менеджменту підприємств. У статті також запропоновано інноваційний алгоритм використання великих мовних моделей штучного інтелекту для автоматизованого інтерпретування графіків PDP. Це дає змогу перетворювати складні статистичні залежності у зрозумілі для нефахівців економічні пояснення, що суттєво підвищує доступність аналітики для малих і середніх підприємств з обмеженими аналітичними ресурсами. Результати дослідження підтверджують, що поєднання XGBoost, підходів пояснюваного штучного інтелекту і LLM забезпечує не лише високу точність прогнозування, а й формує інтерпретовані висновки, які можуть бути легко впроваджені на підприємствах. Запропонований підхід сприяє посиленню фінансово-економічної безпеки підприємств та є корисним як для науковців, так і для практиків у сфері ризик-менеджменту й управління бізнесом у сучасних умовах цифрової трансформації.

Ключові слова: пояснюваний штучний інтелект, прогнозування банкрутства, фінансова безпека підприємства, антикризове управління, великі мовні моделі.

Постановка проблеми. Сучасні економічні умови в Україні характеризуються підвищенням ризиків неплатоспроможності бізнесу. Повномасштабне вторгнення та супутня економічна криза завдали важких втрат: 64% малих і середніх підприємств змушені були тимчасово призупинити або закрити діяльність від початку війни 2022 року [1]. Хоча більшість із них згодом відновили роботу, загальний рівень невизначеності залишається високим. У таких умовах фінансова безпека стає ключовим чинником стійкості бізнесу, адже підприємства все ще зіштовхуються з труднощами ліквідності та попиту.

На сьогодні не існує єдиної загально визнаної методики прогнозування банкрутства, хоча завдяки тривалим дослідженням зарубіжних та вітчизняних науковців розроблено цілу низку моделей. Класичні підходи широко застосовуються для оцінки фінансового стану, проте вони мають обмеження щодо точності в сучасних умовах ринку. Усе це створює потребу в інноваційних підходах до моделювання та прогнозування банкрутства, які поєднували б класичні фінансові індикатори з новими цифровими метриками розвитку. Світовий

досвід свідчить, що застосування штучного інтелекту та машинного навчання відкриває нові можливості для підвищення точності прогнозів. Це дозволяє побудувати комплексні гібридні моделі банкрутства, які інтегрують фінансові показники з показниками цифрової активності бізнесу і можуть краще передбачати кризові ситуації.

Втім, впровадження сучасних методів ШІ супроводжується новими викликами. Хоча неймережі та інші складні алгоритми часто демонструють вищу точність прогнозування, їх внутрішня логіка нерідко є непрозорою для людини. Такі моделі функціонують як «чорні скриньки», тобто приймають рішення без зрозумілого пояснення причин і факторів. Це породжує серйозну проблему довіри: користувачі та експерти не впевнені, чому саме модель зробила той чи інший прогноз. Відсутність прозорості означає, що в роботі алгоритму можуть залишатися прихованими похибки або упередження, які важко виявити і виправити.

Аналіз останніх досліджень і публікацій. Упродовж останніх років у світовій науковій літературі спостерігається зростання уваги до концепції пояс-



нюваного штучного інтелекту (Explainable Artificial Intelligence, XAI) у задачах фінансового прогнозування та оцінювання ризиків. Якщо раніше дослідження у сфері прогнозування банкрутства були зосереджені переважно на підвищенні точності моделей машинного навчання, то сучасні роботи акцентують увагу на необхідності забезпечення прозорості та інтерпретованості результатів.

Серед зарубіжних досліджень варто відзначити роботу Min S. Park та його колег [2], у якій розглянуто проблему інтерпретації моделей машинного навчання при прогнозуванні банкрутства підприємств. Автори застосували алгоритм LIME для пояснення рішень складних моделей класифікації та продемонстрували, що використання локальних пояснень дозволяє виявити ключові фінансові фактори, які впливають на ризик неплатоспроможності. Подальший розвиток цього напрямку представлено у роботі Yu-Cheng Lin [3], де запропоновано гібридну модель прогнозування банкрутства на основі нейронної мережі із інтеграцією методів SHAP та LIME. Застосування інструментів XAI забезпечило інтерпретацію результатів моделі та виявлення впливу окремих показників на фінальний прогноз.

В українській науковій літературі питання пояснюваного штучного інтелекту лише починає формуватися як окремий напрям досліджень. Зокрема, Г.В. Горячев [4] розглядає можливості застосування пояснюваного штучного інтелекту у підтримці управлінських рішень для великих систем із вимірюваним впливом на КРІ підприємства. У роботі аналізуються сучасні підходи до впровадження ПШІ, визначаються ключові групи показників ефективності (фінансові, операційні, клієнтські, інноваційні) та окреслюються організаційні передумови інтеграції таких технологій. У сфері банківської безпеки та фінансових ризиків варто відзначити роботу П.С. Усіка [5], присвячену дослідженню технологій забезпечення кібербезпеки банківських систем із використанням штучного інтелекту. Автор аналізує інтеграцію інтелектуальних систем для виявлення аномалій, шахрайства та фішингових атак.

Водночас аналіз сучасних публікацій свідчить, що в українському науковому просторі відсутні комплексні дослідження, присвячені застосуванню методів пояснюваного штучного інтелекту саме для прогнозування банкрутства підприємств та оцінювання їх фінансової безпеки. Наявні роботи або зосереджені на загальних аспектах управління, або розглядають окремі напрями використання ШІ (зокрема у кібербезпеці), проте не інтегрують інструменти XAI в задачі моделювання ризику неплатоспроможності.

Метою статті є розроблення та апробація пояснюваного підходу на основі штучного інтелекту для прогнозування ймовірності банкрутства та оцінювання впливу фінансово-економічних факторів на фінансову безпеку українських підприємств із подальшою трансформацією результатів моделювання в управлінські рекомендації.

Виклад основного матеріалу дослідження. Для аналізу було використано модель прогнозування банкрутства підприємств, побудовану у роботі [6]. У межах зазначеного дослідження здійснено порівняння кількох

сучасних алгоритмів машинного навчання, за результатами якого встановлено, що модель XGBoost забезпечила найвищу точність на тестовій вибірці – близько 82 % (табл. 1). Крім того, її прогностична ефективність перевищувала результати моделі Random Forest майже на 3 %, що стало підставою для вибору XGBoost як базової моделі для подальшого аналізу.

Важливо зазначити, що для побудови моделі було використано 17 фінансових показників, сформованих на основі балансу та звіту про фінансові результати відповідно до літературних джерел і попередніх досліджень [6, 7]. Принципово важливим є те, що всі відібрані змінні мають чіткий економічний зміст, що створює основу для їх подальшої інтерпретації та трансформації в управлінські рекомендації.

Разом із тим, отримання високої точності у складних моделях машинного навчання супроводжується ризиком втрати інтерпретованості. На відміну від логістичної регресії, де коефіцієнти можуть бути безпосередньо трактовані як напрям і сила впливу змінних, у випадку XGBoost така інтерпретація не є прямою. У зв'язку з цим виникає потреба у застосуванні підходів пояснюваного штучного інтелекту, які дозволяють перетворити «чорну скриньку» моделі на інструмент, придатний для антикризового управління.

У межах пояснюваного ШІ зазвичай розрізняють локальні та глобальні методи пояснення. Локальні методи орієнтовані на інтерпретацію окремого прогнозу для конкретного об'єкта. Класичним прикладом такого підходу є LIME, який формує спрощену модель-пояснювач для конкретного спостереження. LIME набув широкої популярності завдяки універсальності, однак може страждати на нестабільність результатів та інші обмеження [8]. На противагу цьому, глобальні методи надають інтерпретацію поведінки моделі в цілому по всьому набору даних, демонструючи загальні залежності між ознаками та прогнозом. Прикладами глобальних пояснень є важливість ознак (feature importance), що оцінює внесок кожної змінної у модельний результат, та Partial Dependence Plots (PDP), які візуалізують вплив значень ознак на середній прогноз. Такі підходи дозволяють перевірити, чи узгоджуються виявлені моделлю шаблони з економічною логікою та експертними уявленнями, що є критично важливим для використання моделі на підприємствах [9].

З огляду на мету дослідження пріоритет було надано саме глобальним методам. Це пояснюється тим, що управлінські рішення у фінансовій безпеці зазвичай спираються не на одиничний «випадок», а на системні правила та порогові орієнтири, які можна вивести з агрегованої поведінки моделі.

Після вибору фінальної моделі наступним кроком стало дослідження важливості змінних у побудованій

Таблиця 1 – Результати оцінки найкращих моделей з використанням змінних цифровізацій

Метрики	Random forest	XGBoost
Accuracy	80,11%	82,46%
F Beta 2	76,41%	78,17%
ROC AUC	79,67%	81,89%

Джерело: [6]

моделі XGBoost. Для цього було побудовано графік важливості змінних (рис. 1), що дозволяє візуально оцінити внесок кожної із змінних у процес прийняття рішення моделлю [10]. Важливість ознак є ключовим елементом аналізу, оскільки дає відповідь на запитання: які фактори модель використовує найінтенсивніше для формування прогнозу ризику банкрутства.

Згідно з отриманими результатами, найбільший вплив на результат класифікації мали наступні змінні:

x12 – коефіцієнт валового прибутку до поточних зобов'язань;

x53 – коефіцієнт покриття необоротних активів;

x18 – коефіцієнт валової рентабельності;

x8 – коефіцієнт фінансової незалежності;

dg_3_ecommerce – коефіцієнт електронної комерції.

З позиції економічної інтерпретації така структура впливовості є змістовною оскільки модель «зосереджується» на показниках, що відображають здатність бізнесу генерувати валовий результат відносно короткострокових зобов'язань та загальну ефективність операційної діяльності.

Разом з тим, необхідно наголосити на методичному обмеженні: важливість ознак демонструє «вагу» змінної для моделі, проте сама по собі не дає відповіді на питання напряму впливу (ризик зростає чи знижується) і не показує порогових зон, у яких ризик змінюється найбільш різко. З огляду на управлінські цілі, саме ці питання є визначальними. Тому подальший етап аналізу спрямований на встановлення форми залежностей.

Фінальним етапом моделювання стало визначення напряму та сили впливу кожної змінної на ймовірність банкрутства підприємства. Оскільки використана модель XGBoost є нелінійною та складною для безпосередньої інтерпретації, для розкриття її внутрішньої логіки було застосовано графіки часткової залежності. Графіки часткової залежності дозволяють оцінити маржинальний (граничний) ефект окремої змінної

або пари змінних на прогнозоване значення цільової змінної, усереднюючи вплив усіх інших факторів [11]. Такий підхід дає змогу не лише зафіксувати факт важливості змінної, а й пояснити, що саме відбувається з прогнозом при переході від низьких до високих значень показника.

Зважаючи на характеристики задачі, метод Partial Dependence Plot (PDP) було обрано як оптимальний інструмент пояснення. По-перше, мета полягає в тому, щоб зрозуміти загальні закономірності впливу ознак на прогнозовану величину по всьому датасету, а не пояснювати окремі точкові передбачення. PDP безпосередньо надає глобальну інтерпретацію, показуючи, як зміна кожного фактору в цілому впливає на результат моделі. Це відповідає запиту прикладних експертів: їм важливо знати загальний вплив факторів (що підвищує ризик банкрутства, а що знижує), аби довіряти моделі та використовувати її висновки в управлінні. По-друге, PDP забезпечує простоту та наочність комунікації: напрям та форма кривої відображають логіку моделі без спеціальної математичної підготовки. По-третє, у нашому наборі даних ключові фактори мають економічно осмислене незалежне значення, а мультиколінеарність не є критичною, що дозволяє інтерпретувати PDP впевнено та використовувати їх як основу для рекомендацій.

Результати побудови графіків часткової залежності (рис. 2) загалом підтверджують теоретичну обґрунтованість виявлених залежностей. У контексті даного дослідження найінформативнішими виявилися PDP для змінних, які формують виражені стрибкоподібні зміни прогнозу та мають чітку економічну інтерпретацію як управлінські важелі фінансової безпеки.

Водночас на практиці значна частина підприємств має обмежені кадрові та аналітичні ресурси, що ускладнює самостійну інтерпретацію результатів навіть за наявності інструментів пояснюваного штучного інтелекту. У зв'язку з цим, у роботі запропоновано




Рисунок 1 – Графік важливості змінних у фінальній моделі XGBoost

Джерело: складено автором

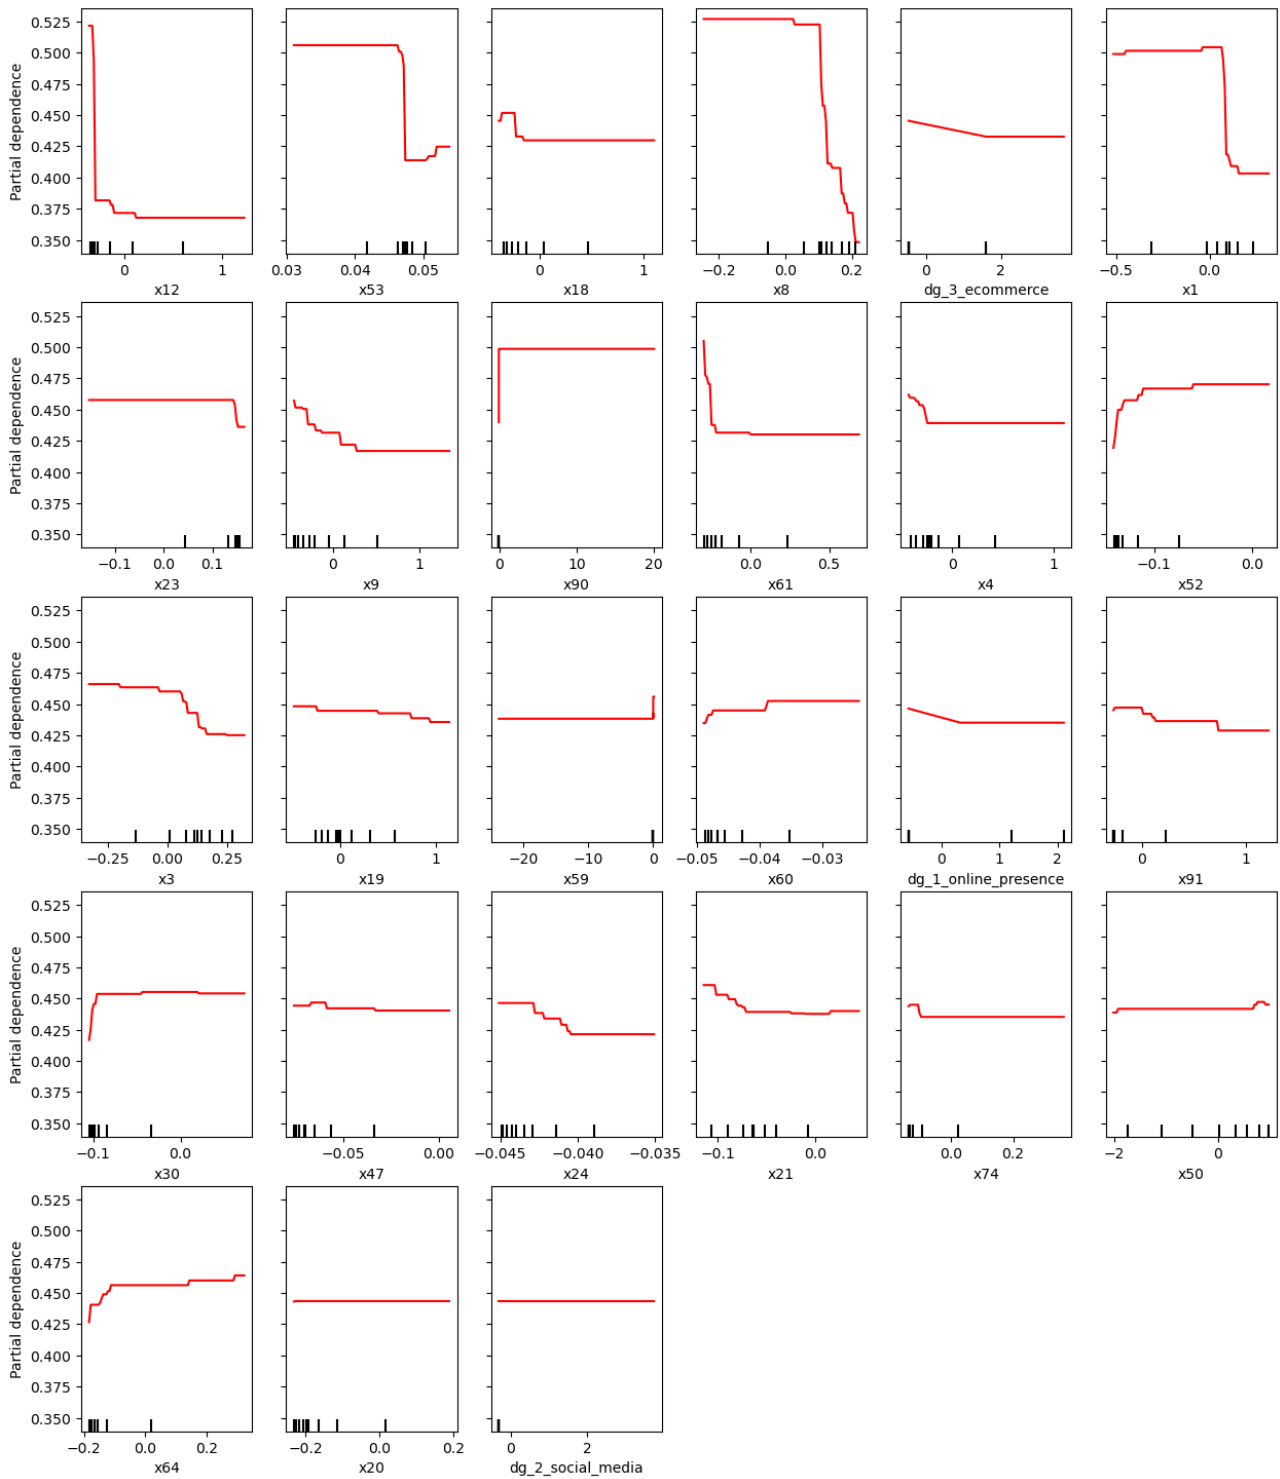


Рисунок 2 – PDP-графіки для змінних фінальної моделі XGBoost

Джерело: складено автором

доповнити аналіз PDP використанням великих мовних моделей (LLM) для автоматизованого формування економічно змістовних пояснень.

Запропонований підхід передбачає реалізацію такого алгоритму:

- формування структурованого опису змінних із зазначенням формули розрахунку та економічної сутності показника;

- побудову графіків PDP із використанням відповідного програмного забезпечення (Python, R тощо);

- формування спеціалізованого промту для економічної інтерпретації результатів;

- передавання опису змінних, графіків та промту у велику мовну модель (ChatGPT, Gemini, Grok);

- отримання текстових аналітичних висновків.

У межах апробації запропонованого підходу було використано попередньо сформований опис змінних, побудовані PDP-графіки та спеціалізований промт. Для інтерпретації результатів застосовано модель ChatGPT 5.1, що дозволило отримати структуровані пояснення впливу ключових факторів.

По-перше, змінна $x8$ (загальний власний капітал / загальні пасиви), яка відображає фінансову незалежність підприємства, демонструє найбільш виражений нелінійний ефект. На PDP-кривій простежується різке зниження прогнозованої ймовірності банкрутства при переході від низьких значень $x8$ до помірних, після чого ефект поступово стабілізується. Така форма залежності узгоджується з економічною логікою: низька частка власного капіталу підвищує вразливість до кредитного та ліквідного тиску, тоді як досягнення мінімально достатнього рівня капіталізації суттєво підвищує стійкість. Управлінська цінність цього висновку полягає у тому, що PDP фактично фіксує критичний коридор, у якому навіть відносно невеликі зміни структури пасивів можуть дати непропорційно великий ефект у зниженні ризику. Відповідно, для підприємств із низькими значеннями $x8$ першочерговими стають рішення щодо докапіталізації, оптимізації боргового портфеля та зменшення частки короткострокових зобов'язань, оскільки саме в цій зоні очікується найбільший граничний ефект з погляду моделі.

По-друге, змінна $x12$ (валовий прибуток / загальні поточні зобов'язання) характеризує здатність підприємства обслуговувати короткострокові зобов'язання за рахунок операційного результату. PDP для $x12$ має чітко виражений пороговий характер: у зоні низьких значень показника прогнозований ризик банкрутства суттєво вищий, однак зі зростанням $x12$ спостерігається різке зниження ризику, після чого крива переходить у відносно пласку ділянку. Це свідчить, що для системи раннього попередження найбільш важливим є вихід підприємства з критичної зони низького покриття поточних зобов'язань валовим прибутком. Практична інтерпретація цього результату полягає у фокусі на заходах, які безпосередньо впливають на чисельник та знаменник показника: підвищення валового прибутку через контроль собівартості, перегляд цінової політики, зміщення асортименту у більш маржинальні позиції, а також управління поточними зобов'язаннями (переговори з постачальниками, реструктуризація коротких боргів).

По-третє, змінна $x53$ (загальний власний капітал / основні засоби) відображає, якою мірою власний капітал покриває довгострокові інвестиції підприємства. PDP-графік для $x53$ демонструє стрибкоподібне зниження прогнозованої ймовірності банкрутства при досягненні певного рівня показника, що вказує на наявність «порогового» режиму фінансової стійкості. Економічно це означає, що недостатність власного капіталу для фінансування необоротних активів підвищує залежність від зовнішніх джерел та уразливість до шоків ліквідності і вартості запозичень. Пояснюваність у форматі PDP дозволяє розглядати $x53$ як індикатор не лише структури активів, а й як маркер узгодженості інвестиційної та фінансової політики: у разі низького $x53$ підвищення ризику відбувається не поступово, а може проявлятися як перехід у кри-

тичний стан. Відповідно, з позиції управління фінансовою безпекою важливими стають рішення щодо докапіталізації, перегляду інвестиційних програм, реалізації або консервації малоефективних активів, а також балансування довгострокових вкладень із джерелами фінансування.

По-четверте, змінна $dg_3_ecommerce$ (рівень можливостей електронної комерції) демонструє стійкий негативний зв'язок з імовірністю банкрутства: підприємства з найвищим рівнем розвитку електронної комерції (2 бали) мають у середньому на ~3% нижчу ймовірність банкрутства порівняно з підприємствами, які не мають жодних можливостей онлайн-продажу. Характер PDP-кривої вказує, що найбільш суттєвий ефект досягається при переході від нульового рівня до наявності інструментів e-commerce, після чого спостерігається часткове насичення. В управлінському вимірі це дозволяє трактувати розвиток базового e-commerce функціоналу як один із превентивних заходів у системі фінансової безпеки, особливо для підприємств, які перебувають у зоні підвищеного ризику за фінансовими коефіцієнтами.

Загалом отримані результати свідчать, що поєднання методів пояснюваного штучного інтелекту на основі графіків часткової залежності з інструментами великих мовних моделей забезпечує принципово новий рівень прикладної інтерпретованості прогнозних систем. Запропонований підхід дозволяє не лише ідентифікувати найбільш значущі фактори ризику та визначити критичні діапазони їх значень, але й трансформувати складні аналітичні результати у структуровані економічно змістовні пояснення, доступні для сприйняття управлінським персоналом.

Висновки. У результаті дослідження сформовано та апробовано модель прогнозування банкрутства на основі алгоритму XGBoost із використанням фінансово-економічних і цифрових показників, яка продемонструвала високу прогностичну здатність у вибірці підприємств переробної промисловості України. Отримані результати підтверджують доцільність застосування сучасних методів машинного навчання для оцінювання ризиків фінансової неспроможності в умовах цифрової трансформації.

Ключовим результатом дослідження є обґрунтування та реалізація пояснюваного підходу до інтерпретації прогнозних моделей. Поєднання аналізу важливості ознак і графіків часткової залежності дозволило трансформувати модель типу «чорної скриньки» в інструмент підтримки управлінських рішень. Зокрема, графік важливості змінних забезпечив ідентифікацію пріоритетних факторів ризику, тоді як PDP-аналіз дозволив встановити напрям, характер і порогові ефекти впливу ключових змінних на ймовірність банкрутства.

Науковою новизною роботи є інтеграція класичних інструментів пояснюваного штучного інтелекту з можливостями великих мовних моделей для автоматизованої економічної інтерпретації результатів. Запропонований підхід на основі поєднання PDP та LLM дозволяє перетворювати складні аналітичні залежності у структуровані та змістовні пояснення, що суттєво знижує бар'єри практичного використання інтелектуальних моделей на підприємствах з обмеженими ана-

літичними ресурсами. Практична реалізація запропонованого підходу передбачає формування проактивних управлінських рекомендацій через пріоритизація зон управлінського контролю, серед яких найбільш критичними виступають управління прибутковістю та маржинальністю, а також підвищення фінансової автономії підприємства.

Загалом результати дослідження підтверджують, що поєднання сучасних методів машинного навчання, інструментів пояснюваного штучного інтелекту та

можливостей великих мовних моделей забезпечує не лише підвищення точності прогнозування банкрутства, а й формування інтерпретованих, економічно обґрунтованих і практично значущих висновків. Розроблений підхід дозволяє завчасно ідентифікувати фінансові загрози, визначати пріоритетні напрями управлінського впливу та обґрунтовувати антикризові заходи, що сприяє посиленню фінансово-економічної безпеки підприємств у сучасних умовах цифрової трансформації.

Список використаних джерел:

1. Enhancing Resilience by Boosting Digital Business Transformation in Ukraine. *OECD Publishing*, 2024. DOI: <https://doi.org/10.1787/4b13b0bb-en>
2. Park M. S., Son H., Hyun C., Hwang H. J. Explainability of Machine Learning Models for Bankruptcy Prediction. *IEEE Access*. 2021, 9. DOI: <https://doi.org/10.1109/ACCESS.2021.3110270>
3. Lin Yu-Cheng, Padliansyah R., Lu Yu-Hsin, Liu Wen-Rang. Bankruptcy prediction: Integration of convolutional neural networks and explainable artificial intelligence techniques. *International Journal of Accounting Information Systems*. 2025. № 56. DOI: <https://doi.org/10.1016/j.accinf.2025.100744>
4. Горячев Г.В. Пояснюваний штучний інтелект у підтримці управлінських рішень для великих систем із вимірюваним впливом на KPI підприємства. *Таврійський науковий вісник*. 2025. № 5 (1). С. 366–375. DOI: <https://doi.org/10.32782/tmv-tech.2025.5.1.39>
5. Усік П.С., Смірнова Т.В., Буравченко К.О., Смірнов О.А., Улічев О.С., Смірнов С.А. Дослідження технологій забезпечення кібербезпеки банківських систем з використанням штучного інтелекту. *Кібербезпека: освіта, наука, технології*. 2025. № 1 (29). С. 704–716. DOI: <https://doi.org/10.28925/2663-4023.2025.29.930>
6. Біличенко М.М. Оцінка фінансової безпеки підприємства методами машинного навчання. *Цифрова економіка та економічна безпека*. 2024. № 4 (13). С. 101–107. DOI: <https://doi.org/10.32782/dees.13-15>
7. Hamdi M., Mestiri S., Arbi A. Artificial Intelligence Techniques for Bankruptcy Prediction of Tunisian Companies: An Application of Machine Learning and Deep Learning-Based Models. *Journal of Risk and Financial Management*. 2024. Vol. 17 (4). DOI: <https://doi.org/10.3390/jrfm17040132>
8. Knab, P.; Marton, S.; Schlegel, U.; Bartelt, C. Which LIME Should I Trust? Concepts, Challenges, and Solutions. *Explainable Artificial Intelligence Communications in Computer and Information Science*. 2025. 2577. P. 28–52. DOI: https://doi.org/10.1007/978-3-032-08324-1_2
9. Brdник S., Podgorelec V., Šumak B. Assessing Perceived Trust and Satisfaction with Multiple Explanation Techniques in XAI-Enhanced Learning Analytics. *Electronics*. 2023. Vol. 12 (12), 2594. DOI: <https://doi.org/10.3390/electronics12122594>
10. Michelucci U. Feature Importance and Selection. *Fundamental Mathematical Concepts for Machine Learning in Science*. Springer Cham 2024. 249 p. DOI: https://doi.org/10.1007/978-3-031-56431-4_10
11. Molnar C. Interpretable Machine Learning: A Guide for Making Black Box Models Explainable. URL: <https://christophm.github.io/interpretable-ml-book>

References:

1. OECD. (2024). *Enhancing resilience by boosting digital business transformation in Ukraine*. OECD Publishing. DOI: <https://doi.org/10.1787/4b13b0bb-en>
2. Park, M. S., Son, H., Hyun, C., & Hwang, H. J. (2021). Explainability of machine learning models for bankruptcy prediction. *IEEE Access*, 9. DOI: <https://doi.org/10.1109/ACCESS.2021.3110270>
3. Lin, Y.-C., Padliansyah, R., Lu, Y.-H., & Liu, W.-R. (2025). Bankruptcy prediction: Integration of convolutional neural networks and explainable artificial intelligence techniques. *International Journal of Accounting Information Systems*, 56, 100744. DOI: <https://doi.org/10.1016/j.accinf.2025.100744>
4. Horiachev, H. V. (2025). Poiasniuvanyi shtuchnyi intelekt u pidtrymtsi upravlinskykh rishen dla velykykh system iz vymiryuvanyim vplyvom na KPI pidpriemstva [Explainable artificial intelligence in supporting managerial decision-making for large systems with measurable impact on enterprise KPIs]. *Tavriiskyi naukovyi visnyk*, 5 (1). DOI: <https://doi.org/10.32782/tmv-tech.2025.5.1.39>
5. Usik, P. S., Smirnova, T. V., Buravchenko, K. O., Smirnov, O. A., Ulichev, O. S., & Smirnov, S. A. (2025). Doslidzhennia tekhnolohii zabezpechennia kiberbezpeky bankivskykh system z vykorystanniam shtuchnoho intelektu [Research on cybersecurity technologies for banking systems using artificial intelligence]. *Kiberbezpeka: osvita, nauka, tekhnolohii*, 1 (29). DOI: <https://doi.org/10.28925/2663-4023.2025.29.930>
6. Bilichenko, M. M. (2024). Otsinka finansovoi bezpeky pidpriemstva metodamy mashynnoho navchannia [Assessment of enterprise financial security using machine learning methods]. *Tsyfrova ekonomika ta ekonomichna bezpeka*, 4 (13), 101–107. DOI: <https://doi.org/10.32782/dees.13-15>
7. Hamdi, M., Mestiri, S., & Arbi, A. (2024). Artificial intelligence techniques for bankruptcy prediction of Tunisian companies: An application of machine learning and deep learning-based models. *Journal of Risk and Financial Management*, 17 (4). DOI: <https://doi.org/10.3390/jrfm17040132>
8. Knab, P., Marton, S., Schlegel, U., & Bartelt, C. (2025). Which LIME should I trust? Concepts, challenges, and solutions. In *Explainable Artificial Intelligence* (Communications in Computer and Information Science, Vol. 2577, pp. 28–52). Springer. DOI: https://doi.org/10.1007/978-3-032-08324-1_2
9. Brdник, S., Podgorelec, V., & Šumak, B. (2023). Assessing perceived trust and satisfaction with multiple explanation techniques in XAI-enhanced learning analytics. *Electronics*, 12 (12). DOI: <https://doi.org/10.3390/electronics12122594>

10. Michelucci, U. (2024). Feature importance and selection. In *Fundamental Mathematical Concepts for Machine Learning in Science* (pp. 229–242). Springer. DOI: https://doi.org/10.1007/978-3-031-56431-4_10
11. Molnar, C. (2025). *Interpretable machine learning: A guide for making black box models explainable* (3rd ed.). <https://christophm.github.io/interpretable-ml-book>

Smerichevskiy Serhii, Bilychenko Maksym
State University “Kyiv Aviation Institute”

APPLICATION OF ARTIFICIAL INTELLIGENCE FOR ANALYSIS OF THE FINANCIAL SECURITY OF AN ENTERPRISE

Modern enterprises operate in conditions of high uncertainty, rapid market changes and increasing influence of digital transformation, which significantly complicates timely identification of financial instability. Traditional statistical approaches to bankruptcy prediction often fail to capture complex nonlinear relationships between financial indicators and therefore provide limited practical value for management decision-making. Machine learning models improve predictive accuracy, but their practical implementation is constrained by low interpretability, as such models frequently behave as «black boxes». This study proposes an explainable artificial intelligence approach to bankruptcy prediction and financial security assessment of Ukrainian enterprises based on financial and digital indicators. The predictive core is the XGBoost algorithm, which demonstrated the highest classification accuracy compared with alternative machine learning methods. To ensure transparency of results, explainable AI techniques were applied, including feature importance analysis and Partial Dependence Plots. These tools enabled identification of key risk factors and determination of the direction, strength and threshold effects of their impact across the dataset. The revealed dependencies correspond to economic logic and allow transformation of statistical patterns into meaningful managerial conclusions. Additionally, the research introduces an extension of the interpretability stage through the integration of large language models. The proposed procedure includes generating structured descriptions of indicators, constructing Partial Dependence Plots graphs, forming a specialized prompt and transferring analytical outputs to a large language model environment for automated economic interpretation. This significantly simplifies analytical work and increases accessibility of advanced analytics for enterprises with limited analytical resources. The obtained results confirm that the combination of machine learning models, explainable AI methods and large language models creates a new level of practical applicability of predictive analytics. The proposed approach enables early detection of financial risks, identification of critical indicator ranges and prioritization of anti-crisis managerial actions, transforming artificial intelligence from a predictive instrument into a decision-support tool for financial security management.

Keywords: explainable artificial intelligence, bankruptcy prediction, enterprise financial security, crisis management, large language models.

JEL classification: C45, G32, O33, M10

Дата надходження статті: 24.01.2026

Дата прийняття статті: 16.02.2026

Дата публікації статті: 03.03.2026