

ТЕОРЕТИКО-МЕТОДОЛОГІЧНІ ЗАСАДИ МОДЕЛЮВАННЯ КРЕДИТНОГО РИЗИКУ: КОМПРОМІС МАТЕМАТИЧНОЇ ТОЧНОСТІ, РЕГУЛЯТОРНОГО КОМПЛАЄНСУ ТА ФІНАНСОВОЇ ІНКЛЮЗІЇ

©2026 АНІСІМОВА Л. А., ВОРОНОВ В. І.

УДК 336.717.061.1:330.131.7
JEL: G21; G28; G32

Анісімова Л. А., Воронов В. І. Теоретико-методологічні засади моделювання кредитного ризику: компроміс математичної точності, регуляторного комплаєнсу та фінансової інклюзії

Актуальність проблеми постає в силу розвитку математичних методів та обчислювальних можливостей для оцінювання індивідуального кредитного ризику. Перспективи впровадження таких методів у практику ризик-менеджменту кредитної галузі вимагають детального вивчення їх сумісності з принципами макропруденційного нагляду, нормативно-правовою базою та макроекономічними цілями розвитку національної та світової економік. Додаткового вивчення потребує також теоретичне обґрунтування принципів роботи та створення наборів даних для моделювання кредитного ризику (з відповідним конструюванням ознак) з позиції мікроекономічної теорії. Мета статті полягає в теоретико-методологічній концептуалізації моделювання роздрібного кредитного ризику, компромісного балансу між прогностичною здатністю непараметричних алгоритмів, нормативними обмеженнями регуляторного комплаєнсу (Basel III/IV, GDPR) та політикою розширення фінансової інклюзії. Використано методи міждисциплінарного, теоретичного, критичного та порівняльного аналізу; синтезу; концептуалізації та формалізації. За результатами дослідження систематизовано та розкрито сутнісний мікроекономічний і регуляторний зміст емпіричних ознак моделей кредитного ризику (показників боргового навантаження, соціо-демографічних характеристик і параметрів історичної платіжної дисципліни) через призму гіпотези життєвого циклу споживання та Марковських ланцюгів міграції заборгованості. Розроблено та обґрунтовано комплексну чотирирівнірну теоретико-методологічну концепцію вибору моделей, яка інтегрує в єдину систему мікроекономічний базис, процеси моделювання ризику, регуляторні обмеження та бажані суспільно-економічні результати. Теоретично обґрунтовано, що використання банками непрозорих алгоритмів ризик-менеджменту посилює ризики жорсткого нормування капіталу та може провокувати системний ефект алгоритмічного виключення маргіналізованих груп позичальників, що стимулює відтік споживчого попиту в нерегульований сектор тіньового банкіngu. Сформульовано концепцію вибору скорингової моделі, яка дозволяє збалансувати точність і прозорість оцінки ризиків. Практичне значення результатів полягає в теоретичному обґрунтуванні доцільності переходу фінансових установ до використання адитивних glass-box архітектур, що сприяє виконанню вимог GDPR і стандартів Базельського комітету без суттєвої втрати якості прогнозування кредитного ризику, сприяючи довгостроковій інституційній стійкості фінансової системи.

Ключові слова: оцінка кредитного ризику; банківський ризик-менеджмент; фінансова інклюзія; інформаційна асиметрія в кредитуванні; регулювання кредитних послуг.

Рис.: 1. **Табл.:** 2. **Формул.:** 1. **Бібл.:** 24.

Анісімова Людмила Анатоліївна – кандидат фізико-математичних наук, доцент, заступник декана економічного факультету, Київський національний університет імені Тараса Шевченка (вул. Володимирська, 60, Київ, 01033, Україна)

E-mail: anisimova@knu.ua

ORCID: <https://orcid.org/0000-0001-9678-269X>

Воронов Володимир Ігорович – магістр, випускник Національного університету «Києво-Могилянська академія» (вул. Г. Сковороди, 2, Київ, 04070, Україна)

E-mail: volodymyr.voronov317@gmail.com

ORCID: <https://orcid.org/0009-0000-9679-8835>

UDC 336.717.061.1:330.131.7
JEL: G21; G28; G32

Anisimova L. A., Voronov V. I. The Theoretical and Methodological Foundations of Credit Risk Modelling:

A Trade-off Between Mathematical Accuracy, Regulatory Compliance, and Financial Inclusion

The relevance of the problem arises from the development of mathematical methods and computational capabilities for the assessment of individual credit risk. The prospects of implementing such methods in the risk management practice of the credit industry require a detailed examination of their compatibility with the principles of macroprudential supervision, the regulatory and legal framework, and the macroeconomic development objectives of national and global economies. Further study is also required regarding the theoretical substantiation of the underlying principles and the construction of datasets for credit risk modelling (including appropriate feature engineering) from the perspective of microeconomic theory. The aim of the article is the theoretical and methodological conceptualisation of retail credit risk modelling, focusing on the trade-off between the predictive power of non-parametric algorithms, regulatory constraints of compliance (Basel III/IV, GDPR), and policies aimed at expanding financial inclusion. The study employs methods of interdisciplinary, theoretical, critical, and comparative analysis; synthesis; conceptualisation; and formalisation. The results of the study systematise and reveal the essential microeconomic and regulatory content of empirical features used in credit risk models (such as debt burden indicators, socio-demographic characteristics, and parameters of historical payment discipline) through the lens of the life-cycle consumption hypothesis and Markov chains of debt migration. A comprehensive four-dimensional theoretical and methodological framework for model selection is developed and substantiated, integrating into a unified system the microeconomic foundation, risk modelling processes, regulatory constraints, and desired socioeconomic outcomes. It is theoretically substantiated that the use by banks of non-transparent risk management algorithms increases the risks of strict capital rationing and may induce a systemic effect of algorithmic exclusion of marginalised borrower groups, thereby

stimulating the outflow of consumer demand into the unregulated shadow banking sector. A conceptual framework for selecting scoring models is formulated, enabling a balance between the accuracy and transparency of risk assessment. The practical significance of the results lies in the theoretical substantiation for the transition of financial institutions toward additive glass-box architectures, which facilitate compliance with GDPR requirements and Basel Committee standards without a substantial loss in credit risk predictive quality, thereby contributing to the long-term institutional stability of the financial system.

Keywords: credit risk assessment; banking risk management; financial inclusion; information asymmetry in lending; regulation of credit services.

Fig.: 1. **Tabl.:** 2. **Formulae:** 1. **Bibl.:** 24.

Anisimova Liudmyla A. – PhD (Physics and Mathematics), Associate Professor, Deputy Dean of the Faculty of Economics, Taras Shevchenko National University of Kyiv (60 Volodymyrska Str., Kyiv, 01033, Ukraine)

E-mail: anisimova@knu.ua

ORCID: <https://orcid.org/0000-0001-9678-269X>

Voronov Volodymyr I. – Master, Graduate of National University of Kyiv-Mohyla Academy (2 H. Skovorody, Kyiv, 04070, Ukraine)

E-mail: volodymyr.voronov317@gmail.com

ORCID: <https://orcid.org/0009-0000-9679-8835>

У сучасному фінансовому секторі управління кредитними ризиками являє собою ключовий елемент досягнення прибутковості банківської діяльності та поєднання її з регуляторними вимогами до інституційної фінансової стійкості. Кредитний скоринг, що є основною практичною формою управління кредитними ризиками, в останні десятиліття ґрунтується на класичних параметричних моделях, таких як логістична регресія. Проте поширення більш ефективних не-параметричних моделей ансамблевого навчання, таких як XGBoost (eXtreme Gradient Boosting) та LightGBM (Light Gradient Boosting Machine), породило питання можливості переходу індустрії на більш складні підходи до кредитного скорингу. Ансамблеві архітектури здатні фіксувати складні нелінійні взаємодії, що підвищує точність прогнозування індивідуальних дефолтів та краще відображає складну взаємодію соціально-економічних ознак кредитного профілю позичальника. Проте подібні моделі є фундаментально непрозорими «чорними ящиками». Їх використання породжує конфлікт із міжнародними та національними нормативно-правовими актами, такими як GDPR (General Data Protection Regulation) і Basel в ЄС, та ECOA (Equal Credit Opportunity Act) в США, які встановлюють поняття «право на пояснення» – обов’язок кредитора надати позичальнику пояснення щодо його рішення, відмову в наданні якого не можна виправдати теоретичною чи практичною неможливістю пояснення алгоритмічної моделі прийняття рішення.

Хоча фінансова індустрія намагається вирішити цю проблему за допомогою методів post-hoc інтерпретації (зокрема, SHAP), подібні методи є лише відокремленим від прогнозової моделі наближенням. Альтернативу post-hoc інтерпретації становлять так звані glass-box моделі, як-от ЕВМ, які за дизайном здатні пояснити свої результати.

Консервативність і висока зарегульованість фінансової індустрії, що схиляє більшість інститу-

цій використовувати класичну логістичну регресію, та поява складніших моделей різного роду актуалізує необхідність дослідити та порівняти предикативну ефективність і можливості інтерпретації передбачень таких моделей між собою, та зіставити їх з регуляторними вимогами до моделей оцінки кредитного ризику, а також дослідити наслідки впровадження таких моделей для фінансової інклюзії.

ОГЛЯД ЛІТЕРАТУРИ

ТА АНАЛІЗ ПОПЕРЕДНІХ ДОСЛІДЖЕНЬ

Зацікавленість тематикою моделювання та оцінювання кредитних ризиків у банківському секторі, а також вирішення супутніх регуляторних і соціально-економічних викликів, підтверджується широтою та різноспрямованістю напрацювань сучасних представників наукових кіл. Так, питанням економіки інформації, мінімізації інформаційної асиметрії, подолання морального ризику та несприятливого відбору в межах концепції «принципал – агент» на кредитних ринках присвячено фундаментальні праці таких дослідників, як Feess E., Schieble M., Shah S., Stiglitz J. E., Weiss A. [1–3].

Математико-статистичні підходи до оцінювання кредитоспроможності позичальників, починаючи від багатовимірного дискримінантного аналізу та класичної логістичної регресії до сучасних непараметричних архітектур машинного навчання та ансамблевих методів, детально розглянуто в роботах Altman E. I., Amberg N., Bhalla D., Frank Y., Furletti M. J., Jacobson T., Montevechi A. A., Picco A. R., Quadrini V. [4–7; 13; 14; 18; 19; 22].

Виклики регуляторного комплаєнсу, трансформації нагляду в межах міжнародних стандартів Базель II, III, IV, а також макроекономічні особливості забезпечення фінансової інклюзії та системної стабільності представлені в дослідженнях Čihák M., Gourinchas P.-O., Mare D. S., Mehrotra A., Melecky M., Parker J. A., Yetman J. [8–12; 15–17; 20; 21].

Разом із тим, стрімка цифровізація фінансового сектора та посилення вимог міжнародного та національного законодавства (зокрема, норм GDPR щодо «права на пояснення») створюють методологічний конфлікт між прогностичною точністю «black-box» моделей і потребою прозорості ризик-менеджменту. Зазначені особливості, включно з необхідністю пошуку балансу між жорсткою мітигацією ризиків комерційних банків та недопущенням алгоритмічного виключення позичальників, потребують більш деталізованих теоретико-методологічних досліджень, що наразі залишається вкрай актуальним і перспективним напрямом.

МЕТА ТА МЕТОДИ ДОСЛІДЖЕННЯ

Мета статті полягає в теоретико-методологічній концептуалізації моделювання роздрібного кредитного ризику компромісного балансу між прогностичною здатністю непараметричних алгоритмів, нормативними обмеженнями регуляторного комплаєнсу (Basel III/IV, GDPR) та політикою розширення фінансової інклюзії. У статті формалізовано мікроекономічні чинники інформаційної асиметрії та агентських витрат у кредитному процесі, критично оцінено вплив жорстких регуляторних вимог до інтерпретованості моделей на оптимізацію структури банківського капіталу, а також макроекономічно обґрунтовано виникнення структурних спотворень та зниження рівня фінансової інклюзії на кредитному ринку (ефекту алгоритмічного виключення позичальників) внаслідок жорсткого математичного раціонування капіталу.

Методи дослідження. Методологічну основу роботи становить *міждисциплінарний теоретичний аналіз*, що синтезує економіку інформації, інституційну економіку, теорію кредитного ризику та машинне навчання; *метод концептуалізації* використано для декомпозиції простору ознак кредитного профілю (зокрема, через призму гіпотези життєвого циклу споживання та Марковських ланцюгів міграції простроченої заборгованості) з метою формалізації їхнього мікроекономічного змісту; *метод критичного аналізу та екстраполяції* застосовано для накладення теоретичної моделі Стігліца – Вайса на сучасні умови алгоритмічного управління ризиками та теоретичного обґрунтування механізму та системних ризиків зміщення споживчого попиту на кредитні послуги в секторі тіньового банкінгу; *метод порівняльного аналізу* – для зіставлення архітектур машинного навчання, що застосовуються для моделювання кредитного ризику.

РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

Роздрібна кредитна транзакція фундаментально функціонує в рамках економіки інформації,

характерною ознакою якої є значний ступень інформаційної асиметрії. На відміну від стандартних неокласичних товарних ринків, де ціноутворення слугує ефективним механізмом клірингу, кредитні ринки передбачають обмін поточної, реальної ліквідності на теоретичну обіцянку майбутнього погашення. Така динаміка ліквідності створює системний дисбаланс сил, який грає на користь позичальника, оскільки він за своєю природою володіє кращими знаннями щодо своєї справжньої фінансової спроможності, дисципліни, особливостей поведінки чи вразливості до зовнішніх економічних шоків. Ця інформація є переважно недоступною для кредитора. Оскільки внутрішня вартість кредиту значною мірою залежить від цих неспостережуваних характеристик, ринок роздрібного кредитування функціонує в умовах надзвичайно недосконалої інформації [1; 2].

У призмі інституційної економіки та теорії контрактів ця динаміка породжує класичну проблему «принципал – агент» між фінансовою установою та споживачем кредитної послуги. Кредитна установа, виступаючи в ролі принципала, надає капітал споживачеві (агенту) відповідно до договірного очікування його відповідального фінансового використання та планового погашення зобов'язань. Однак ці відносини призводять до значних агентських витрат, зумовлених двома інформаційними програшами. До моменту видачі кредиту принципал стикається з несприятливим відбором через прихований профіль ризику позичальника. Це означає, що банк не здатний ідеально розрізнити заявників з низьким і високим рівнем ризику. Натомість, після виплати коштів принципал наражається на так званий моральний ризик (*moral hazard*), що виникає внаслідок прихованих дій агента. Оскільки кредитор не в змозі ефективно контролювати повсякденні моделі поведінки позичальника або накопичення ним вторинної заборгованості перед іншими кредитними установами, агент може мати фінансовий стимул до більш ризикованої поведінки, повністю усвідомлюючи, що фінансовий ризик у разі повного дефолту непропорційно поглинається принципалом [1].

Системні макроекономічні наслідки окресленої проблеми були математично формалізовані Джозефом Стігліцом та Ендрю Вайсом у 1981 році. Вченими було доведено, що кредитні ринки з недосконалою інформацією системно не здатні досягнути рівноваги лише за рахунок коригування відсоткових ставок [3]. Якщо фінансова установа вбачає підвищений сукупний ризик у своєму пулі заявників і намагається зменшити цей ризик шляхом простого підвищення відсоткової ставки,

це провокує два економічно деструктивні явища. *По-перше*, несприятливий відбір, або ефект сортування, діє як руйнівний механізм відбору, що непропорційно відлякує надійних позичальників, які відмовляються платити непомірні ставки для фінансування власного безпечного споживання. Таким чином, у пулі заявників починають домінувати ненадійні позичальники, готові прийняти високі ставки саме тому, що вони мають низьку суб'єктивну ймовірність фактичного погашення боргу. *По-друге*, ефект стимулювання різко збільшує боргове навантаження на позичальника, спонукаючи його використовувати капітал для більш ризикованих ініціатив з вищою дисперсією результатів, щоб згенерувати дохід, необхідний для уникнення дефолту [2; 3].

Вони довели, що очікуваний дохід банку не зростає лінійно зі збільшенням відсоткової ставки, а радше утворює увігнуту криву. Для максимізації очікуваної прибутковості та мінімізації загального ризику дефолту портфеля банки підтримують відсоткові ставки на специфічній, оптимальній для банку, точці рівноваги та застосовують раціонування кредитів. У цьому стані кредитного нормування певним сегментам пулу заявників суворо та повністю відмовляють у кредитах, навіть якщо ці незадоволені заявники пропонують виплачувати значно вищі відсотки задля отримання капіталу [3].

Ключовою складовою ефективного встановлення кредитної ставки, сегментування пулу заявників та раціонування кредитів є моделі кредитного скорингу, які являють собою раціональну передумову прийняття управлінських рішень стосовно вищезгаданих банківських механізмів максимізації кредитного доходу [1].

Сучасний стан роздрібного кредитного скорингу характеризується остаточним переходом від якісних евристичних оцінок до об'єктивного математичного моделювання. До епохи Data Science оцінка вартості та ризиковості споживчого кредиту цілковито покладалась на експертну думку кредитних інспекторів, які здебільшого діяли в рамках концепції «5 Cs of Credit»: Характер (Character), Спроможність (Capacity), Капітал (Capital), Забезпечення (Collateral) та Умови (Conditions) [4]. Цей підхід вимагав від кредитних менеджерів робити комплексні соціально-економічні судження щодо надійності заявника, базуючись на власному досвіді та випрацьованих індустрією евристичних. Проте ця суб'єктивна методологія мала суттєві недоліки: вона погано масштабувалась в епоху масового споживання кредитних послуг і була вкрай вразливою до явних і прихованих упереджень, часто дискримінуючи позичаль-

ників на основі якісних або дискримінаційних демографічних ознак, таких як раса, соціальний статус тощо [5].

Щораз більший попит на об'єктивні кредитні рішення, як з боку кредитних установ, так і з боку споживачів, зумовив необхідність переходу до емпіричної класифікації. Попри те, що перші статистичні підходи використовували одновимірний аналіз, вирішальний прорив в індустрії стався в 1968 році завдяки Едварду Альтману та запровадженню Z-оцінки Альтмана (Altman Z-score). Альтман застосував багатовимірний дискримінантний аналіз для об'єднання кількох фінансових змінних в єдиний прогнозний індекс, показавши, що одночасний аналіз багатьох змінних дає значно вищу точність прогнозування, ніж ізольована оцінка окремих метрик [6].

Зі зростанням ринку роздрібного кредитування кредитні установи прийняли та розширили методологію Альтмана для оцінки величезних споживчих кредитних портфелів, встановивши домінування частотних статистичних моделей в кредитному скорингу. Розглядаючи ймовірність як довгострокову частоту спостережуваних подій, частотні моделі ідеально підходили для фінансових даних, що складаються з масивів інформації щодо здійснених кредитних транзакцій, типових для роздрібного банкінгу. Крім того, оскільки роздрібні дані є сильно асиметричними та часто порушують припущення щодо слідування нормальному багатовимірному розподілу, яке необхідно для дискримінантного аналізу, логістична регресія швидко стала чільним алгоритмом у цій сфері. Проектуючи ймовірність дефолту за допомогою функції зв'язку на набір ознак, логістична регресія забезпечила можливість побудови легко інтерпретованої скорингової карти. Цей методологічний перехід дозволив кредиторам ефективно перетворювати комплексні соціоекономічні дані про позичальника на точні, вимірювані математичні ймовірності, необхідні для управління ризиками масового споживчого ринку та виконання вимог міжнародного банківського регулювання [7].

Методологія кредитного скорингу розробляється не лише з огляду на максимізацію прибутку фінансової установи, але й згідно зі строгим, нормативним регулюванням. Задля забезпечення глобальної фінансової стабільності Базельський комітет з банківського нагляду впровадив низку міжнародних регуляторних угод, що окреслюють вимоги забезпечення достатності капіталу та запобігання системному поширенню фінансових шоків. Основний постулат Базельської системи вимагає від банків утримувати мінімальний відсоток регулятивного капіталу як захисний буфер для їхніх ак-

тивів, зважених на ризик (*Risk-Weighted Assets*), для поглинання непередбачуваних збитків. Важливим етапом розвитку міжнародного фінансового нагляду стало запровадження підходу на основі внутрішніх рейтингів (*Internal Ratings-Based approach*) у рамках угоди «Базель II». Замість того, щоб покладатися на жорсткі, стандартизовані регуляторні ваги ризику, визначені зовнішніми агентствами, підхід на основі внутрішніх рейтингів дозволяє кваліфікованим банківським установам використовувати власні емпіричні моделі та гранулярні дані клієнтів для оцінки ключових параметрів ризику. Цей підхід суттєво підвищує чутливість до ризику, гарантуючи, що вимоги до капіталу точно відповідають фактичному математичному ризику, закладеному в портфелі банку, а також є адекватними для локальної ринкової ситуації [8].

У межах цієї системи розрахунок очікуваних і непередбачуваних збитків повністю залежить від трьох основних параметрів ризику – ймовірності дефолту, рівня витрат у разі дефолту та величини кредитної вимоги у випадку ризику. *Ймовірність дефолту* являє собою математично розраховану ймовірність того, що позичальник допустить дефолт протягом одного року. *Рівень витрат у разі дефолту* кількісно визначає величину економічних збитків, які банк понесе у випадку дефолту. *Величина кредитної вимоги* у випадку дефолту являє собою загальний використаний залишок плюс орієнтовну суму невикористаної підтвердженої кредитної лінії, яка опиниться під ризиком у момент настання дефолту [9; 10]. Ці три параметри утворюють рівняння очікуваних збитків (*Expected Loss*), яке визначається як:

$$EL = PD \times LGD \times EAD,$$

де *PD* – Probability of Default; *LGD* – Loss Given Default; *EAD* – Exposure at Default.

Оскільки очікувані збитки є прогнозованими стандартними витратами на ведення бізнесу, вони заздалегідь покриваються за рахунок утворення операційних резервів та ціноутворення.

У контексті кредитного скорингу прогностичні моделі розробляються насамперед для точної оцінки ймовірності дефолту, який, як ми окреслили, є складовим елементом очікуваних збитків – ключового параметра фінансової стійкості кредитної установи. Щоб гарантувати, що процеси навчання та валідації скорингових моделей базуються на стандартизованій емпіричній основі, міжнародні регулятори впроваджують єдине визначення цільової події, себто дефолту, або настання неплатоспроможності позичальника. Для стандартних роздрібних позицій стандартизований

маркер дефолту спрацьовує тоді, коли прострочення зобов'язання досягає 90 днів. Цей жорсткий регуляторний поріг пояснює, чому під час розробки скорингових моделей статус «90DaysPastDue» розглядається як бінарна цільова змінна, що відокремлює «хороших» позичальників від «поганих» і вказує на дефолт [11].

Крім того, у межах фіналізованих реформ «Базель III» (так званого «Базель IV») було посилено вимоги до калібрування та валідації внутрішніх скорингових моделей. Зокрема, регулятори прагнули зменшити надмірну варіативність оцінок ризику між банками, підвищити порівнюваність моделей, посилити консервативність параметрів ризику дефолту та забезпечити більш стабільний зв'язок між прогнозованими ризиками та достатністю капіталу [12].

Коректне конструювання простору ознак моделі є важливим етапом, що фактично відповідає за відображення в операційній аналітиці тих чи інших мікроекономічних постулатів і регуляторних вимог. Набори даних, які використовуються для аналізу роздрібного кредитного ризику, такі як «Give Me Some Credit», являють собою не просто сукупність емпіричних змінних, а структуровані параметри вразливості позичальника, його ліквідності та поведінкової дисципліни.

Змінні, що вимірюють коефіцієнт заборгованості (*debt ratio*) та рівень використання незабезпечених відновлюваних кредитних ліній (*revolving utilization of unsecured lines*), слугують основними математичними індикаторами наближеності позичальника до обмежень ліквідності [13; 14]. Хоча теорія корпоративної структури капіталу часто припускає, що фінансовий важіль не має значення за ідеальних ринкових умов, роздрібні ринки зазнають сильного впливу фінансового тертя та інформаційної асиметрії. Високе значення показника відношення боргу до доходу (*debt-to-income ratio*) вказує на брак буфера наявного доходу для поглинання екзогенних економічних шоків, що фундаментально збільшує ймовірність скорого настання неплатоспроможності позичальника [13]. Крім того, використання відновлювальних кредитів діє як надзвичайно чутливий поведінковий проксі-індикатор наближення фінансових дистресів контрагента в режимі реального часу. Таким чином це засвідчує, що споживач активно заміщує власний дохід боргом, для підтримки базового рівня споживання [14]. Довгострокові емпіричні дослідження демонструють, що для споживачів відновлювальних кредитних продуктів збільшення доступності кредиту на 10% часто призводить до майже симетричного збільшення накопиченого боргу на

9,99%. Це підкреслює значну поведінкову реакцію на встановлені кредитором кредитні ліміти, яку моделі повинні фіксувати для оцінки серйозності ситуації та запобігання підвищеному ризику [15].

Включення демографічних показників, зокрема віку, місячного доходу та кількості утриманців, відображає соціально-економічні реалії, які визначають позицію позичальника на кривій життєвого циклу споживання. Гіпотеза життєвого циклу споживання (*Life-Cycle Hypothesis*) стверджує, що індивіди намагаються згладити своє споживання шляхом активного запозичення в молодості та інтенсивного заощадження в роки пікового заробітку середнього віку [16]. Емпіричні дані цілком узгоджуються з цією теорією, оскільки накопичення споживчого боргу швидко прискорюється у віці від двадцяти до сорока років, після чого значно знижується після п'ятдесяти. Відповідно, вік виступає вирішальним нелінійним модифікатором. Натомість співвідношення між місячним доходом і кількістю утриманців встановлює нижні межі витрат, які передують кредитному дефолту. Велика кількість утриманців у поєднанні з помірним або низьким доходом створює середовище високого ризику, де локалізовані шоки неминуче змушують позичальника допускати дефолт за незабезпеченими кредитами заради виживання сім'ї [17].

Окрім цього, важливим є включення граничних змінних прострочення за кредитними платежами, таких як прострочення від 30 до 59 днів та від 60 до 89 днів. Ці змінні є важливим елементом

моделювання споживчого кредитування за допомогою ланцюгів Маркова. Шлях до нормативно визначеного дефолту рідко буває непередбачуваним, миттєвим переходом від платоспроможності до дефолту. Радше він являє собою поступове, вимірюване погіршення стану через різні стадії прострочення. Аналіз коефіцієнтів переходу кількісно визначає швидкість міграції позичальника з пулу раннього прострочення в більш критичний стан у наступних періодах. Перехід до кошика прострочення від 60 до 89 днів є серйозним випереджувальним індикатором майбутнього дефолту, який демонструє, що позичальник, який не зміг врегулювати свій борг протягом першого місяця, виявляє хронічну, системну фінансову неспроможність, а не тимчасову помилку, яку можна легко усунути.

Аналізуючи точну частоту цих локалізованих вікон прострочення, моделі кредитного скорингу здатні ефективно розрахувати схильність позичальника до термінальної неплатоспроможності, тобто дефолту [18; 19]. Порівняльне теоретико-методологічне обґрунтування необхідності застосування різних груп ознак для коректного моделювання індивідуального кредитного ризику наведено в *табл. 1*.

На макроекономічному рівні створення ефективних кількісних кредитних моделей створює системний компроміс між суспільним запитом на широку фінансову інклюзію та інституційною необхідністю суворого зниження ризиків. Розширення доступу до кредитів широко визнається як жит-

Таблиця 1

Теоретико-методологічне обґрунтування простору ознак моделі кредитного ризику

Група ознак моделі	Приклади емпіричних змінних	Мікроекономічний та поведінковий зміст ознаки	Регуляторний маркер
Показники боргового навантаження	Коефіцієнт боргового навантаження, Рівень використання незабезпечених відновлених кредитних ліній	Індикатори обмеження ліквідності позичальника та проксі-метрики фінансового дистресу в режимі реального часу	Компонент оцінки ймовірності настання дефолту портфеля (Probability of Default – PD)
Соціодемографічні характеристики	Вік позичальника, місячний дохід, кількість утриманців	Відображення позиції індивіда на кривій життєвого циклу споживання та визначення нижньої межі виживання сім'ї	Модифікатор консервативності оцінки параметрів очікуваних збитків (Expected Loss – EL)
Параметри історичної платіжної дисципліни	Кількість випадків прострочення платежів (від 30 до 59 днів, від 60 до 89 днів)	Визначення коефіцієнтів переходу (міграції) позичальника між кошиками ланцюгів Маркова ранньої заборгованості	Прямий випереджувальний індикатор термінального дефолту позичальника (маркер «90DaysPastDue»)

Джерело: складено авторами на основі [13–19].

тево важливий механізм для стимулювання економічного зростання, подолання бідності, сприяння підприємництву та згладжування нерівності у споживанні. Використовуючи ефективні моделі, що працюють на основі даних, банки можуть розширити пул споживачів їх кредитних послуг на демографічні сегменти, які раніше були виключені з ринку споживчого кредитування через суб'єктивні упередження та неефективність евристичної епохи кредитного скорингу. Застосування подібних моделей дозволяє звужити дисперсію очікуваних збитків і дати змогу поступово розширювати фінансову інклюзію на більш вразливі та ризикові straty населення [20].

Однак емпіричні дані, які демонструють окремі економічні дослідження, демонструють негативну кореляцію між необмеженою фінансовою інклюзією та системною фінансовою стабільністю. У міру того, як фінансові установи надають кредити все більш маргінальним позичальникам (особам, які класифікуються як позичальники з високим ризиком через підвищене боргове навантаження, низькі доходи або нестабільне використання відновлюваних кредитів), знижується як рівень фінансової стійкості окремого банку, так і фінансова стабільність усієї системи в цілому [20].

Для підтримки стабільності та збереження банківських ліцензій установи зобов'язані, відповідно до Базельських стандартів нагляду, надавати пріоритет зниженню ризиків над інклюзією. Оскільки нижні межі капіталу «Базель IV» карають портфелі з високою дисперсією та вимагають підвищеного буфера капіталу для проблемних активів, банки нормативно демотивовані кредитувати осіб, які проявляють ризикову поведінку в історичних даних. Як наслідок, хоча кількісні скорингові моделі успішно усувають відверту людську упередженість та емоційні переконання, вони ненавмисно запроваджують нову, математично строгу форму кредитного нормування. Караючи за прострочення платежів і несприятливі демографічні обмеження, прогнозні алгоритми системно виключають споживачів, які за своєю природою зазнають вищої волатильності [21].

Цей феномен створює середовище ненавмисного алгоритмічного виключення. Точні прогнозні ознаки, які використовуються для вирішення проблеми «принципал – агент» (наприклад, коефіцієнти переходу між різними стадіями прострочення), математично відрізають вразливі демографічні групи від формального банківського сектора, часто підштовхуючи їх до тіньового банкінгу. До того ж, хоча інтеграція розширених альтернативних

даних часто пропагується індустрією фінансових технологій як рішення для людей, які не мають доступу до банківських послуг, соціологічні та економічні аналізи свідчать про те, що такі дані часто лише підвищують точність цього виключення. У багатьох випадках це приносить користь апарату управління ризиками кредитної установи, а не гарантує справжню інклюзію для маргіналізованих груп, які за своєю суттю схильні до більш волатильної поведінки [20].

Зіставивши та проаналізувавши теоретичні аспекти мікроекономічного змісту кредитного ризику, регуляторного нагляду та макроекономічного значення впровадження математичного моделювання ризику для фінансової інклюзії, стає можливим накласти їх на найбільш поширені архітектури, що застосовуються в моделюванні роздрібного кредитного ризику. Сучасний технологічний інструментарій банківського ризик-менеджменту може бути класифікований за багатьма різноманітними чинниками, серед яких, зокрема, – параметричність і рівень прозорості алгоритмів прийняття рішень. Традиційним базисним алгоритмом індустрії є класична логістична регресія, яка є параметричною моделлю, що забезпечує лінійну адитивність та пряму інтерпретованість коефіцієнтів, що, своєю чергою, повністю нівелює ризики регуляторних претензій, проте має обмежену предикативну здатність на складноструктурованих масивах даних. Натомість поширення непараметричних методів машинного навчання, зокрема алгоритмів градієнтного бустингу над деревами рішень (*XGBoost*, *LightGBM*), дозволило значно підвищити точність прогнозування дефолтів завдяки автоматичній фіксації нелінійних залежностей та інтерференції ознак [22].

Водночас їхня апіорі непрозорість (*black-box modelling*) створює суттєві перешкоди для відповідності вимогам нормативного комплаєнсу. Компромісним вектором у цьому контексті виступає використання узагальнених адитивних моделей з інтерактивними функціями (GA2M), реалізованих, зокрема, у моделі Explainable Boosting Machines (EBM), які поєднують точність бустингу із прямою візуалізацією внеску кожної окремої ознаки [23]. Концептуальне порівняння зазначених математичних архітектур за критеріями точності та прозорості узагальнено в *табл. 2*.

На основі проведеного аналізу та систематизації компромісів і суперечностей у галузі моделювання кредитного ризику авторами запропоновано комплексну теоретико-методологічну архітектуру для вибору та оцінювання моделей кредитного скорингу. Зазначена концепція інтегрує чотири

Порівняльна характеристика архітектур моделей кредитного скорингу

Критерій порівняння	Логістична регресія	Ансамблеві методи	Моделі з вбудованою пояснюваністю
Характер архітектури	Параметрична, лінійна	Непараметрична, дерево-видна (ітеративний бустинг)	Непараметрична, адитивна нелінійна
Врахування нелінійності ознак	Низьке (вимагає попереднього ручного кодування змінних)	Високе (автоматична фіксація складних нелінійних взаємодій)	Високе (через інтерактивні функції та одновимірні графіки)
Відповідність вимогам GDPR і Basel IV	Висока (пряма інтерпретованість і прозорість коефіцієнтів)	Обмежена (вимагає залучення відокремлених post-hoc наближень, наприклад, SHAP)	Висока (вбудована за дизайном «glass-box» прозорість алгоритму)
Вплив на фінансову інклюзію позичальників	Жорстке лінійне раціонування капіталу	Ризик посилення математично строгого алгоритмічного виключення	Оптимізація балансу між ризиком портфеля та залученням позичальників

Джерело: складено авторами на основі [22–24].

взаємопов'язані виміри, що відображають наскрізний процес трансформації мікроекономічних сигналів у суспільно-економічні результати:

- 1. Мікроекономічний базис.** Вихідна точка моделювання, яка спирається на класичну економічну теорію інформації та концепцію «принципал – агент». На цьому етапі фіксується природа інформаційної асиметрії на кредитному ринку, де банк (принципал) намагається нівелювати ризик несприятливого відбору та морального ризик через ідентифікацію поведінкових сигналів потенційного позичальника (агента).
- 2. Моделювання ризику.** Технологічна проєкція мікроекономічного базису. Вона охоплює процеси конструювання ознак на основі проксі-метрик обмеження ліквідності, історії заборгованості з використанням ланцюгів Маркова та безпосередньої алгоритмічної оцінки ймовірності настання дефолту позичальника. Саме тут здійснюється вибір моделі машинного навчання та підходу до її інтерпретації.
- 3. Регуляторні обмеження.** Інституційний фільтр, який формує вимоги до обраних математичних алгоритмів. Даний вимір визначається стандартами макропруденційного нагляду, правовими нормами захисту даних і нормативами застосування моделей штучного інтелекту. Регуляторний комплаєнс виступає ключовим тригером виникнення методологічного конфлікту, обмежуючи застосування непрозорих моделей «чорної скриньки» в банківському секторі.

- 4. Суспільно-економічні наслідки.** Останній рівень системи, що відображає зворотний макроекономічний ефект від застосування алгоритмів. Жорстке математичне раціонування капіталу комерційними банками визначає кінцевий рівень фінансової інклюзії в державі. У разі надмірного зміщення оптимізаційного фокуса моделі в бік мінімізації ризиків виникає ефект системного алгоритмічного виключення маргіналізованих або вразливих категорій позичальників, що стимулює відтік споживчого попиту в нерегульований сектор тіньового банкінгу.

Запропонована чотиривимірна модель дозволяє фінансовим установам та регуляторам перейти від ізольованої оцінки математичної точності алгоритмів до комплексного управління ризиками в контексті сталого розвитку фінансової системи. Графічне відображення запропонованої концепції наведено на рис. 1.

ВИСНОВКИ

Отже, вище описано здійснене теоретико-методологічне узагальнення сучасних підходів до моделювання кредитного ризику та сформовано інтегровану концептуальну модель вибору архітектури машинного навчання для кредитного скорингу. На відміну від підходів, що розглядають ефективність моделей переважно через призму їхньої прогнозовної здатності, запропонована концепція об'єднує чотири взаємопов'язані виміри: *мікроекономічні передумови виникнення кредитного ризику; математичне моделювання ризику; регуляторні обме-*



Рис. 1. Інтегрована теоретико-методологічна концепція вибору архітектури кредитного скорингу

Джерело: складено авторами.

ження банківської діяльності та суспільно-економічні наслідки використання алгоритмічних моделей. Така інтеграція дозволяє розглядати вибір скорингової моделі як багатокритеріальну задачу, що виходить за межі суто технічної оптимізації прогнозової точності.

Проведений аналіз підтверджує висновки класичної економічної теорії щодо визначальної ролі інформаційної асиметрії та проблеми «принципал – агент» у функціонуванні кредитних ринків, узгоджуючись із роботами J. E. Stiglitz та A. Weiss [3]. Одночасно результати дослідження розширюють сучасні підходи до кредитного скорингу, доповнюючи традиційне порівняння алгоритмів машинного навчання аналізом їх відповідності вимогам банківського регулювання та пояснюваності моделей. На відміну від значної частини сучасних досліджень, які переважно концентруються на підвищенні прогнозової ефективності ансамблевих методів [22; 24], у роботі обґрунтовано доцільність оцінювання моделей у контексті компромісу між прогнозовою точністю, інтерпретованістю, нормативним комплаєнсом і потенційним впливом на фінансову інклюдію.

Практичне значення запропонованої концепції полягає в можливості її використання як методологічної основи під час розроблення, оцінювання та вибору архітектур моделей кредитного скорингу в банківських установах, а також при формуванні підходів до регуляторної оцінки внутрішніх скорингових систем. Запропонований підхід може бути використаний як концептуальний інструмент для збалансування інтер-

есів управління кредитним ризиком, забезпечення нормативної відповідності та підтримки сталого розвитку фінансової інклюдії.

Перспективним напрямом подальших досліджень є емпірична перевірка запропонованої концепції шляхом порівняльного аналізу логістичної регресії, ансамблевих алгоритмів градієнтного бустингу та Explainable Boosting Machine на реальних наборах кредитних даних із використанням сучасних методів оцінювання прогнозової якості, калібрування моделей і засобів їх інтерпретації. ■

БІБЛІОГРАФІЯ

1. Feess E., Schieble M. Credit Scoring and Incentives for Loan Officers in a Principal Agent Model. *Working Paper Series: Finance and Accounting*. No. 30. Department of Finance, Goethe University Frankfurt am Main, 1998. URL: <https://d-nb.info/1180332466/34>
2. Shah S. The Principal-Agent Problem in Finance. *Social Science Research Network*. Rochester, NY, 2014. URL: <https://papers.ssrn.com/abstract=2574742>
3. Stiglitz J. E., Weiss A. Credit Rationing in Markets with Imperfect Information. *The American Economic Review*. 1981. Vol. 71. No. 3. P. 393–410. URL: <https://www.jstor.org/stable/1802787>
4. Baiden J. E. The 5 C's of Credit in the Lending Industry. *SSRN Journal*. 2011. DOI: <https://doi.org/10.2139/ssrn.1872804>
5. Furletti M. J. An Overview and History of Credit Reporting. *SSRN Journal*. 2002. DOI: <https://doi.org/10.2139/ssrn.927487>
6. Altman E. I. A Fifty-Year Retrospective on Credit Risk Models, the Altman Z-Score Family of Models and Their Applications to Financial Markets and Mana-

- gerial Strategies. *Journal of Credit Risk*. 2018. Vol. 14. No. 4. P. 1–34.
DOI: <https://doi.org/10.21314/JCR.2018.243>
7. Frank Y. Credit Scoring as a Credit Risk Management Technique: Introduction. 2025. URL: https://www.academia.edu/7490103/Credit_Scoring_as_a_Credit_Risk_Management_Technique_Introduction
8. Altman E. I. Revisiting Credit Scoring Models in a Basel 2 Environment. *NYU Working Paper*. No. S-FI-02-11. 2002. URL: <https://ssrn.com/abstract=1298829>
9. Basel Committee on Banking Supervision. An Explanatory Note on the Basel II IRB Risk Weight Functions. 2005. URL: <https://www.bis.org/bcbs/irbriskweight.pdf>
10. Basel II: International Convergence of Capital Measurement and Capital Standards: A Revised Framework – Comprehensive Version. 2006. URL: <https://www.bis.org/publ/bcbs128.htm>
11. Basel Calculation of RWA for Credit Risk 36.68. URL: https://www.bis.org/basel_framework/chapter/CRE/36.htm
12. KPMG China. Basel IV Update: SA and IRB. KPMG Insights, 2024. URL: <https://kpmg.com/cn/en/insights/2024/03/basel-iv-update-sa-and-irb.html>
13. Ajike P. O. Assessing the Impact of Debt Ratio Variability on Corporate Solvency, Credit Risk Exposure, and Investment Decision-Making Efficiency. *International Journal of Advance Research Publication and Reviews*. 2025. Vol. 2. Iss. 10. P. 424–439.
DOI: <https://doi.org/10.55248/gengpi.6.1025.3669>
14. Amberg N., Jacobson T., Quadrini V., Picco A. R. Dynamic Credit Constraints: Theory and Evidence from Credit Lines. *Sveriges Riksbank Working Paper Series*. No. 422. 2023. URL: <https://www.ecb.europa.eu/pub/pdf/scpwps/ecb.wp3216~87bce3b9cf.en.pdf>
15. Fulford S., Schuh S. Consumer Revolving Credit and Debt over the Life Cycle and Business Cycle. Federal Reserve Bank of Boston. *Research Department Working Papers*. 2015. No. 15–17. URL: <https://www.bostonfed.org/publications/research-department-working-paper/2015/consumer-revolving-credit-and-debt-over-the-life-cycle-and-business-cycle.aspx>
16. Gourinchas P.-O., Parker J. A. Consumption Over the Life Cycle. *Econometrica*. 2002. Vol. 70. Iss. 1. P. 47–89.
DOI: <https://doi.org/10.1111/1468-0262.00269>
17. Coulson A., Review of «The Two-Income Trap: Why Middle-Class Mothers and Fathers are Going Broke». *Financial Counseling and Planning*. 2003. Vol. 14. Iss. 2. URL: <https://www.afcpe.org/news-and-publications/journal-of-financial-counseling-and-planning/volume-14-2/book-reivews-of-the-two-income-trap-why-middle-class-mothers-and-fathers-are-going-broke/>
18. Blackburn B. How to Pinpoint What Drives Early-Stage Delinquency Roll Rate. *dotData*. August 14, 2025. URL: <https://dotdata.com/blog/early-stage-delinquency-roll-rate-in-subprime-lending/>
19. Bhalla D. Roll Rate Analysis. *Listen Data*. 2019. URL: <https://www.listendata.com/2019/09/roll-rate-analysis.html>
20. Čihák M., Mare D. S., Melecký M. Financial Inclusion and Stability: Review of Theoretical and Empirical Links. *The World Bank Research Observer*. 2021. Vol. 36. Iss. 2. P. 197–233.
DOI: <https://doi.org/10.1093/wbro/lkaa006>
21. Mehrotra A., Yetman J. Financial Inclusion – Issues for Central Banks. *BIS*. 2015. URL: https://www.bis.org/publ/qtrpdf/r_qt1503h.htm
22. Bello O. A. Machine Learning Algorithms for Credit Risk Assessment: An Economic and Financial Analysis. *International Journal of Management Technology*. 2023. Vol. 10. Iss. 1. URL: <https://eajournals.org/ijmt/vol10-issue-1-2023/machine-learning-algorithms-for-credit-risk-assessment-an-economic-and-financial-analysis/>
23. Bussmann N., Giudici P., Marinelli D., Papenbrock J. Explainable Machine Learning in Credit Risk Management. *Computational Economics*. 2021. Vol. 57. Iss. 1. P. 203–216.
DOI: <https://doi.org/10.1007/s10614-020-10042-0>
24. Montevechi A. A., de Carvalho Miranda R., Medeiros A. L., Montevechi J. A. B. Advancing Credit Risk Modelling with Machine Learning: A Comprehensive Review of the State-of-the-Art. *Engineering Applications of Artificial Intelligence*. 2024. Vol. 137. Part A. Art. 109082.
DOI: <https://doi.org/10.1016/j.engappai.2024.109082>

REFERENCES

- Ajike P. O. (2025). Assessing the Impact of Debt Ratio Variability on Corporate Solvency, Credit Risk Exposure, and Investment Decision-Making Efficiency. *International Journal of Advance Research Publication and Reviews*, 10(2), 424–439.
<https://doi.org/10.55248/gengpi.6.1025.3669>
- Altman E. I. (2002). Revisiting Credit Scoring Models in a Basel 2 Environment. *NYU Working Paper*. <https://ssrn.com/abstract=1298829>
- Altman E. I. (2018). A Fifty-Year Retrospective on Credit Risk Models, the Altman Z-Score Family of Models and Their Applications to Financial Markets and Managerial Strategies. *Journal of Credit Risk*, 4(14), 1–34.
<https://doi.org/10.21314/JCR.2018.243>
- Amberg N., Jacobson T., Quadrini V. & Picco A. R. (2023). Dynamic Credit Constraints: Theory and Evidence from Credit Lines. *Sveriges Riksbank Working Paper Series*. <https://www.ecb.europa.eu/pub/pdf/scpwps/ecb.wp3216~87bce3b9cf.en.pdf>
- Baiden J. E. (2011). The 5 C's of Credit in the Lending Industry. *SSRN Journal*.
<https://doi.org/10.2139/ssrn.1872804>
- Basel Committee on Banking Supervision. (2005). *An Explanatory Note on the Basel II IRB Risk Weight Functions*. <https://www.bis.org/bcbs/irbriskweight.pdf>
- Bello O. A. (2023). Machine Learning Algorithms for Credit Risk Assessment: An Economic and Financial Analysis.

- International Journal of Management Technology*, 1(10). <https://eajournals.org/ijmt/vol10-issue-1-2023/machine-learning-algorithms-for-credit-risk-assessment-an-economic-and-financial-analysis/>
- Bhalla D. (2019). Roll Rate Analysis. *Listen Data*. <https://www.listendata.com/2019/09/roll-rate-analysis.html>
- bis.org. (2006). *Basel II: International Convergence of Capital Measurement and Capital Standards: A Revised Framework – Comprehensive Version*. <https://www.bis.org/publ/bcbs128.htm>
- bis.org. *Basel Calculation of RWA for Credit Risk* 36.68. https://www.bis.org/basel_framework/chapter/CRE/36.htm
- Blackburn B. (2025). How to Pinpoint What Drives Early-Stage Delinquency Roll Rate. *dotData*. <https://dotdata.com/blog/early-stage-delinquency-roll-rate-in-sub-prime-lending/>
- Bussmann N., Giudici P., Marinelli D. & Papenbrock J. (2021). Explainable Machine Learning in Credit Risk Management. *Computational Economics*, 1(57), 203–216. <https://doi.org/10.1007/s10614-020-10042-0>
- Coulson A. (2003). Review of «The Two-Income Trap: Why Middle-Class Mothers and Fathers are Going Broke». *Financial Counseling and Planning*, 2(14). <https://www.afcpe.org/news-and-publications/journal-of-financial-counseling-and-planning/volume-14-2/book-reviews-of-the-two-income-trap-why-middle-class-mothers-and-fathers-are-going-broke/>
- Feess E. & Schieble M. (1998). Credit Scoring and Incentives for Loan Officers in a Principal Agent Model. *Department of Finance, Goethe University Frankfurt am Main*. <https://d-nb.info/1180332466/34>
- Frank Y. (2025). *Credit Scoring as a Credit Risk Management Technique: Introduction*. https://www.academia.edu/7490103/Credit_Scoring_as_a_Credit_Risk_Management_Technique_Introduction
- Fulford S. & Schuh S. (2015). Consumer Revolving Credit and Debt over the Life Cycle and Business Cycle. Federal Reserve Bank of Boston. *Research Department Working Papers*. <https://www.bostonfed.org/publications/research-department-working-paper/2015/consumer-revolving-credit-and-debt-over-the-life-cycle-and-business-cycle.aspx>
- Furletti M. J. (2002). An Overview and History of Credit Reporting. *SSRN Journal*. <https://doi.org/10.2139/ssrn.927487>
- Gourinchas P.-O. & Parker J. A. (2002). Consumption Over the Life Cycle. *Econometrica*, 1(70), 47–89. <https://doi.org/10.1111/1468-0262.00269>
- Čihák M., Mare D. S. & Melecký M. (2021). Financial Inclusion and Stability: Review of Theoretical and Empirical Links. *The World Bank Research Observer*, 2(36), 197–233. <https://doi.org/10.1093/wbro/lkaa006>
- KPMG China. (2024). Basel IV Update: SA and IRB. *KPMG Insights*. <https://kpmg.com/cn/en/insights/2024/03/basel-iv-update-sa-and-irb.html>
- Mehrotra A. & Yetman J. (2015). Financial Inclusion – Issues for Central Banks. *BIS*. https://www.bis.org/publ/qtrpdf/r_qt1503h.htm
- Montevecchi A. A., de Carvalho Miranda R., Medeiros A. L. & Montevecchi J. A. B. (2024). Advancing Credit Risk Modeling with Machine Learning: A Comprehensive Review of the State-of-the-Art. *Engineering Applications of Artificial Intelligence*, 137. <https://doi.org/10.1016/j.engappai.2024.109082>
- Shah S. (2014). *The Principal-Agent Problem in Finance*. Rochester, NY. <https://papers.ssrn.com/abstract=2574742>
- Stiglitz J. E. & Weiss A. (1981). Credit Rationing in Markets with Imperfect Information. *The American Economic Review*, 3(71), 393–410. <https://www.jstor.org/stable/1802787>

Дослідження не отримувало зовнішнього фінансування.

Автори заявляють про відсутність конфлікту інтересів.

Під час підготовки роботи автори використали Gemini з метою коректури та редагування тексту. Автори перевірили та відредагували отримані матеріали.

Стаття надійшла до редакції / Received: 03.07.2026
Статтю прийнято до публікації / Accepted: 17.07.2026
Оприлюднено / Published: 18.08.2026