

Касьянова Н.В.

доктор економічних наук, професор,
завідувач кафедри бізнес-аналітики та цифрової економіки
Державного некомерційного підприємства
«Державний університет «Київський авіаційний інститут»

Кушнірова К.С.

магістр
Державного некомерційного підприємства
«Державний університет «Київський авіаційний інститут»

Kasianova Nataliia, Kushnirova Kateryna

State Non-Commercial Company
"State University "Kyiv Aviation Institute"

МОДЕЛЮВАННЯ КРЕДИТНОГО СКОРИНГУ МЕТОДАМИ ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ ДАНИХ

MODELING CREDIT SCORING USING DATA MINING METHODS

У роботі обґрунтовано методичний підхід до вдосконалення системи кредитного скорингу фізичних осіб на основі методів інтелектуального аналізу даних для підвищення ефективності управління кредитними ризиками банку. Проаналізовано базу даних позичальників для визначення ключових факторів, що впливають на кредитний ризик: якісні характеристики клієнтів, фінансові параметри кредиту та зовнішні чинники. Використання кластеризації дозволило виявити значну диференціацію в кредитній поведінці різних груп клієнтів банку. Для підвищення точності прогнозування кредитоспроможності було розроблено нейронну мережу на основі багатoshарового перцептрону. Модель показала високу ефективність у виявленні надійних позичальників. Обґрунтовано доцільність комбінованого підходу: застосування логістичної регресії та кластерного аналізу для попереднього відбору клієнтів з подальшим використанням нейронної мережі для ухвалення остаточного рішення у складних випадках.

Ключові слова: кредитоспроможність фізичних осіб, скорингова модель, великі дані, дискримінантний аналіз, кластеризація, нейронна мережа, прогнозування кредитоспроможності.

The paper substantiates a methodological approach to improving the credit scoring system for individuals based on data mining methods. A classification of the main types of scoring models is provided, and the conditions for their application for assessing the borrower's creditworthiness are determined. The authors paid great attention to the formation of a list of characteristics-indicators that make it possible to assess the borrower. The feasibility of using both quantitative characteristics that reveal the client's financial capabilities and qualitative ones that relate to demographic and social factors is proven. The methods of constructing scoring models were analyzed, from classical ones – logistic regression, decision tree and cluster analysis, which are the basic algorithms of intelligent data analysis, to machine learning and building neural network models, which allow obtaining a more holistic picture of the financial behavior of a potential client. The paper analyzes a database of borrowers to identify key factors affecting credit risk. The use of clustering allowed us to identify significant differentiation of credit behavior of different groups of bank clients. To improve the accuracy of creditworthiness forecasting, a neural network based on a multilayer perceptron was developed. The network architecture includes a hidden layer, for the formation of which the hyperbolic tangent function was used. The output layer was constructed using a sigmoid activation function, which provides an estimate of the probability of a borrower belonging to creditworthiness classes. The model showed high efficiency in identifying reliable borrowers, but requires optimization for better prediction of defaults due to the imbalance of training data. The proposed scoring model contributes to reducing the level of problem loans, reducing operating costs for processing applications, and improving customer segmentation. The feasibility of a combined approach is substantiated: the use of logistic regression and cluster analysis for preliminary selection of clients with the subsequent use of a neural network to make final decisions in complex cases.

Keywords: creditworthiness of individuals, scoring model, big data, discriminant analysis, clustering, neural network, creditworthiness forecasting.

Постановка проблеми. Розвиток банківського сектору України супроводжується активним зростанням обсягів кредитування та відповідним підвищенням рівня кредитних ризиків. В Україні спостерігалась позитивна тенденція до зниження частки непрацюючих кредитів з максимальних 54 % у 2018 році до 38 % у 2022 році. За даними Національного банку України, рівень проблемних кредитів у вітчизняних банках досягав у 2023 році 37,25 % [1], що в десятки разів перевищує показники розвинених країн. Військові дії на території України збільшили ризик кредитної діяльності банків. В зв'язку з цим, вітчизняні банки потребують впровадження сучасних технологій аналізу даних для підвищення якості кредитних рішень.

Швидка цифрова трансформація фінансового сектору висуває нові вимоги до процесу оцінки кредитоспроможності. Традиційні методи все частіше виявляються недостатніми для забезпечення точної та оперативної оцінки ризиків. Дослідження рівня непрацюючих кредитів у провідних економіках, таких як США, Франція та Японія, свідчать про значну ефективність скорингових систем у мінімізації кредитних ризиків. Багаторічний досвід застосування скорингу та передових технологій дозволив цим країнам утримувати рівень проблемних кредитів на стабільно низькому рівні (1–3 %). Впровадження кредитного скорингу на основі методів інтелектуального аналізу даних стає критично важливим для забезпечення конкурентоспроможності банківських установ та ефективного управління кредитними ризиками. Таким чином, актуальність теми дослідження обумовлена гострою необхідністю розробки більш ефективних підходів до оцінки кредитних ризиків.

Аналіз останніх досліджень і публікацій. Теоретичною основою дослідження стали фундаментальні праці провідних вітчизняних та зарубіжних вчених у сфері кредитного скорингу та управління банківськими ризиками. Значний внесок у розвиток теорії кредитного скорингу зробили Д. Дюран [2], який заклали основи сучасного скорингу, Е. Альтман [3], що розробив перші математичні моделі оцінки кредитоспроможності, Р. Тафлер та Г. Тішоу [4], які вдосконалили методологію скорингового аналізу. Е. Хауарі [5] розглянув можливості застосування штучного інтелекту для побудови скорингової моделі.

Серед українських науковців вагомий внесок у дослідження проблематики кредитного скорингу зробили: В. Вітлінський, який розробив теоретико-методологічні засади оцінки банківських ризиків [6]; О. Васюренко, що досліджував особливості впровадження скорингових

моделей у вітчизняних банках [7]; А. Мороз, який обґрунтував специфіку застосування міжнародного досвіду в українських умовах [8]; С. Смерічевський розглянув питання кредитного рейтингу компаній за допомогою нейронних мереж [9], Л. Примостка, яка розвинула теорію управління банківськими ризиками [10].

В той же час, методи інтелектуального аналізу даних, у тому числі машинного навчання, щодо побудови скорингових моделей для оцінки кредитоспроможності фізичних осіб досі не знайшли широкого розповсюдження як у науковій літературі, так і у практичній діяльності комерційних банків.

Метою дослідження є розробка та обґрунтування методичних підходів до вдосконалення системи кредитного скорингу фізичних осіб на основі методів інтелектуального аналізу даних для підвищення ефективності управління кредитними ризиками банку.

Виклад основного матеріалу дослідження. Кредитний скоринг – це інструмент кількісної оцінки кредитоспроможності, що базується на статистичному аналізі великих обсягів даних. Використовуючи кредитну історію та соціально-демографічні характеристики, скоринг дозволяє прогнозувати ймовірність дефолту. Історично доведено, що певні соціальні фактори корелюють з фінансовою відповідальністю позичальників.

Впровадження скорингу принесло значні переваги для фінансового сектору. Автоматизація дозволила значно збільшити обсяги обробки кредитних заяв, зменшивши при цьому потребу в ручній праці. Швидкість прийняття рішень стала вирішальним фактором конкурентоспроможності, особливо в сегменті споживчого кредитування. Крім того, стандартизація процедур оцінки забезпечила більшу об'єктивність та прозорість, знизивши вплив суб'єктивних факторів.

Однак, існуючі скорингові моделі мають певні обмеження. Кількість параметрів, що використовуються в таких моделях, часто є недостатньою для адекватної оцінки кредитного ризику. У типовій скоринговій моделі використовується різна кількість параметрів: по 13 параметрів для споживчого кредитування та отримання іпотеки, 25 для автокредитування [11]. На наш погляд, для повної та ефективної оцінки кредитоспроможності позичальника такої кількості чинників впливу може бути замало.

Для підвищення точності прогнозів необхідно розробляти більш складні моделі, що враховують більшу кількість факторів та використовують сучасні методи аналізу даних. Крім того, скорингові системи потребують регулярного оновлення для адаптації до змін ринкових умов. Рішення цих проблем можливо за

використанням сучасних методів інтелектуального аналізу даних, таких як кластерний аналіз, дерева рішень та нейромережі [12].

Відповідно до цілей, які ставить перед собою банк, виділяються різні типи скорингу (табл. 1).

В залежності від типу скорингу використовуються різні набори характеристик-показників позичальника. В основу повинно бути покладено перелік кількісних показників, які відповідають Постанові НБУ № 23 від 25.01.2012 р. «Положення про порядок формування та використання банками України резервів для відшкодування можливих втрат за активними банківськими операціями»:

- сукупний чистий дохід (періодичні сукупні доходи, які зменшено на сукупні витрати та зобов'язання, крім зобов'язань перед банком);
- накопичення клієнта на рахунках банку (за бажанням позичальника);
- фінансові показники, що характеризують поточну платоспроможність позичальника та його фінансові можливості виконати зобов'язання за кредитом. Оптимальні значення та кількість цих коефіцієнтів банк установлює самостійно [13].

Серед якісних критеріїв оцінки позивальника Національний банк пропонує наступні:

- загальний матеріальний стан клієнта (наявність у власності майна, крім майна, переданого в заставу);

- соціальна стабільність клієнта (наявність постійної роботи, ділова репутація, сімейний стан тощо);

- вік позичальника.

Спираючись на досвід банківської системи, можна бачити, що разом із розвитком споживчого кредитування, зростає кількість невиконаних та шахрайств. Дивлячись на зручність та ефективність застосування скорингу для оцінки кредитоспроможності позичальника, зростає необхідність розвитку скорингової моделі за рахунок більш широкого використання саме якісних характеристик. Зазвичай інформація про клієнтів, які подали заявку на кредит, містить у собі опис їхніх демографічних характеристик, фінансових показників, даних про нерухомість та інші відповідні змінні.

Методи побудови скорингових моделей постійно розвиваються. Так до класичних методів включають логістичну регресію, дерева рішень та Random Forest, які є базовими алгоритмами інтелектуального аналізу даних. Найбільш поширеними методами при створенні скорингових моделей є: дерева рішень, логістична регресія та кластерний аналіз (табл. 2).

Аналізуючи великі дані, моделі кредитного скорингу побудовані на основі машинного навчання дозволяють отримати більш цілісну картину фінансової поведінки потенційного клієнта, показуючи аспекти, які традиційні методи

Таблиця 1

Загальні характеристики різних типів скорингу

Тип скорингу	Характеристика
Скоринг заявок на кредит (application scoring)	оцінка кредитоспроможності клієнта-позичальника для отримання кредиту
Скоринг стягнення (collection scoring)	визначення найбільш пріоритетних дій у роботі з позичальниками, які допустили прострочення погашення боргу або повністю припинили виплати
Скоринг поведінки (behavioral scoring)	оцінка динаміки стану кредитного рахунку клієнта шляхом використання ймовірнісних моделей, які дозволяють прогнозувати зміни платоспроможності позичальника та визначати оптимальні ліміти кредитування тощо
Аплікаційний скоринг (application scoring)	оцінка кредитоспроможності потенційного позичальника до початку кредитних відносин на основі інформації, яку отримано з бази даних кредитних справ у цілому по системі
Передпродажний скоринг (pre-sale scoring)	виявлення потенційних потреб клієнта на основі кредитних історій позичальників аналогічної категорії та створення різноманітних пропозицій, які можуть бути цікаві клієнту
Скоринг відгуку (response scoring)	оцінки ймовірності відгуку на пропозиції, що робить банк клієнту в межах передпродажного скорингу
Скоринг утримання (attrition scoring)	оцінка ймовірності розриву відносин між клієнтом та банком, що дає можливість заздалегідь застосувати заходи для підвищення лояльності клієнта
Скоринг шахрайства (fraud scoring)	оцінка ймовірності шахрайства з боку потенційного позичальника, застосовується разом з аплікаційним та поведінковим скорингами для більш детального аналізу клієнта.

Джерело: розроблено авторами на основі [8–10]

Таблиця 2

Методи побудови моделі кредитного скорингу

Метод	Переваги	Обмеження	Точність прогнозування
Дерева рішень	Прозорість, інтерпретованість	Можливе перенавчання	75–85%
Логістична регресія	Простота, надійність	Лінійність зв'язків	70–80%
Кластерний аналіз	Гнучкість, сегментація	Складність валідації	85–90%
Нейронні мережі	Гнучкість, нелінійність зв'язків, можливість використання великих масивів якісних даних	Складність валідації	90–95%

Джерело: розроблено авторами на основі [14]

можуть упустити. Такі моделі допомагають усунути упередження щодо віку, статі, професії, статусу зайнятості чи певних етичних переконань позичальника. До більш сучасних методів відносять: нейронні мережі, Gradient Boosting та Deep Learning, які забезпечують більш високу точність прогнозування та дають можливість обробки великих обсягів інформації. Нейронні мережі демонструють високу точність у прогнозуванні кредитних ризиків, досягаючи показників 90–95%. Особливо ефективними вони виявилися при аналізі масивів даних, які крім традиційних фінансових показників включають й поведінкові патерни клієнтів, дані, отримані з соціальних мереж та інших неформальних джерел інформації.

Для побудови скорингової моделі було застосовано програмне забезпечення IBM SPSS Statistics через його потужні можливості статистичного аналізу та зручність використання. На основі факторного аналізу було виявлено приховані фактори, які впливають на кредитоспроможність позичальника. Даний метод дозволяє зменшити кількість змінних, виявляючи латентні структури в даних. Було виділено три групи факторів:

1) часові характеристики: вік позичальника ($days_birth = -0.966$), дата публікації ($publication_timestamp = 0.968$), дата реєстрації ($registration_timestamp = 0.968$), тривалість працевлаштування ($days_employed = -0.967$);

2) фінансові аспекти кредиту: розмір платежу ($annuity_paymentm = 0.922$), тіло кредиту ($loan_body = 0.965$), вартість товару ($goods_price = 0.935$) та дохід позичальника ($income = 0.576$);

3) зовнішні фактори: зовнішні ($external_source_2 = 0.758$) та регіональні ($population_relative_region = 0.881$) характеристики.

Результати дискримінантного аналізу надають додаткову інформацію про важливість різних змінних у розрізненні груп позичальників. Отримано одну дискримінантну функцію з власним значенням 0,051. Хоча це значення

є досить низьким, але воно пояснює 100 % дисперсії між групами факторів. Канонічна кореляція становить 0,221, що вказує на помірний зв'язок між дискримінантними змінними та групами факторів. Стандартизовані канонічні коефіцієнти дискримінантної функції свідчать про те, що розмір кредиту, тривалість працевлаштування, вартість товару та вік позичальника є ключовими факторами для розрізнення груп позичальників. Змінні *publication_timestamp* та *mobile_contact_flag* не пройшли тест на толерантність та були виключені з подальшого аналізу. Значення тесту Box's M становить 184,632, що вказує на необхідність обережної інтерпретації результатів дискримінантного аналізу та необхідність використання альтернативних методів класифікації.

В зв'язку з цим, було застосовано метод k-means як найбільш ефективний інструмент кластеризації позичальників [15], що дозволило банку формалізувати структуру клієнтської бази та виявити приховані закономірності, які можна використати для управління ефективністю кредитних операцій. Для визначення кількості кластерів в роботі було застосовано низку кількісних критеріїв для оцінки якості кластеризації: індекс силуету (Silhouette index), індекс Девіса-Болдіна (Davies-Bouldin index) та коефіцієнт Калінські-Харабаша (Calinski-Harabasz coefficient). Розрахунки цих показників для різної кількості кластерів (від 2 до 6) показали, що оптимальним є розбиття клієнтської бази на 3 кластери. Ця кількість забезпечує найкращу збалансованість між якістю кластеризації та можливістю інтерпретації отриманих сегментів (табл. 3).

Отримані результати свідчать про наявність суттєвої диференціації в кредитній поведінці трьох груп клієнтів банку. Статистично значущі відмінності між кластерами за ключовими показниками, які підтверджені результатами дисперсійного аналізу, закладають основу для формування диференційованих підходів до оцінки ризиків, обґрунтування кредитних пропозицій та управління проблемною заборгованістю.

Таблиця 3

Результати кластеризації

Характеристики-показники	Кластери		
	«Консервативні позичальники»	«Преміум позичальники»	«Середній сегмент»
Розмір кластеру	196 клієнтів 56,8 % вибірки	42 клієнти 12,2 % вибірки	107 клієнтів 31 % вибірки
Сума кредиту (<i>loan_body</i>), грн	38535	104144	75530
Вартість товарів (<i>goods_price</i>), грн	30454	135714	76355
Щомісячні платежі (<i>annuity_payment</i>), грн	5780,3	15621,6	11329,5
Інформація для формування стратегії кредитування	Стабільна кредитна поведінка, обережний підхід при запозиченні коштів	Найвищий рівень кредитного ризику, можливі труднощі з обслуговуванням боргу	Стандартний кредитний продукт, типова стратегія управління ризиками

Джерело: розроблено авторами за результатами моделювання у IBM SPSS Statistics

Використання побідної кластеризації потенційних позичальників дозволить підвищити ефективність кредитних операцій банку.

З метою поглибленого аналізу кредитного ризику було побудовано нейронну мережу на основі багат шарового перцептронну. Модель включає шість вхідних параметрів, що характеризують фінансовий та соціальний стан позичальника: дохід (*income*), сума кредиту (*loan_body*), щомісячний платіж (*annuity_payment*), вік (*years_old*), стаж роботи (*years_employed*) та розмір родини (*family_memebers_coast*). Всі вхідні змінні пройшли процедуру нормалізації та стандартизації для забезпечення коректної роботи моделі.

Архітектура мережі включає прихований шар з нейронів штучного характеру та вихідного шару, який характеризує два можливі варіанти завершення кредитного процесу: повернення позики та дефолт позичальника. Для побудови прихованого шару обрано гіперболічний тангенс у якості функції активації, що дає можливість виявляти нелінійні залежності в даних. Вихідний шар побудовано за допомогою сигмоїдної функції активації, яка забезпечує оцінку ймовірності належності позичальника до класів «дефолт» або «без дефолту». Навчання скорингової моделі проводилося на вибірці з 235 спостережень (68,1% початкового датасету), а тестування відбувалось на 110 спостереженнях, що склало 31,9% початкової вибірки.

Результати побудови нейронної мережі показали високу точність моделі: 91,5% для навчальної вибірки та 84,5% для тестової. Крім того, модель демонструє відмінні результати у визначенні надійних позичальників (100% точність), але є певні обмеження щодо прогнозування

потенційних дефолтів. Це на наш погляд, пов'язано з незбалансованістю класів у навчальних даних (кількість кредитоспроможних позичальників значно перевищує кількість дефолтів) та потребує додаткового налаштування моделі для підвищення чутливості до випадків дефолту.

Таким чином, для практичного використання доцільно застосовувати комбінований підхід: логістична регресія для попереднього скринінгу та використання нейронної мережі для остаточного прийняття рішень у складних випадках. Результати дослідження підтверджують ефективність використання такого симбіозу моделей для оцінки кредитного ризику та вказують на перспективність подальшого вдосконалення скорингової моделі шляхом розширення набору вхідних параметрів та оптимізації архітектури нейронної мережі.

Впровадження скорингової моделі в діяльність банку дозволить отримати наступні результати:

- зниження рівня проблемних кредитів в середньому на 15–20%;
- скорочення операційних витрат на обробку кредитних заявок на 25–30%;
- підвищення ефективності крос-продажів та покращення відносин з клієнтами за рахунок більш точної сегментації та застосування індивідуального підходу до кожного сегменту.

Таким чином, результати підтверджують доцільність застосування методів машинного навчання для побудови скорингової моделі для прогнозування кредитоспроможності фізичних осіб.

Висновки з проведеного дослідження. Результати дослідження з оптимізації кредитного скорингу за допомогою методів аналізу даних виявили як потенціал, так і обмеження використаних підходів. Факторний аналіз успішно виявив ключові латентні фактори, що

впливають на кредитоспроможність позичальників. Однак, результати дискримінантного аналізу вказують на необхідність використання більш складних підходів до класифікації позичальників. Використання методів машинного навчання дозволило побудувати більш точну скорингову модель, яка дозволяє суттєво оптимізувати процеси управління кредитними ризиками та підвищити якість кредитного портфеля банку в цілому.

Отримані результати відкривають шлях для подальших досліджень:

1. Інтеграцію альтернативних джерел даних, таких як соціальні медіа або поведінкові дані, для розширення набору предикторів оцінки кредитоспроможності.

2. Дослідження динамічних моделей скорингу, які можуть адаптуватися до змін у економічному середовищі та поведінці позичальників.

3. Застосування передових методів машинного навчання, таких як ансамблеві методи або нейронні мережі, для покращення точності класифікації та розробки стратегій кредитування клієнтів різні x кластерів.

Оптимізація кредитного скорингу залишається критично важливим завданням для фінансових установ. Продовження досліджень у цьому напрямку має потенціал значно покращити процеси прийняття рішень у кредитуванні, зменшуючи ризики для фінансових установ та розширюючи доступ до кредитів для надійних позичальників.

Список використаних джерел:

1. Наглядова статистика. Національний банк України. URL: <https://bank.gov.ua/ua/statistic/supervision-statist#1> (дата звернення: 03.12.2024).
2. Durand D. Risk Elements in Consumer Installment Financing. Technical Report. New York: National Bureau of Economic Research, 1941. 128 p.
3. Altman E.I., Saunders A. Credit risk measurement: Developments over the last 20 years. *Journal of Banking & Finance*. 1997. URL: <https://www.tandfonline.com/doi/epdf/10.1080/030851499000000013> (дата звернення: 15.11.2024).
4. Taffler R., Tisshaw H. Going, Going, Gone – Four Factors Which Predict. *Accountancy*. 1977. Vol. 88. No. 1003. P. 50–54.
5. Ayoub El Qadi El Haouari. An EXplainable Artificial Intelligence Credit Rating System. Artificial Intelligence. Sorbonne Université, 2023. URL: <https://theses.hal.science/tel-04472510v1> (дата звернення: 21.11.2024).
6. Вітлінський В.В., Пернарівський О.В. Кредитний ризик комерційного банку: монографія. Київ : Знання, 2000. 251 с.
7. Васюренко О.В. Банківські операції. Київ : Знання, 2008. 318 с.
8. Мороз А.М. Банківські операції: підручник. Київ : КНЕУ, 2002. 476 с.
9. Смерічевський С.Ф., Касьянова Н.В., Глушаченко С.С. Маркетингові дослідження кредитного рейтингу на основі штучної нейронної мережі. *Маркетинг і цифрові технології*. 2017. № 1 (2). С. 32–40. URL: <https://www.mdt-opu.com.ua/index.php/mdt/article/view/14> (дата звернення: 21.11.2024).
10. Примостка Л.О. Фінансовий менеджмент у банку: підручник. Київ : КНЕУ, 2012. 338 с.
11. Задорожна Р.П. Використання нейронних мереж для прогнозування надійності комерційних банків. *Економіка та суспільство*. 2021. № 27. URL: <https://economyandsociety.in.ua/index.php/journal/article/view/446/428> (дата звернення: 24.11.2024).
12. Bello O.A. Machine Learning Algorithms for Credit Risk Assessment: An Economic and Financial Analysis. *International Journal of Management Technology*. 2023. № 10(1). С. 109–133. URL: <https://eajournals.org/ijmt/wp-content/uploads/sites/69/2024/06/Machine-Learning-Algorithms.pdf> (дата звернення: 24.11.2024).
13. Постанова НБУ «Про затвердження Положення про визначення банками України розміру кредитного ризику за активними банківськими операціями» від 30.06.2016 № 351. URL: https://bank.gov.ua/ua/legislation/Resolution_30062016_351 (дата звернення: 05.12.2024).
14. Zhang X., Yu L. Consumer credit risk assessment: A review from the state-of-the-art classification algorithms, data traits, and learning methods. *Expert Systems with Applications*. 2024. № 37(A). DOI: <https://doi.org/10.1016/j.eswa.2023.121484> (дата звернення: 07.12.2024).
15. Hjelkrem L., Lange P. Explaining Deep Learning Models for Credit Scoring with SHAP: A Case Study Using Open Banking Data. *Risk Management Journal*. 2023. № 6(4). DOI: <https://doi.org/10.3390/jrfm16040221> (дата звернення: 05.12.2024).
16. Johnson O. Automated Credit Scoring: Leveraging Machine Learning for Financial Inclusion. *International Journal of Interdisciplinary Finance Insights*. 2024. № 3(3). URL: <https://injm.com/index.php/ijifi/article/view/109> (дата звернення: 07.12.2024).
17. Mestiri S. Credit scoring using machine learning and deep Learning-Based models. *Data Science in Finance and Economics*. 2024. № 4(2). С. 236–248. DOI: <https://doi.org/10.3934/DSFE.2024009> (дата звернення: 07.12.2024).

18. Marwa H., Salah A., Zied M., Zied J. A Machine Learning Model for Accurate Credit Risk Forecasting in Banking Systems: An Empirical Investigation. *International Journal of Supply & Operations Management*, 2024. № 11(2). P. 168–187. DOI: <https://doi.org/10.22034/IJSOM.2023.109898.2722> (дата звернення: 07.12.2024).

References:

1. Nahliadova statystyka. Natsionalnyi bank Ukrainy. [Supervisory statistics. National Bank of Ukraine]. Available at: <https://bank.gov.ua/ua/statistic/supervision-statist#1> (accessed December 3, 2024).
2. Durand D. (1941) Risk Elements in Consumer Installment Financing. Technical Report. New York: National Bureau of Economic Research, 128 p.
3. Altman E. I., Saunders A. (1997) Credit risk measurement: Developments over the last 20 years. *Journal of Banking & Finance*. Available at: <https://www.tandfonline.com/doi/epdf/10.1080/030851499000000013> (accessed November 15, 2024).
4. Taffler R., Tisshaw H. (1977) Going, Going, Gone – Four Factors Which Predict. *Accountancy*, vol. 88, no. 1003, pp. 50–54.
5. Ayoub El Qadi El Haouari. (2023) An EXplainable Artificial Intelligence Credit Rating System. Artificial Intelligence. Sorbonne Université. Available at: <https://theses.hal.science/tel-04472510v1> (accessed November 21, 2024).
6. Vitlinskiy V. V., Pernarivskiy O. V. (2000) *Kredytnyi ryzyk komertsiiinoho banku: monohrafiia*. [Credit risk of a commercial bank: monograph]. Kyiv: Znannia, 251 p. (in Ukrainian)
7. Vasiurenko O. V. (2008) *Bankivski operatsii*. [Banking operations]. Kyiv: Znannia, 318 p. (in Ukrainian)
8. Moroz A. M. (2002) *Bankivski operatsii: pidruchnyk*. [Banking operations: textbook]. Kyiv: KNEU. 476 p.
9. Smerichevskiy S. F., Kasianova N. V., Hlushachenko S. S. (2017) Marketynhovi doslidzhennia kredytnoho reitynhu na osnovi shtuchnoi neironnoi merezhi. [Marketing research of credit rating based on artificial neural network] *Marketynh i tsyfrovi tekhnolohii*, vol. 1(2), pp. 32–40. Available at: <https://www.mdt-opu.com.ua/index.php/mdt/article/view/14> (accessed November 21, 2024).
10. Prymostka L. O. (2012) *Finansovyi menedzhment u banku: pidruchnyk*. [Financial management in a bank: textbook]. Kyiv: KNEU. 338 p.
11. Zadorozhna R. P. (2021) Vykorystannia neironnykh merezh dlia prohnozuvannia nadiinosti komertsiiinykh bankiv. [Using neural networks to predict the reliability of commercial banks]. *Ekonomika ta suspilstvo*, no. 27. Available at: <https://economyandsociety.in.ua/index.php/journal/article/view/446/428> (accessed November 24, 2024).
12. Bello O. A. (2023) Machine Learning Algorithms for Credit Risk Assessment: An Economic and Financial Analysis. *International Journal of Management Technology*, vol. 10(1), pp. 109–133. Available at: <https://eajournals.org/ijmt/wp-content/uploads/sites/69/2024/06/Machine-Learning-Algorithms.pdf> (accessed November 24, 2024).
13. Postanova NBU "Pro zatverdzhennia Polozhennia pro vyznachennia bankamy Ukrainy rozmiru kredytnoho ryzyku za aktyvnymy bankivskymy operatsiiamy" [Resolution of the NBU "On approval of the Regulation on determining by Ukrainian banks the amount of credit risk for active banking operations"] vid 30.06.2016 No. 351. Available at: https://bank.gov.ua/ua/legislation/Resolution_30062016_351 (accessed December 5, 2024).
14. Zhang X., Yu L. (2024) Consumer credit risk assessment: A review from the state-of-the-art classification algorithms, data traits, and learning methods. *Expert Systems with Applications*, vol. 37(A). DOI: <https://doi.org/10.1016/j.eswa.2023.121484> (accessed December 7, 2024).
15. Hjelkrem L., Lange P. (2023) Explaining Deep Learning Models for Credit Scoring with SHAP: A Case Study Using Open Banking Data. *Risk Management Journal*, vol. 6(4). DOI: <https://doi.org/10.3390/jrfm16040221> (accessed December 5, 2024).
16. Johnson O. (2024) Automated Credit Scoring: Leveraging Machine Learning for Financial Inclusion. *International Journal of Interdisciplinary Finance Insights*, vol. 3(3). Available at: <https://injm.com/index.php/ijifi/article/view/109> (accessed December 7, 2024).
17. Mestiri S. (2024) Credit scoring using machine learning and deep Learning-Based models. *Data Science in Finance and Economics*, vol. 4(2), pp. 236–248. DOI: <https://doi.org/10.3934/DSFE.2024009> (accessed December 7, 2024).
18. Marwa H., Salah A., Zied M., Zied J. (2024) A Machine Learning Model for Accurate Credit Risk Forecasting in Banking Systems: An Empirical Investigation. *International Journal of Supply & Operations Management*. vol. 11(2), pp. 168–187. DOI: <https://doi.org/10.22034/IJSOM.2023.109898.2722> (accessed December 7, 2024).