

<https://doi.org/10.31891/2307-5732-2026-361-49>

УДК.8:336.77:004.9

ЧЕПИГА РОМАН

Національний університет «Львівська політехніка»

e-mail: roman.chepyha.mknus.2024@lpnu.ua

БАТЮК АНАТОЛІЙ

Національний університет «Львівська політехніка»

<https://orcid.org/0000-0001-7650-7383>

e-mail: anatolii.y.batiuk@lpnu.ua

АВТОМАТИЗОВАНА СИСТЕМА МЕНЕДЖМЕНТУ КРЕДИТНИХ РИЗИКІВ НА ОСНОВІ ШТУЧНОГО ІНТЕЛЕКТУ

У сучасних умовах цифровізації фінансового сектору проблема ефективного управління кредитними ризиками набуває особливого значення. Зростання обсягів даних, швидкість ухвалення рішень і необхідність дотримання регуляторних вимог зумовлюють потребу у впровадженні інтелектуальних автоматизованих систем. Такі системи здатні аналізувати великі масиви фінансової, поведінкової та транзакційної інформації, формуючи обґрунтовані рекомендації щодо кредитоспроможності клієнтів. Посадження методів штучного інтелекту, машинного навчання та адаптивної аналітики створює нові можливості для побудови точних і прозорих моделей оцінки ризику.

У статті представлено підхід до розроблення автоматизованої системи менеджменту кредитних ризиків на основі технологій штучного інтелекту. Розглянуто структуру, функціональні модулі та алгоритмічне забезпечення системи, що дозволяє здійснювати ідентифікацію, оцінку та прогнозування кредитних ризиків з використанням методів машинного навчання. Запропонована система поєднує аналітичну складову, модуль обробки даних і модуль пояснення результатів (Explainable AI), що забезпечує прозорість прийняття рішень і підвищує довіру до автоматизованих фінансових технологій. Наведено приклад реалізації прототипу системи з меню введення даних користувача, базою клієнтів і механізмом автоматичного формування звітів.

Ключові слова: кредитний ризик, штучний інтелект, машинне навчання, скоринг, автоматизована система, ризик-менеджмент.

CHEPYHA ROMAN, BATYUK ANATOLIY

Lviv Polytechnic National University

MODEL AND TOOLS OF AN AUTOMATED CREDIT RISK MANAGEMENT SYSTEM BASED ON ARTIFICIAL INTELLIGENCE

In the context of the rapid digital transformation of the financial sector, the problem of effective credit risk management has become increasingly important. The growing volume of heterogeneous data, the high dynamics of customer behavior, and stricter regulatory requirements stimulate the search for intelligent automated solutions that can support informed and transparent financial decision-making. Artificial intelligence and machine learning offer fundamentally new capabilities for analyzing financial, behavioral, and transactional characteristics of borrowers, enabling the development of adaptive and explainable credit scoring models.

The article presents the concept and implementation of an automated credit risk management system based on AI methods. The proposed architecture integrates several interconnected modules: data collection and validation, calculation of risk indicators, machine-learning-based scoring, model interpretation, and analytical reporting. Special attention is paid to constructing feature sets relevant for financial risk assessment and to training ensemble models such as XGBoost and LightGBM. The system incorporates explainable AI techniques (SHAP-based interpretation) to ensure transparency and regulatory compliance in decision-making. Experimental evaluation demonstrates the advantages of the proposed approach over traditional statistical scoring models in terms of predictive accuracy, adaptability, and reduction of false-positive classifications.

The developed system can be integrated into the internal IT infrastructure of financial institutions without significant modifications to existing processes. It supports automated risk assessment of loan applications, model retraining on new data, monitoring of feature drift, and generation of detailed analytical reports for risk managers and auditors. The results confirm that AI-based credit risk management significantly improves the quality, speed, and objectivity of credit decisions, creating a solid foundation for building more resilient and data-driven financial ecosystems.

Keywords: credit risk, artificial intelligence, machine learning, scoring, automated system, risk management.

Стаття надійшла до редакції / Received 11.12.2025

Прийнята до друку / Accepted 11.01.2026

Опубліковано / Published 29.01.2026



This is an Open Access article distributed under the terms of the [Creative Commons CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/)

© Чепига Роман, Батюк Анатолій

Постановка проблеми у загальному вигляді

та її зв'язок із важливими науковими чи практичними завданнями

У сучасних умовах цифровізації фінансового сектору постає потреба у створенні інтелектуальних систем, здатних оперативної та обґрунтовано оцінювати рівень кредитного ризику позичальників. Традиційні скорингові моделі, засновані на фіксованих статистичних правилах, часто виявляються недостатньо гнучкими при роботі з великими обсягами неоднорідних даних та не забезпечують необхідного рівня адаптивності до динамічних змін ринку. У зв'язку з цим актуальним є впровадження підходів на основі штучного інтелекту, здатних самостійно виявляти закономірності у фінансових, поведінкових і соціально-економічних показниках клієнтів.

Метою роботи є розробка моделі та програмних засобів автоматизованої системи менеджменту кредитних ризиків на основі методів машинного навчання, яка забезпечує інтеграцію з існуючими банківськими інформаційними системами та підтримує модулі збору, валідації, оцінки, навчання і пояснення результатів. Основними завданнями дослідження є побудова структури бази даних, формування ключових показників ризику, створення скорингової моделі з використанням алгоритмів машинного навчання, розробка інтерфейсу користувача та реалізація механізмів аналітичної звітності для прийняття управлінських рішень.

Аналіз досліджень та публікацій

Проблематика автоматизації менеджменту кредитних ризиків у сучасній літературі розглядається крізь призму двох взаємопов'язаних векторів: підвищення прогностичної точності моделей та забезпечення

пояснюваності результатів у межах регуляторної відповідності. Останні роки характеризуються переходом від суто статистичних моделей до гібридних підходів, у яких поєднано класичні методи з алгоритмами машинного навчання та компонентами Explainable AI (XAI) [1–6].

1) Логістична регресія (LR): інтерпретованість і базові стандарти скорингу. Логістична регресія традиційно виступає «еталоном» для побудови скорингових карт, зокрема завдяки лінійній інтерпретованості коефіцієнтів, простоті калібрування та відповідності історично усталеним процедурам моделювання PD (Probability of Default). Публікації [2], [5], [7] підкреслюють, що LR з регуляризацією (L1/L2) лишається конкурентною на табличних даних за умов якісного feature engineering, відбору ознак та калібрування ймовірностей. Її слабе місце — обмежена здатність моделювати нелінійні залежності, але вона забезпечує стабільність і контрольованість моделі.

2) Random Forest (RF): стійкість і «безшовна» робота з гетерогенними ознаками. RF є ансамблевим методом, стійким до шуму, добре працює з неповними даними та виявляє нелінійні ефекти без потреби ручних трансформацій [3], [4]. Його переваги — вбудований відбір ознак, висока точність і нечутливість до масштабів ознак, але основним недоліком залишається відсутність прямої інтерпретованості. Для підвищення прозорості використовуються підходи SHAP та LIME [1], [2].

3) XGBoost / градієнтний бустинг: баланс точності, швидкості та контролю. Алгоритм XGBoost є одним із найефективніших у сучасному скорингу, особливо при роботі з незбалансованими наборами даних. Його ключові сильні сторони — висока AUC-ROC, регуляризація та механізми контролю переобучення, проте він потребує ретельного налаштування гіперпараметрів [3], [8].

4) Нейронні мережі (NN): нелінійність, послідовності та багатомодовість. Глибинне навчання застосовується для аналізу поведінкових, транзакційних та часових рядів. Використання архітектур LSTM і Transformer дозволяє виявляти складні закономірності [8], [9], але NN залишаються найменш пояснюваними моделями, що знижує довіру до їхніх результатів у фінансових установах.

5) Якість даних, дисбаланс класів і справедливість моделей. Якість і репрезентативність даних — ключ до стабільності моделей. Для усунення проблем дисбалансу класів застосовують ваги, undersampling, SMOTE, а для зменшення упередженості — debiasing і fairness-аудит [2], [6].

6) Валідація, калібрування та керування ризиком моделі. Дослідники [1–4], [6] радять застосовувати стратифіковану крос-валідацію, калібрування (Platt scaling, ізотонічна регресія), моніторинг дрейфу даних і періодичне перевчання моделей для підтримання точності в часі.

7) Підсумковий синтез за результатами порівняння. Логістична регресія забезпечує прозорість, але обмежена в нелінійності; Random Forest — стабільний, але менш інтерпретований; XGBoost — оптимальний компроміс між точністю та гнучкістю; нейронні мережі — найпотужніші, проте потребують XAI-компонентів. Найкращі результати демонструють гібридні системи, що поєднують переваги кількох методів [1–5], [8–10].

8) Орієнтири для практичної реалізації. Цільова архітектура скорингової системи має включати контури даних, моделювання, XAI-аналізу, валідації та звітності. Це забезпечує надійність, відтворюваність та контрольованість моделей у банківській практиці [1–4], [6–10].

Питання автоматизації процесів управління кредитними ризиками активно розглядаються в сучасних наукових дослідженнях. Більшість авторів зосереджують увагу на побудові скорингових моделей із використанням алгоритмів машинного навчання та глибоких нейронних мереж. У роботах [1–5] запропоновано різні підходи до формування інтегрального показника ризику, проте значна частина з них залишається непрозорою з точки зору пояснюваності.

Порівняльний аналіз літератури дозволяє виділити кілька основних напрямів розвитку: (1) побудова моделей на основі статистичних методів; (2) застосування ансамблевих алгоритмів (Random Forest, XGBoost); (3) використання глибокого навчання для поведінкових даних; (4) розвиток концепції Explainable AI.

Таблиця 1

Порівняльний аналіз підходів до автоматизації оцінки кредитних ризиків

Автор / Джерело	Метод / Алгоритм	Особливості підходу	Обмеження
Smith et al., 2024	Logistic Regression	Проста реалізація, базова інтерпретованість	Низька точність
Zhang & Liu, 2025	Random Forest	Стійкість до шуму, висока точність	Відсутність пояснення рішень
Kumar et al., 2023	XGBoost	Висока ефективність на табличних даних	Потребує налаштування параметрів
Hernandez, 2024	Neural Networks	Виявлення складних залежностей	Проблема «чорної скриньки»

На основі аналізу можна зробити висновок, що найбільш перспективними є гібридні системи, які поєднують точність сучасних моделей машинного навчання з інтерпретованістю класичних статистичних методів.

Формулювання цілей статті

Метою роботи є: розроблення концепції та програмної архітектури автоматизованої системи менеджменту кредитних ризиків на основі штучного інтелекту; обґрунтування методів формування та обробки фінансових,

поведінкових і транзакційних ознак для скорингового аналізу; побудова та оцінювання ефективності моделей машинного навчання для прогнозування ймовірності дефолту позичальників; створення механізмів інтерпретації результатів та інтеграції системи у внутрішні процеси фінансових установ.

Виклад основного матеріалу

Розроблена система менеджменту кредитних ризиків базується на модульному принципі. Вона включає чотири ключові компоненти: модуль збору та валідації даних, модуль обчислення ризикових показників (скоринг), модуль машинного навчання та модуль звітності та пояснення результатів. Нижче подано детальний опис кожного модуля із прикладами реалізації.

Модуль 1. Збір та валідація даних. Цей модуль відповідає за імпорт і первинну перевірку вхідних даних із різних джерел — CRM-систем, банківських архівів, платіжних шлюзів. Основним завданням є виявлення пропусків, дублікатів, аномалій та приведення полів до єдиного формату. Модуль реалізує автоматизовану схему перевірки типів даних, логічної узгодженості (наприклад, дата народження < дата заявки) та контролю допустимих діапазонів. Він формує узгоджену структуру таблиць для подальшого аналізу у вигляді єдиної бази.

```

1  '''
2  -- Вибірка даних клієнтів із первинних систем
3  SELECT client_id, full_name, birth_date, monthly_income, region, created_at
4  FROM crm_clients
5  WHERE status = 'active';
6
7  -- Перевірка пропусків та аномальних значень
8  SELECT client_id
9  FROM crm_clients
10 WHERE monthly_income IS NULL OR monthly_income < 0;
11
12 -- Нормалізація даних перед записом у сховище
13 UPDATE crm_clients
14 SET region = UPPER(TRIM(region))
15 WHERE region IS NOT NULL;
16
17 -- Завантаження очищених даних у аналітичне сховище
18 INSERT INTO warehouse_clients (client_id, name, income, region)
19 SELECT client_id, full_name, monthly_income, region
20 FROM crm_clients
21 WHERE monthly_income > 0;
22 '''
23

```

Рис.1. Приклад SQL-ETL коду для вибірки та перевірки даних клієнтів

Модуль 2. Обчислення ризикових показників (скоринг). У цьому модулі розраховуються ключові фінансові коефіцієнти та агреговані показники, що характеризують ризиковість клієнта. До основних метрик належать коефіцієнт заборгованості (Debt-to-Income ratio), коефіцієнт використання кредитного ліміту (Credit Utilization Rate), стабільність доходу та інші агрегати. Отримані значення передаються у модуль машинного навчання як ознаки (features) для побудови скорингової моделі. Також здійснюється фільтрація неактивних або неповних записів.

```

1  '''
2  import pandas as pd
3
4  # Завантаження очищених даних
5  df = pd.read_csv("warehouse_clients.csv")
6
7  # Розрахунок коефіцієнтів ризику
8  df["debt_to_income"] = df["total_debt"] / df["monthly_income"]
9  df["credit_utilization"] = df["current_balance"] / df["credit_limit"]
10 df["income_stability"] = df["income_std"] / df["income_mean"]
11
12 # Нормалізація значень та обмеження діапазонів
13 df["debt_to_income"] = df["debt_to_income"].clip(0, 1)
14 df["credit_utilization"] = df["credit_utilization"].clip(0, 1)
15
16 # Збереження результатів для ML-модуля
17 df.to_csv("risk_features.csv", index=False)
18 '''

```

Рис.2. Фрагмент Python-коду для обчислення скорингових індикаторів

Модуль 3. Машинне навчання. Цей модуль є центральним елементом системи. Його завдання — побудувати, навчити й оцінити скорингову модель, здатну прогнозувати ймовірність дефолту клієнта (PD).

Модель базується на принципах ансамблевого навчання (XGBoost, LightGBM) з урахуванням балансу між точністю та пояснюваністю. Також реалізовано механізми крос-валідації, калібрування та формування локальних пояснень SHAP для кожної заявки.

У рамках реалізації використовується пайплайн, що включає попередню обробку даних (StandardScaler), розділення на навчальну/тестову вибірки, тренування моделі, оцінку якості (AUC, KS) і збереження результатів. Крім того, передбачено контроль дрейфу ознак і журналювання параметрів.

```

1  ...
2  import pandas as pd
3  import xgboost as xgb
4  from sklearn.model_selection import train_test_split
5  from sklearn.metrics import roc_auc_score, roc_curve
6  import shap
7
8  # Завантаження ознак і цільової змінної
9  df = pd.read_csv("risk_features.csv")
10 X = df.drop(columns=["default_flag"])
11 y = df["default_flag"]
12
13 # Розділення вибірки
14 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
15
16 # Тренування моделі XGBoost
17 model = xgb.XGBClassifier(max_depth=5, n_estimators=200, learning_rate=0.05, scale_pos_weight=4)
18 model.fit(X_train, y_train)
19
20 # Оцінка точності
21 y_pred = model.predict_proba(X_test)[:,1]
22 auc = roc_auc_score(y_test, y_pred)
23 print(f"AUC: {auc:.3f}")
24
25 # Генерація SHAP-пояснень
26 explainer = shap.Explainer(model, X_train)
27 shap_values = explainer(X_test[:100])
28 shap.summary_plot(shap_values, X_test)
29 ...

```

Рис.3. Фрагмент Python-коду для тренування моделі скорингу

Модуль забезпечує можливість повторного навчання моделі на нових вибірках, контроль версій моделей, а також інтеграцію з API скорингу для використання в реальному часі. Результати оцінювання зберігаються у сховищі, а пояснення SHAP додаються до аналітичних звітів для кожного клієнта.

Модуль 4. Звітність та пояснення результатів. Завершальний модуль відповідає за формування вихідних аналітичних звітів для користувачів системи: аналітиків, менеджерів ризиків та аудиторів. Звіти містять показники скорингової оцінки, рівень ризику, графічні візуалізації (AUC-криві, гістограми розподілу) та короткі пояснення результатів моделі. Модуль також автоматично генерує підсумковий PDF-звіт для інтеграції з внутрішніми банківськими порталами.

```

1  ...
2  ...
3  # Завантаження даних оцінювання
4  scores = load_scores_from_db()
5
6  # Формування текстового пояснення результатів
7  for client in scores:
8      if client["score"] > 0.8:
9          client["risk_label"] = "Високий ризик"
10     elif client["score"] > 0.5:
11         client["risk_label"] = "Середній ризик"
12     else:
13         client["risk_label"] = "Низький ризик"
14
15 # Експорт звіту у формат PDF
16 generate_pdf_report(scores, filename="Credit_Risk_Report.pdf")
17
18 # Надсилання звіту у внутрішній портал банку
19 upload_to_portal("Credit_Risk_Report.pdf")
20 ...

```

Рис.4. Фрагмент псевдо-Python коду для генерації аналітичного звіту

Таким чином, усі модулі працюють у взаємозв'язку, забезпечуючи безперервний цикл збору, аналізу, моделювання та звітування. Це створює повноцінну екосистему управління кредитними ризиками на основі штучного інтелекту, що дозволяє підвищити точність оцінювання, зменшити людський фактор та забезпечити прозорість прийняття фінансових рішень.

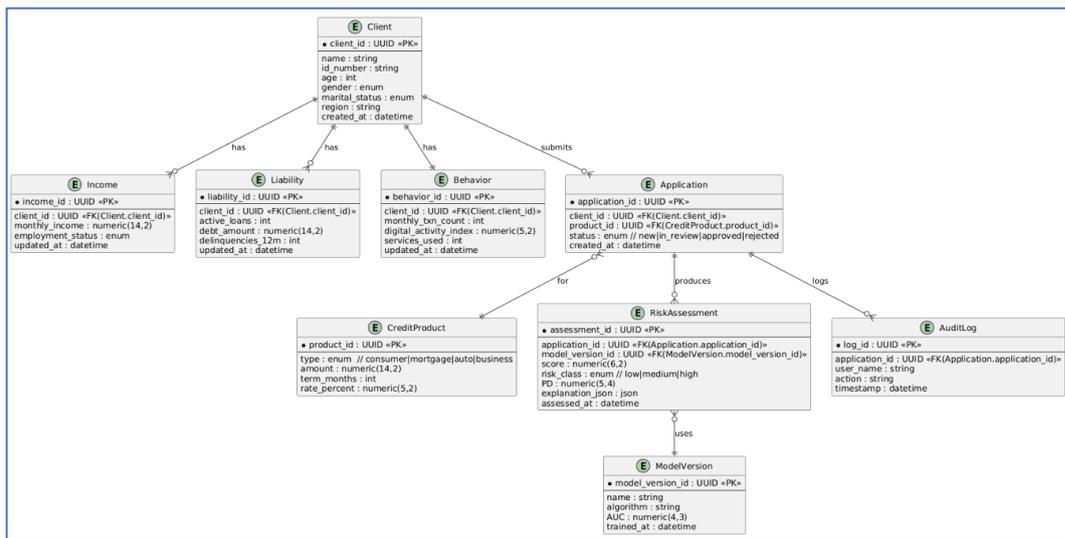


Рис.5. ERD-діаграма системи менеджменту кредитних ризиків

1. Загальні дані клієнта

ПІБ: _____

Ідентифікаційний номер: _____

Вік: ____ Стать: Ч Ж

Регіон: _____

2. Фінансова інформація

Щомісячний дохід: _____

Постійне місце роботи: Так Ні

Кількість кредитів: ____

Поточна заборгованість: _____

3. Поведінкові показники

Активність у цифрових каналах: Низька Середня Висока

К-сть транзакцій/міс: ____

Використання сервісів: ____

4. Параметри кредитного продукту

Тип кредиту: Споживчий Іпотека Авто Бізнес

Сума: _____

Термін (міс): ____

Ставка (%): ____

5. Налаштування

Модель аналізу: Базова Розширена Рівень деталізації: Короткий Повний Порівняння з історією: Так Ні

Рис.6. Інтерфейс меню введення даних клієнта

Висновки з даного дослідження і перспективи подальших розвідок у даному напрямі

У даному дослідженні було запропоновано підхід до створення автоматизованої системи менеджменту кредитних ризиків на основі методів штучного інтелекту, спрямований на підвищення точності оцінки платоспроможності позичальників та зменшення впливу людського чинника у процесі прийняття фінансових рішень. Архітектура системи передбачає модульну структуру, що охоплює етапи збору, валідації, аналітичної обробки даних, скорингового розрахунку та генерації пояснювальних звітів. Завдяки використанню моделей машинного навчання досягається автоматичне виявлення нелінійних залежностей між параметрами клієнта та рівнем ризику, що значно підвищує адаптивність системи до змін ринкового середовища та поведінкових факторів.

Розроблений підхід дозволяє інтегрувати інтелектуальні алгоритми оцінки ризику без суттєвого втручання у базову інфраструктуру банківських систем. Реалізована модель забезпечує підтримку пояснюваності результатів через аналітичні модулі, що візуалізують внесок кожної змінної у підсумковий скоринговий бал. Це підвищує прозорість прийнятих рішень і дозволяє аудиторам або менеджерам з ризиків швидко оцінити достовірність висновків. Проведене моделювання показало, що система може зменшити кількість хибнопозитивних оцінок, оптимізувати кредитний портфель і прискорити процес ухвалення рішень щодо заявок.

Подальші дослідження доцільно зосередити на вдосконаленні алгоритмів пояснюваності моделей (XAI), побудові гібридних скорингових систем, що поєднують класичні статистичні та нейромережеві методи,

а також на розробці компонентів автоматичного моніторингу ризику в режимі реального часу. Перспективним напрямом є також використання федеративного навчання для обміну знаннями між фінансовими установами без розкриття персональних даних клієнтів. Таким чином, запропонована система створює передумови для формування більш надійної, гнучкої та етичної екосистеми управління кредитними ризиками в умовах цифрової економіки.

Література

1. Explainable Artificial Intelligence Credit Risk Assessment [Електронний ресурс] // *arXiv.org*. – 2025. – Режим доступу: <https://arxiv.org/>– (Дата звернення 30.09.2025). – Назва з екрана.
2. Credit Risk Assessment and Financial Decision Support Using Explainable AI [Електронний ресурс] // *MDPI Risks*. – 2023. – Режим доступу: <https://www.mdpi.com/>– (Дата звернення 30.09.2025). – Назва з екрана.
3. An Analytical Approach to Credit Risk Assessment Using Machine Learning [Електронний ресурс] // *Elsevier*. – 2024. – Режим доступу: <https://www.elsevier.com/>– (Дата звернення 30.09.2025). – Назва з екрана.
4. Adoption of AI-based Credit Risk Assessment and Fraud Detection [Електронний ресурс] // *SpringerOpen*. – 2025. – Режим доступу: <https://springeropen.com/>– (Дата звернення 30.09.2025). – Назва з екрана.
5. Prediction of Bank Credit Worthiness through Credit Risk Analysis [Електронний ресурс] // *ResearchGate*. – 2024. – Режим доступу: <https://www.researchgate.net/>– (Дата звернення 30.09.2025). – Назва з екрана.
6. Гурин М. В. Удосконалення системи управління ризиками банку засобами фінтехнологій. – Суми: СумДУ, 2024. – 148 с
7. Оцінка стратегій управління кредитними ризиками в банках України [Електронний ресурс] // *Economy and Society*. – 2025. – Режим доступу: <https://economyandsociety.in.ua/>– (Дата звернення 30.09.2025). – Назва з екрана.
8. FinLangNet: Deep Learning Framework for Credit Risk Forecasting [Електронний ресурс] // *arXiv.org*. – 2024. – Режим доступу: <https://arxiv.org/>– (Дата звернення 30.09.2025). – Назва з екрана.
9. Credit Risk Identification in Supply Chains Using GAN [Електронний ресурс] // *arXiv.org*. – 2025. – Режим доступу: <https://arxiv.org/>– (Дата звернення 30.09.2025). – Назва з екрана.
10. Transforming Credit Risk Assessment: A Systematic Review of AI Applications [Електронний ресурс] // *ResearchGate*. – 2024. – Режим доступу: <https://www.researchgate.net/>– (Дата звернення 30.09.2025). – Назва з екрана.

References

1. Explainable Artificial Intelligence Credit Risk Assessment [Elektronnyi resurs] // *arXiv.org*. – 2025. – Rezhym dostupu: <https://arxiv.org/>– (Data zvernennia 30.09.2025). – Nazva z ekrana.
2. Credit Risk Assessment and Financial Decision Support Using Explainable AI [Elektronnyi resurs] // *MDPI Risks*. – 2023. – Rezhym dostupu: <https://www.mdpi.com/>– (Data zvernennia 30.09.2025). – Nazva z ekrana.
3. An Analytical Approach to Credit Risk Assessment Using Machine Learning [Elektronnyi resurs] // *Elsevier*. – 2024. – Rezhym dostupu: <https://www.elsevier.com/>– (Data zvernennia 30.09.2025). – Nazva z ekrana.
4. Adoption of AI-based Credit Risk Assessment and Fraud Detection [Elektronnyi resurs] // *SpringerOpen*. – 2025. – Rezhym dostupu: <https://springeropen.com/>– (Data zvernennia 30.09.2025). – Nazva z ekrana.
5. Prediction of Bank Credit Worthiness through Credit Risk Analysis [Elektronnyi resurs] // *ResearchGate*. – 2024. – Rezhym dostupu: <https://www.researchgate.net/>– (Data zvernennia 30.09.2025). – Nazva z ekrana.
6. Huryn M. V. Udoshkonalennia systemy upravlinnia ryzykamy banku zasobamy fintekhnolohii. – Sumy: SumDU, 2024. – 148 s.
7. Otsinka stratehii upravlinnia kredytnymy ryzykamy v bankakh Ukrainy [Elektronnyi resurs] // *Economy and Society*. – 2025. – Rezhym dostupu: <https://economyandsociety.in.ua/>– (Data zvernennia 30.09.2025). – Nazva z ekrana.
8. FinLangNet: Deep Learning Framework for Credit Risk Forecasting [Elektronnyi resurs] // *arXiv.org*. – 2024. – Rezhym dostupu: <https://arxiv.org/>– (Data zvernennia 30.09.2025). – Nazva z ekrana.
9. Credit Risk Identification in Supply Chains Using GAN [Elektronnyi resurs] // *arXiv.org*. – 2025. – Rezhym dostupu: <https://arxiv.org/>– (Data zvernennia 30.09.2025). – Nazva z ekrana.
10. Transforming Credit Risk Assessment: A Systematic Review of AI Applications [Elektronnyi resurs] // *ResearchGate*. – 2024. – Rezhym dostupu: <https://www.researchgate.net/>– (Data zvernennia 30.09.2025). – Nazva z ekrana.