

*Електронний журнал «Ефективна економіка» включено до переліку наукових фахових видань України з питань економіки (Категорія «Б», Наказ Міністерства освіти і науки України № 975 від 11.07.2019). Спеціальності – 051, 071, 072, 073, 075, 076, 292. Ефективна економіка. 2025. № 4.*

**DOI: <http://doi.org/10.32702/2307-2105.2025.4.26>**

**УДК 338.1**

*О. І. Ляшенко,*

*д. е. н, професор, завідувачка кафедри економічної кібернетики,  
Київський національний університет імені Тараса Шевченка*

*ORCID ID: <https://orcid.org/0000-0002-0197-4179>*

*Т. В. Кравець,*

*к. ф.-м. н., доцент, доцент кафедри економічної кібернетики,  
Київський національний університет імені Тараса Шевченка*

*ORCID ID: <https://orcid.org/0000-0003-4823-5143>*

*О. К. Мордатенко,*

*студент освітньої програми «Економічна кібернетика»,  
Київський національний університет імені Тараса Шевченка*

*ORCID ID: <https://orcid.org/0009-0005-6689-9842>*

## **МОДЕЛЮВАННЯ КРЕДИТНОГО РИЗИКУ З ВИКОРИСТАННЯМ ГІБРИДНОЇ МОДЕЛІ RNN-LSTM ДЛЯ ЦИФРОВИХ ФІНАНСОВИХ УСТАНОВ**

*О. Liashenko,*

*Doctor of Economic Sciences, Professor, Head of the Department of Economic  
Cybernetics, Taras Shevchenko National University of Kyiv*

*T. Kravets,*

*PhD in Physico-Mathematical Sciences, Associate Professor,  
Associate Professor of the Department of Economic Cybernetics,  
Taras Shevchenko National University of Kyiv*

*О. Mordatenko,*

*Student of the educational program “Economic Cybernetics”,  
Taras Shevchenko National University of Kyiv*

## **CREDIT RISK MODELING USING HYBRID RNN-LSTM MODEL FOR DIGITAL FINANCIAL INSTITUTIONS**

*У сучасному світі цифрові фінансові інститути займають дедалі важливіше місце, забезпечуючи швидкі, зручні та доступні фінансові послуги для широкого кола клієнтів. Зі зростанням обсягів операцій та кількості користувачів зростає й потреба у вдосконаленні систем оцінки та управління кредитними ризиками.*

*Застосування методів машинного навчання та, зокрема, рекурентних нейронних мереж (RNN) і довготривалої короткочасної пам'яті (LSTM), відкриває нові можливості для підвищення точності та ефективності моделей кредитного ризику. Гібридна модель RNN-LSTM дозволяє не лише враховувати часові залежності у даних, але й адаптуватися до складних структурних змін, що є критично важливим для прогнозування дефолтів та оцінки кредитоспроможності клієнтів. Метою проведення цього дослідження було визначити ефективність моделей RNN, LSTM та гібридної моделі RNN-LSTM при оцінці ознак невиконання позичальників. Для цього була розроблена гібридна модель RNN-LSTM та протестована на даних, отриманих з Kaggle. Модель RNN використовувалася для вибору ознак за допомогою індексу Джині. Модель LSTM була застосована для бінарної класифікації клієнтів на основі їх історичних даних, щоб визначити фінансову доцільність надання кредиту кожному позичальнику.*

*Показано, що нейромережі, які використовують гібридну модель RNN-LSTM, здатні з високою точністю класифікувати позичальників, схильних до невиконання кредитних зобов'язань. У процесі моделювання за допомогою побудови гібридної моделі була досягнута точність 0,8269.*

*Таким чином, впровадження гібридної моделі RNN-LSTM у кредитний скоринг дозволяє з високою точністю прогнозувати неплатоспроможність позичальників, що сприяє зменшенню кредитних втрат і підвищенню ефективності фінансових установ. Це відкриває нові перспективи для вдосконалення кредитних скорингових систем.*

*In today's world, digital financial institutions are playing an increasingly important role, providing fast, convenient and affordable financial services to a wide range of customers. As transaction volumes and the number of users grow, the need for improved credit risk assessment and management systems also increases.*

*The application of machine learning methods, and in particular recurrent neural networks (RNN) and long short-term memory (LSTM), opens up new opportunities to improve the accuracy and efficiency of credit risk models. The hybrid RNN-LSTM model allows not only to take into account temporal dependencies in the data, but also to adapt to complex structural changes, which is critically important for predicting defaults and assessing customer creditworthiness. The purpose of this study was to determine the effectiveness of RNN, LSTM, and hybrid RNN-LSTM models in assessing signs of borrower default. For this purpose, a hybrid RNN-LSTM model was developed and tested on data obtained from Kaggle. The RNN model was used to select features using the Gini index. The LSTM model was applied for binary classification of clients based on their historical data to determine the financial feasibility of granting a loan to each borrower.*

*It was shown that neural networks using a hybrid RNN-LSTM model are capable of highly accurate classification of borrowers prone to credit defaults. During the modeling process, using the construction of a hybrid model, an accuracy of 0.8269 was achieved.*

*Thus, the implementation of a hybrid RNN-LSTM model in credit scoring enables highly accurate prediction of borrower default, which helps reduce credit losses and increase the efficiency of financial institutions. This opens up new perspectives for improving credit scoring systems.*

***Ключові слова:*** *кредитний скоринг, класифікація, методи машинного навчання, гібридні моделі.*

***Keywords:*** *credit scoring, classification, machine learning methods, hybrid models.*

***Постановка проблеми у загальному вигляді та її зв'язок із важливими науковими чи практичними завданнями.*** Вплив банківської системи невідмінно зростає разом із розвитком економіки та економічних відносин. Одним з основних факторів успішної діяльності банківських установ невідперечно є ефективне управління кредитним ризиком. З огляду на вище сказане оцінка потенційного повернення або невідвернення кредиту є особливо актуальною.

Паралельно банківській системі розвивається і ІТ сфера, зокрема можна виділити методи машинного навчання, котрі дозволяють із великої кількості даних, які накопичуються у фінансових компаніях, знаходити потрібну інформацію для вирішення певних проблем та оптимізації процесів. Методи машинного навчання набули надзвичайної популярності через зростання обчислювальних потужностей комп'ютерної техніки, що дозволило використовувати штучний інтелект у банківській сфері серед методів аналізу кредитного скорингу. Скорингові системи є зручним інструментом оцінювання кредитоспроможності адже використання скорингу сприяє підвищенню швидкості та правильності прийняття рішень щодо видачі кредитів, що є важливим у реаліях сьогодення. Окрім того, скоринг може враховувати як суто фінансові показники діяльності позичальника, так і якісні чинники.

***Аналіз останніх досліджень і публікацій.*** Кредитний скоринг є фундаментальним інструментом в оцінці кредитоспроможності позичальників, який використовується фінансовими установами для прийняття рішень щодо надання кредитів [1, 2]. Він представляє собою числовий вираз ймовірності того, що позичальник виконає свої зобов'язання перед кредитором. Цей числовий показник розраховується на основі статистичних методів і аналізу історичних даних про поведінку клієнтів [3, 4].

Основні традиційні методи кредитного скорингу включають кілька підходів [5]. Першим був метод експертних систем. Цей метод передбачав

оцінку кредитоспроможності позичальника на основі досвіду та інтуїції кредитних аналітиків. Другим підходом були правила кредитування. Цей метод базувався на встановленні банками та фінансовими установами певних порогових значень для ключових фінансових показників, таких як рівень доходів, співвідношення боргу до доходу та інші. Позичальники, які відповідали цим критеріям, вважалися кредитоспроможними. Третім методом були бальні системи. В рамках цього методу кожному критерію, такому як вік, рівень доходів, стаж роботи, наявність нерухомості тощо, присвоювався певний бал. Загальна сума балів використовувалася для визначення кредитоспроможності позичальника. Четвертим підходом був аналіз фінансових коефіцієнтів [5].

Сучасні системи базуються на статистичних моделях, алгоритмах машинного навчання та великих масивах даних, що дозволяє значно підвищити точність і надійність оцінки кредитних ризиків. Однак, деякі принципи, закладені у традиційних методах, все ще використовуються як основа для сучасних підходів, забезпечуючи важливу спадковість та узгодженість у системах кредитного скорингу. Застосування інформаційних технологій, великих даних та машинного навчання трансформували традиційні методи кредитного скорингу, зробивши їх більш ефективними та об'єктивними.

Одним з найбільш значущих впливів є використання великих даних. Завдяки збору та аналізу великого обсягу різноманітних даних фінансові установи отримали можливість більш глибоко розуміти поведінку позичальників. Дані з різних джерел, таких як соціальні мережі, онлайн-покупки, дані з мобільних додатків та навіть поведінкові патерни, дозволяють створювати більш комплексний профіль клієнта. Це забезпечує більш точну оцінку кредитного ризику та знижує ймовірність надання кредитів недобросовісним позичальникам [5].

Машинне навчання є ще одним ключовим компонентом сучасного кредитного скорингу. Використання алгоритмів машинного навчання

дозволяє аналізувати великі обсяги даних, виявляти приховані закономірності та робити прогнози щодо платоспроможності позичальників. Алгоритми можуть постійно навчатися на нових даних, вдосконалюючи свої прогнози та підвищуючи точність моделей скорингу. Це дає змогу швидко адаптуватися до змін у поведінці споживачів та ринкових умовах [6, 7, 8].

Ось кілька прикладів використання гібридних моделей з LSTM у наукових дослідженнях:

- Гібридна модель з використанням CNN і LSTM для аналізу часових рядів зображень або відео. CNN витягує просторові ознаки з зображень, а LSTM моделює тимчасові залежності між цими ознаками. У одному з досліджень дана гібридна модель використовувалася для передбачення опадів, комбінуючи властивості CNN і LSTM [6].
- Використання GAN для генерації синтетичних даних, які потім обробляються LSTM для прогнозування або класифікації. Такий підхід може бути корисним для поліпшення якості даних або збільшення обсягу тренувальної вибірки. В одному з досліджень така гібридна модель використовувалася для синтезу аудіо, де LSTM шар обробляв синтезовані за допомогою GAN дані для подальшого покращення якості моделі [7].
- LSTM + Random Forests: Використання LSTM для виділення часових ознак з даних, а потім класифікація або регресія цих ознак за допомогою Random Forests. У [8] вказана гібридна модель використовувала LSTM для витягання часових ознак з криптовалютних даних, а потім Random Forests - для прогнозування волатильності.

Застосування гібридних моделей, таких як RNN-LSTM, відкриває нові перспективи для подальшого розвитку кредитного скорингу. Ці моделі дозволяють враховувати не тільки поточні дані, але й їхню динаміку, що особливо важливо для оцінки кредитних ризиків у цифрових фінансових установах. Гібридні підходи поєднують сильні сторони різних методів і можуть значно підвищити точність та надійність прогнозів, сприяючи

кращому управлінню ризиками і підвищенню стабільності фінансових систем [4].

**Формулювання цілей статті (постановка завдання).** Ця робота присвячена дослідженню застосування гібридної моделі RNN-LSTM для моделювання кредитних ризиків у цифрових фінансових інститутах. Основна мета полягає у розробці та тестуванні моделі, яка здатна забезпечити високий рівень точності прогнозів при збереженні оперативності та ефективності обробки даних.

**Виклад основного матеріалу дослідження.** Рекурентна нейронна мережа (RNN) може бути визначена як особлива форма штучної нейронної мережі, яка була структурована для роботи з послідовними даними. Ці алгоритми глибокого навчання зазвичай використовуються для вирішення порядкових або часових завдань, таких як переклад мови, обробка природної мови (NLP), розпізнавання мови і підписи до зображень; вони включені в такі популярні програми, як Siri, голосовий пошук і Google Translate [9]. RNN відрізняються своєю "пам'яттю", оскільки беруть інформацію з попередніх входів, щоб впливати на поточний вхід і вихід. У той час як традиційні глибокі нейронні мережі припускають, що входи і виходи є незалежними один від одного, вихід рекурентних нейронних мереж залежить від попередніх елементів у послідовності. Хоча майбутні події також можуть бути корисними для визначення виходу певної послідовності, односпрямовані рекурентні нейронні мережі не можуть врахувати ці події у своїх прогнозах [10].

Мережі довготривалої короткочасної пам'яті (LSTM) – це особливий вид RNN, здатний навчатися довготривалим залежностям. LSTM спеціально розроблені для того, щоб уникнути проблеми довготривалої залежності. Запам'ятовування інформації на тривалий час - це практично їхня поведінка за замовчуванням, а не те, чого вони намагаються навчитися [10, 11, 12].

Використання індексу Джині (Gini Index) для вибору ознак у RNN мережах є інноваційним підходом, що поєднує методи з області прийняття

рішень з потужністю RNN для обробки послідовних даних. Індекс Джині часто застосовується для оцінки важливості ознак у задачах класифікації.

Індекс Джині є мірою «нечистоти» (impurity) або «нерівності» позначень/лейблів певного класу, пов'язаних з певною ознакою. Тобто він оцінює, наскільки добре ознака розділяє дані на класи. Чим нижчий індекс Джині для вузла/певного значення властивості даних, тим "чистіший" вузол, тобто тим більше певна властивість містить прикладів одного класу.

Імовірність класу для певного значення ознаки обчислюється за частотною формулою. Сума зважених показників Джині для всіх значень ознаки, визначає індекс Джині для цієї ознаки.

Сама RNN-модель не змінюється, коли вибір ознак здійснюється за допомогою RNN-моделі та індексу Джині. Замість цього, прогнози RNN моделі використовуються для визначення відносної релевантності кожної ознаки за допомогою індексу Джині.

Таким чином, на основі аналізу важливості ознак буде обрано підмножину ознак, які мають більшу вагу або вважаються найбільш важливими. Буде обрано поріг важливості ознаки та збережено ознаки, які перевищують цей поріг. І обрана підмножина буде далі використовуватися як вхідні параметри для наступного шару гібридної моделі.

Нейронна мережа, використана в цьому дослідженні, є гібридною моделлю RNN-LSTM. RNN мережа створювалась з метою зменшення кількості параметрів, покращити час навчання та збільшити швидкість моделі LSTM. Використовуючи RNN, ми спочатку витягуємо найважливіші ознаки з даних перед тим, як вони надходять до моделі LSTM, потім обираємо індикатори, які є більш релевантними для прогнозування кредитного ризику компанії, спрощуємо дані та об'єднуємо переваги обох моделей RNN та LSTM у гібридній моделі RNN-LSTM.

У RNN інформація передається у двосторонньому напрямку, що підтримує зв'язок між довгими послідовностями даних завдяки її внутрішній пам'яті. На основі прогнозів, зроблених моделлю RNN, ми здійснюємо вибір

ознак, використовуючи індекс Джині. Виділені за допомогою індексу Джині ознаки далі використовуються як вхідні дані для моделі LSTM. І, насамкінець, модель виконує класифікацію шляхом групування ймовірностей, а саме:

- Клас 1 включає ймовірності від 0 до 0.5;
- Клас 2 включає ймовірності від 0.5 до 1.

Для перевірки роботи запропонованої гібридної моделі, скористаймося набором даних одного з кредитних бюро, котрий було завантажено із платформи Kaggle [13].

**Таблиця 1. Перші 5 рядків даних у транспонованому вигляді**

|                                   |          |           |          |         |         |
|-----------------------------------|----------|-----------|----------|---------|---------|
| <b>person_age</b>                 | 22       | 21        | 25       | 23      | 24      |
| <b>person_income</b>              | 59000    | 9600      | 9600     | 65500   | 54400   |
| <b>person_home_ownership</b>      | rent     | own       | mortgage | rent    | rent    |
| <b>person_emp_length</b>          | 123.0    | 5.0       | 1.0      | 4.0     | 8.0     |
| <b>loan_intent</b>                | personal | education | medical  | medical | medical |
| <b>loan_grade</b>                 | D        | B         | C        | C       | C       |
| <b>loan_amnt</b>                  | 35000    | 1000      | 5500     | 35000   | 35000   |
| <b>loan_int_rate</b>              | 16.02    | 11.14     | 12.87    | 15.23   | 14.27   |
| <b>loan_status</b>                | 1        | 0         | 1        | 1       | 1       |
| <b>loan_percent_income</b>        | 0.59     | 0.1       | 0.57     | 0.53    | 0.55    |
| <b>cb_person_default_on_file</b>  | Y        | N         | N        | N       | Y       |
| <b>cb_person_cred_hist_length</b> | 3        | 2         | 3        | 2       | 4       |

*Джерело: [12]*

Загалом база даних містить 32581 спостережень та складається з 12 показників, 11 з яких слугуватимуть незалежними змінними, а `loan_status` буде відповідно залежною зі значеннями 0 та 1. Тобто, якщо позичальник не виконує свої зобов'язання, то інвестиція буде невдалою і позначається як 1. У протилежному випадку, якщо клієнт не допускає дефолту та клієнт зможе повернути суму, яку йому надали у вигляді кред, то бізнес буде успішним і `loan_status` позначається як 0.

Незалежні змінні (Табл.1):

- Person age: вік заявника на кредит у роках;
- Person home ownership: оренда, іпотека або власність;
- Cb person cred hist length: вимірюється в роках;
- Клас кредиту (Loan grade): A, B, C, D, E;

- Loan Intent: мета отримання кредиту;
- Applicant Income: рівень доходу заявника;
- Тривалість зайнятості (Employment length), вимірюється в роках;
- Loan Amount: запитувана сума кредиту (в тисячах);
- Interest rate: відсоткова ставка, що нараховується заявнику на кредит;
- Відсоток доходу від кредиту (loan percent income): вимірюється як відсоток;
- Наявність дефолту в особистій кредитній історії (Cb person default on file): Y або N, тобто так або ні.

Розгляньмо тепер деякі ознаки окремо, аби краще розуміти дані [13]. Виявляється, що найчастіше беруть кредит на навчання та медичні послуги й найменш часто – на ремонт оселі. При цьому лише 22% клієнтів не допускать дефолту, а 78% - допускать. Розподіл сум, які беруть у кредит, є правостороннім асиметричним ( $\text{mean} > \text{median}$ ) з невеликим викидом даних на позначці 35000. У цьому дослідженні ми проводимо попередню обробку даних шляхом заміни пропущених значень. Враховуючи числовий тип пропущених даних у наборі даних, для заповнення пропущених значень використовувалися середні значення. Також для тренування й тестування ділимо наш датасет на 2 частини: 80% даних беремо на тренування, а інші 20% - на тестування.

Щоб перевірити важливість кожної ознаки набору даних про кредитний ризик для продуктивності прогнозування, спочатку була створена модель RNN [14]. Структура моделі RNN, яка використовується для класифікації заявників на кредит, представлена на Рис. 1.

```

Model: "RNN модель"
Layer (type)                Output Shape                Param #
=====
input_33 (InputLayer)       [(None, 26, 1)]            0
simple_rnn_18 (SimpleRNN)    (None, 64)                 4224
dense_22 (Dense)            (None, 1)                  65
=====
Total params: 4289 (16.75 KB)
Trainable params: 4289 (16.75 KB)
Non-trainable params: 0 (0.00 Byte)

```

**Рис. 1. RNN модель, побудована за допомогою бібліотеки keras**

*Джерело: створено авторами*

На основі прогнозів моделі RNN та обчислення індексу Джині було здійснено вибір найважливіших ознак для подальшого дослідження (Табл. 2). Після встановлення порогу 0.1500 було виділено 8 з 11 ознак, які мають значний вплив на прогнозування статусу дефолту. Усунення менш релевантних ознак підвищує інтерпретованість набору ознак і покращує загальну ефективність системи.

**Таблиця 2. Індекс Джині для кожної ознаки**

| Ознака              | Індекс GINI | Ознака                          | Індекс GINI |
|---------------------|-------------|---------------------------------|-------------|
| Loan intent         | 0,1952      | Person home ownership           | 0,1536      |
| Person age          | 0,1783      | Loan interest rate              | 0,1501      |
| Person income       | 0,1753      | Cb person default on file       | 0,1486      |
| Loan amount         | 0,1675      | Person employment length        | 0,1425      |
| Loan percent income | 0,1669      | Cb person credit history length | 0,1215      |
| Loan grade          | 0,1639      |                                 |             |

*Джерело: створено авторами*

На другому етапі будується модель LSTM, шар якої складається з 64 нейронів (Рис. 2). Вихідний шар (dense) містить 1 нейрон. Також є 1 шар випадкового відсіву (dropout layer), який запобігає перенавчанню моделі. Для класифікації модель групує ймовірності від 0 до 0.5 в клас 1 і позначає їх як 0, якщо прогнозовані значення знаходяться між 0.5 і 1, вони групуються в

клас 2 і позначаються як 1. Щоб визначити точність моделі, використовується матриця плутанини з урахуванням помилки класифікації.

Model: "LSTM модель"

| Layer (type)                                 | Output Shape    | Param # |
|----------------------------------------------|-----------------|---------|
| input_34 (InputLayer)                        | [(None, 26, 1)] | 0       |
| lstm_13 (LSTM)                               | (None, 64)      | 16896   |
| dropout_12 (Dropout)                         | (None, 64)      | 0       |
| batch_normalization_12 (Batch Normalization) | (None, 64)      | 256     |
| dense_23 (Dense)                             | (None, 1)       | 65      |


=====  
Total params: 17217 (67.25 KB)  
Trainable params: 17089 (66.75 KB)  
Non-trainable params: 128 (512.00 Byte)

**Рис. 2. LSTM модель, побудована за допомогою бібліотеки keras**

*Джерело: створено авторами*

Гібридна ж модель RNN-LSTM складається з 3 шарів, функції активації tg та логістичної сигмоїдної функції. Вхідний шар складається з кількості ознак у датасеті. Прихований шар гібридної моделі RNN-LSTM складається з 64 нейронів, і є один щільний шар, який виконує роль вихідного шару і складається з 1 нейрона. Цей шар приймає всі значення з прихованого шару і групує їх у значення від 0 до 1, де поріг класифікації як дефолт (1) становить 0.5.

Насамперед, звернемо увагу на матрицю невідповідностей (Рис. 3), яка відображає результати навчання гібридної моделі RNN-LSTM. Ми можемо побачити, що модель успішно класифікувала 1991 позичальника як "поганих", в той час як 820 "поганих" позичальників були помилково визнані "добрими" (False-Negative). Також видно, що 3692 "добрих" позичальників були помилково визнані "поганими" (False-Positive).



**Рис. 3. Матриця невідповідностей гібридної моделі**

*Джерело: створено авторами*

Для оцінки результатів моделювання використаємо наступні метрики [11]:

□ Чутливість (Sensitivity або True Positive Rate): ця метрика показує, яка частка позитивних прикладів була правильно визнана моделлю. Формально вона визначається як кількість правильно визнаних позитивних випадків (True Positives) поділена на загальну кількість позитивних випадків, тобто True Positives плюс False Negatives. Вища чутливість вказує на більш ефективне визначення позитивних випадків.

□ Специфічність (Specificity або True Negative Rate): метрика показує, яка частка негативних прикладів була правильно визнана моделлю. Формально вона визначається як кількість правильно визнаних негативних випадків (True Negatives) поділена на загальну кількість негативних випадків,

тобто True Negatives плюс False Positives. Вища специфічність вказує на більш ефективно визначення негативних випадків.

□ Точність (Accuracy): дана метрика є однією з основних і показує загальну точність моделі, тобто відсоток правильно класифікованих прикладів серед усіх прикладів. Вона вимірює загальний успіх моделі у правильному визначенні класів. Однак вона може бути непоказною у випадках, коли класи не збалансовані.

□ F1-показник (F1-Score): є гармонічним середнім між показником точності і чутливістю. Вище значення F1-показника вказує на кращий баланс між точністю та чутливістю.

□ Площа під кривою ROC (AUC(ROC)) [15]: чим вище значення, тим краще працює класифікатор. Крім того, через його вищу стійкість порівняно з точністю, при оцінці ефективності моделей глибокого навчання даний показник служить більш придатною метрикою продуктивності, ніж точність.

Порівняння показників якості моделей RNN, LSTM та RNN-LSTM представлено в Табл. 3.

**Таблиця 3. Порівняння показників якості моделей**

|          | Sensitivity | Specificity | F1 Score | Accuracy | AUC (ROC) |
|----------|-------------|-------------|----------|----------|-----------|
| RNN      | 0,8060      | 0,9560      | 0,1469   | 0,7835   | 0,6166    |
| LSTM     | 0,8607      | 0,9601      | 0,5088   | 0,8107   | 0,6485    |
| RNN-LSTM | 0,8909      | 0,9607      | 0,6059   | 0,8269   | 0,6997    |

*Джерело: створено авторами*

Результати показують, що гібридна модель RNN-LSTM має кращі показники якості, порівняно з моделями RNN та LSTM. Наприклад, при перегляді F1-Score спостерігається поліпшення на 9,710% для гібридної моделі RNN-LSTM, порівняно з моделлю LSTM. Модель RNN показала найгірші результати. Всі три моделі виконують однакову роботу, але гібридна модель RNN-LSTM працює краще завдяки поєднанню переваг двох інших моделей. Точність була обчислена за допомогою матриці невідповідностей, при цьому гібридна модель RNN-LSTM досягла найкращої

точності зі значенням 82,69%, тоді як модель LSTM досягла точності 81,07%. Табл. 3 також наводить значення чутливості, причому гібридна модель RNN-LSTM має найвище значення чутливості, яке становить 0,8909. Як зазначалося раніше, чутливість вказує на рівень, на якому моделі визначають дійсні позитивні результати (тобто рівень, на якому модель класифікує позичальників, які сплачують позику). Крім того, чутливість відноситься до кількості клієнтів з фактичним позитивним результатом (True-Positive + False-Negative), які правильно класифіковані як позитивні (True-Positives).

Порівнюючи моделі за показником AUC(ROC), ми можемо зробити висновок, що гібридна модель RNN-LSTM має явну перевагу над іншими двома моделями. І, якщо це не так помітно за умовним показником точності, то показник AUC(ROC) чітко виділяє якість гібридної моделі, порівняно з найближчим її суперником – LSTM. Крім того, AUC(ROC) є стійким до дисбалансу класів, тому це вчергове доводить успішність роботи розробленої гібридної моделі.

### ***Висновки та перспективи подальших розвідок у даному напрямі.***

Метою проведення цього дослідження було визначити ефективність моделей RNN, LSTM та гібридної моделі RNN-LSTM при оцінці ознак невикплати позичальників. Для цього була розроблена гібридну модель RNN-LSTM та протестована на даних, отриманих з Kaggle. Модель RNN використовувалася для вибору ознак за допомогою індексу Джині. Модель LSTM використовувалася для класифікації позичальників на основі того, чи будуть вони не сплачувати платіж. Ця модель була обрана через її припущену ефективність зі змінними даними, оскільки вона розроблена для збереження важливих подій, відкидаючи менш значущі. Фактично модель повинна виконувати завдання бінарної класифікації, спрямоване на класифікацію кожного клієнта на основі їх історичних даних щодо того чи фінансово доцільно буде кредитувати того чи іншого позичальника.

Було показано, що нейромережі, які використовують гібридну модель RNN-LSTM, можуть досить точно класифікувати позичальників як тих, хто

не виплачуватимуть кредит. У процесі моделювання за допомогою побудови гібридної моделі була досягнута точність 0,8269. Навіть якщо цей результат далекий від ідеального, можна припустити, що вищу точність можна досягти за умови поліпшення вибору гіперпараметрів нейромережі, а також більш обережного огляду та маніпулювання набором даних. Гібридна модель RNN-LSTM працює виключно з даними щодо кредитного ризику, уникнувши необхідності додаткового вводу від клієнта. Відповідно, рішення про кредит можна приймати швидко, ідеально в режимі практичного часу, оскільки весь процес кредитного скорингу повністю автоматизований. Надалі планується розглянути спроможність розглянутих та інших гібридних методів машинного навчання у моделюванні кредитного ризику та дослідження стійкості моделі на різних базах даних.

### Література

1. Johnson, B. (2023), “Credit Scoring Models 101: Types and Examples for a Stronger Financial Future”, available at: <https://www.highradius.com/resources/Blog/credit-scoring-models-types-and-examples/> (Accessed 24 Nov 2024).
2. Investopedia: Is Credit Scoring? Purpose, Factors, and Role In Lending, (2023), available at: [https://www.investopedia.com/terms/c/credit\\_scoring.asp](https://www.investopedia.com/terms/c/credit_scoring.asp) (Accessed 15 Nov 2024).
3. Fishchuk, D.L., Rudnichenko, N.D. and Shybaiev, D.S. (2021), “Credit Risk Assessment Decision Support System”, *Zbirka dopovidej na Mizhnarodnij naukovo-praktychnij konferentsii International Scientific and Practical Conference “Information Control Systems and Technologies”* [Conference Proceedings of the International Scientific and Practical Conference], National University “Odessa Polytechnic”, Odesa, Ukraine, pp. 154-156, available at: <http://icst-conf.com/2021.pdf#page=153> (Accessed 12 Nov 2024).
4. Klimov, D. M. (2023), “Digitalization and the future of the banking system of Ukraine”, *Zbirka dopovidej na Mizhnarodnij naukovo-praktychnij konferentsii “Innovative Methods of Economic Management in the Context of Business Digitalization”* [Conference Proceedings of the International Scientific

and Practical Conference], MAUP, Kyiv, Ukraine, pp. 138-140, available at: [https://library.maup.com.ua/Naukovi\\_vydannya/Konf\\_Innov\\_metody\\_upravlinnya.pdf#page=139](https://library.maup.com.ua/Naukovi_vydannya/Konf_Innov_metody_upravlinnya.pdf#page=139) (Accessed 4 Dec 2024).

5. Datsko, M. and Druschak, N. (2022), “Credit scoring modelling using machine learning methods”, *Visnyk of the Lviv University. Series Economics*, vol. 63, pp. 56-66, DOI: <http://dx.doi.org/10.30970/ves.2022.63.0.6305>.

6. Shi, X., Chen, Z., Wang, H. and Yeung, D.-Y. (2015), “Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting”, available at: [https://proceedings.neurips.cc/paper\\_files/paper/2015/file/07563a3fe3bbe7e3ba84431ad9d055af-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2015/file/07563a3fe3bbe7e3ba84431ad9d055af-Paper.pdf) (Accessed 20 Jan 2025).

7. Marafioti, A., Perraudin, N., Holighaus, N. and Majdak, P. (2019), “Adversarial Generation of Time-Frequency Features with application in audio synthesis”, available at: <https://proceedings.mlr.press/v97/marafioti19a.html> (Accessed 18 Jan 2025).

8. Seo, M. and Kim, G. (2020), “Hybrid Forecasting Models Based on the Neural Networks for the Volatility of Bitcoin”, available at: <https://www.mdpi.com/2076-3417/10/14/4768> (Accessed 2 Oct 2024).

9. Sankar, S., Barfett, J., Colak, E. and Valaee, S. (2018), “Recent advances in recurrent neural networks”, available at: <https://arxiv.org/pdf/1801.01078.pdf> (Accessed 12 Nov 2024).

10. Olah, C. (2015), “Understanding LSTM Networks”, available at: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/> (Accessed 10 Nov 2024).

11. Liashenko, O., Kravets, T. and Kostovetskyi, Y. (2023), “Machine Learning and Data Balancing Methods for Bankruptcy Prediction”, *Ekonomika*, vol. 102(2), pp. 28–46. doi: 10.15388/.

12. Kaggle: credit risk dataset containing credit bureau data, available at: <https://www.kaggle.com/datasets/laotse/credit-risk-dataset/data> (Accessed 15 Nov 2024).

13. Matplotlib documentation, available at: <https://matplotlib.org/stable/gallery/index.html> (Accessed 23 Nov 2024).

14. Tensorflow: Working with RNN, available at: [https://www.tensorflow.org/guide/keras/working\\_with\\_rnn](https://www.tensorflow.org/guide/keras/working_with_rnn) (Accessed 12 Dec 2024).

15. Google developers: Classification: ROC Curve and AUC, available at: <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc> (Accessed 30 Nov 2024).

## References

1. Johnson, B. (2023), “Credit Scoring Models 101: Types and Examples for a Stronger Financial Future”, available at: <https://www.highradius.com/resources/Blog/credit-scoring-models-types-and-examples/> (Accessed 24 Nov 2024).

2. Investopedia (2023), “Is Credit Scoring? Purpose, Factors, and Role In Lending”, available at: [https://www.investopedia.com/terms/c/credit\\_scoring.asp](https://www.investopedia.com/terms/c/credit_scoring.asp) (Accessed 15 Nov 2024).

3. Fishchuk, D.L., Rudnichenko, N.D. and Shybaiev, D.S. (2021), “Credit Risk Assessment Decision Support System”, *Zbirka dopovidej na Mizhnarodnij naukovo-praktychnij konferentsii* [International Scientific and Practical Conference “Information Control Systems and Technologies”], National University “Odessa Polytechnic”, Odesa, Ukraine, pp. 154-156, available at: <http://icst-conf.com/2021.pdf#page=153> (Accessed 12 Nov 2024).

4. Klimov, D. M. (2023), “Digitalization and the future of the banking system of Ukraine”, *Zbirka dopovidej na Mizhnarodnij naukovo-praktychnij konferentsii* [“Innovative Methods of Economic Management in the Context of Business Digitalization” Conference Proceedings of the International Scientific and Practical Conference], MAUP, Kyiv, Ukraine, pp. 138–140, available at: [https://library.maup.com.ua/Naukovi\\_vydannya/Konf\\_Innov\\_metody\\_upravlinnya.pdf#page=139](https://library.maup.com.ua/Naukovi_vydannya/Konf_Innov_metody_upravlinnya.pdf#page=139) (Accessed 4 Dec 2024).

5. Datsko, M. and Druschak, N. (2022), “Credit scoring modelling using machine learning methods”, *Visnyk of the Lviv University. Series Economics*, vol. 63, pp. 56-66, DOI: <http://dx.doi.org/10.30970/ves.2022.63.0.6305>.

6. Shi, X., Chen, Z., Wang, H. and Yeung, D.-Y. (2015), “Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting”,

available at:  
[https://proceedings.neurips.cc/paper\\_files/paper/2015/file/07563a3fe3bbe7e3ba84431ad9d055af-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2015/file/07563a3fe3bbe7e3ba84431ad9d055af-Paper.pdf) (Accessed 20 Jan 2025).

7. Marafioti, A., Perraudin, N., Holighaus, N. and Majdak, P. (2019), “Adversarial Generation of Time-Frequency Features with application in audio synthesis”, available at: <https://proceedings.mlr.press/v97/marafioti19a.html> (Accessed 18 Jan 2025).

8. Seo, M. and Kim, G. (2020), “Hybrid Forecasting Models Based on the Neural Networks for the Volatility of Bitcoin”, available at: <https://www.mdpi.com/2076-3417/10/14/4768> (Accessed 2 Oct 2024).

9. Sankar, S., Barfett, J., Colak, E. and Valaee, S. (2018), “Recent advances in recurrent neural networks”, available at: <https://arxiv.org/pdf/1801.01078.pdf> (Accessed 12 Nov 2024).

10. Olah, C. (2015), “Understanding LSTM Networks”, available at: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/> (Accessed 10 Nov 2024).

11. Liashenko, O., Kravets, T. and Kostovetskyi, Y. (2023), “Machine Learning and Data Balancing Methods for Bankruptcy Prediction”, *Ekonomika*, vol. 102(2), pp. 28-46. doi: 10.15388/.

12. Kaggle (2024), “Credit risk dataset containing credit bureau data”, available at: <https://www.kaggle.com/datasets/laotse/credit-risk-dataset/data> (Accessed 15 Nov 2024).

13. Matplotlib documentation (2024), available at: <https://matplotlib.org/stable/gallery/index.html> (Accessed 23 Nov 2024).

14. Tensorflow (2024), “Working with RNN”, available at: [https://www.tensorflow.org/guide/keras/working\\_with\\_rnn](https://www.tensorflow.org/guide/keras/working_with_rnn) (Accessed 12 Dec 2024).

15. Google developers (2024), “Classification: ROC Curve and AUC”, available at: <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc> (Accessed 30 Nov 2024).

*Стаття надійшла до редакції 31.03.2025 р.*