

<https://doi.org/10.31891/2307-5732-2026-365-46>
УДК 004.85:336.76

РУДНІЧЕНКО МИКОЛА

Національний університет «Одеська політехніка»
<https://orcid.org/0000-0002-7343-8076>
e-mail: nickolay.rud@gmail.com

ШВЕДОВ ДЕНИС

Національний університет «Одеська політехніка»
<https://orcid.org/0009-0002-4823-8782>
e-mail: studylearnerstudy@gmail.com

МЕТОД БАГАТОВИМІРНОЇ ОЦІНКИ ФІНАНСОВИХ РИЗИКІВ НА ОСНОВІ ГІБРИДНОГО ГЛИБИННОГО НАВЧАННЯ

У статті розглянуто проблему комплексної оцінки фінансових ризиків інвесторів в умовах зростаючої динамічності та невизначеності фінансових ринків. Обґрунтовано доцільність використання сучасних підходів глибокого навчання для інтелектуального аналізу ризикових факторів, що формуються під впливом взаємодії фінансових, макроекономічних та поведінкових чинників. Запропоновано метод багатовимірної оцінки фінансових ризиків на основі гібридних моделей глибокого навчання, який інтегрує механізми формування узгодженого простору фінансових ознак, побудову латентних представлень ризикових факторів та прогнозування їх динаміки. Метод орієнтований на поєднання різних архітектур нейронних мереж із метою більш повного відображення часових, структурних та контекстних характеристик фінансових даних. У роботі розкрито концептуальні засади формування інтегрального показника фінансового ризику інвестора, який узагальнює результати багатовимірного аналізу та прогнозування ризикових факторів. Запропонований підхід передбачає адаптивне налаштування параметрів моделей глибокого навчання з урахуванням змін фінансового середовища, що забезпечує стійкість оцінювання та підвищення його прогностичної цінності. Отримані результати підтверджують перспективність застосування гібридних моделей глибокого навчання для інтелектуального аналізу фінансових ризиків, оскільки вони забезпечують більш повне врахування взаємозв'язків між фінансовими показниками та зовнішніми економічними чинниками.

Ключові слова: оцінка фінансових ризиків, гібридні моделі, глибоке навчання, інтелектуальний аналіз даних, багатовимірні великі дані.

RUDNICHENKO MYKOLA, SHVEDOV DENYS

Cherkassy State Technological University

MULTIDIMENSIONAL FINANCIAL RISK ASSESSMENT METHOD BASED ON HYBRID DEEP LEARNING

This article addresses the challenge of providing a comprehensive assessment of financial risks for investors within the context of increasing dynamism and uncertainty in financial markets. The study substantiates the feasibility of employing advanced deep learning approaches for the intelligent analysis of risk factors emerging from the interplay of financial, macroeconomic, and behavioral drivers. It is demonstrated that traditional statistical and econometric models often fail to adequately capture the complex non-linear structure of financial processes, highlighting the urgent need for new methods focused on multidimensional data analysis and adaptive environmental responsiveness.

The authors propose a method for the multidimensional assessment of investors' financial risks based on hybrid deep learning models. This method integrates mechanisms for forming a consistent financial feature space, constructing latent representations of risk factors, and forecasting their dynamics. The approach is designed to combine diverse neural network architectures to more comprehensively reflect the temporal, structural, and contextual characteristics of financial data. Particular emphasis is placed on the integration of macroeconomic indicators and market conditions, which enhances the information density of the models and ensures a more realistic interpretation of risk processes.

The paper delineates the conceptual foundations for developing an integral financial risk indicator that synthesizes the results of multidimensional analysis and risk factor forecasting. The proposed approach facilitates adaptive parameter tuning of deep learning models in response to shifts in the financial environment, ensuring robust estimation and increased predictive value. Furthermore, the article details the algorithmic aspects of the method's implementation, establishing a framework for subsequent software development and experimental validation. The findings confirm the promise of hybrid deep learning models for the intelligent analysis of financial risks, as they provide a more holistic account of the interdependencies between financial metrics and external economic factors.

Keywords: financial risk assessment, hybrid models, deep learning, data mining, multidimensional big data.

Стаття надійшла до редакції / Received 11.02.2026

Прийнята до друку / Accepted 11.03.2026

Опубліковано / Published 28.05.2026



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/)

© Рудніченко Микола, Шведов Денис

Вступ

Фінансові ринки у сучасних умовах характеризуються високим рівнем динамічності, складністю взаємозв'язків між учасниками та значною невизначеністю, що безпосередньо впливає на процеси прийняття інвестиційних рішень в різних сферах економіки. Проблематика адекватної оцінки ризиків у сфері інвестицій набула особливої актуальності внаслідок зростання обсягів даних, їх багатовимірності та неоднорідності. Через це все більше ускладнюються виклики, які постають перед сучасними інвесторами, що пов'язані не лише з необхідністю прогнозування поведінки активів, але й із потребою врахування макроекономічних факторів, геополітичної ситуації, змін у регуляторному середовищі та психологічних аспектів поведінки ринку [1].

Слід зазначити, що складність і неоднозначність процесу прийняття інвестиційних рішень досить часто

обумовлені низкою складно формалізованих чинників. Фінансові ризики мають багаторівневу природу, оскільки вони можуть виникати на мікрорівні у вигляді специфічних характеристик компанії-емітента, на мезорівні у формі галузевих коливань, а також на макрорівні у зв'язку зі змінами глобальних економічних трендів. Традиційні статистичні методи, засновані на припущенні стаціонарності даних і лінійності залежностей, виявляються недостатніми для моделювання таких складних процесів. Це зумовлює інтенсивний розвиток методів, що застосовують в своєму контексті елементи штучного інтелекту (ШІ), інтелектуального аналізу даних (ІАД) та глибинного навчання (ГН), які дозволяють автоматизувати аналіз великих обсягів різномірних даних, визначити приховані в них шаблони та інтегрувати різноструктуровані джерела даних, в результаті чого з'являється можливість формування комплексних прогностичних моделей, зокрема штучний нейронних мереж (ШНМ), здатних урахувати різні рівні ризику в багатовимірному просторі станів [2].

Важливим фактором в рамках аналізу проблематики оцінки інвестиційних ризиків є саме проблема багатовимірності сценаріїв інвестиційного розвитку, оскільки інвестор повинен враховувати одночасно велику кількість факторів, що мають як кількісну, так і якісну природу. До таких факторів можуть належати як обчислювальні фінансові показники компаній, зокрема макроекономічні індикатори, показники ринкових індексів, корпоративні новини та інші [3]. Не менш важливою проблемою цільової інвестиційної аналітики в нас час є необхідність автоматизації обробки великих обсягів операційних даних, які щоденно змінюються та постійно зростають [4].

Фінансові ринки генерують терабайти інформації щодня, і ефективна робота з такими масивами даних стає можливою завдяки ефективному застосуванню різних моделей ГН з високим рівнем паралелізації обчислень [5].

Всі означені аспекти при їх комплексному аналізі формують змістовну потребу у розробці нових методів аналізу, здатних поєднувати багатовимірність даних з можливостями сучасних методів ШІ, насамперед алгоритмів ІАД та моделей ГН, що, в свою чергу, обумовлює актуальність досліджень у цій галузі.

Аналіз проблематики, досліджень та публікацій

Сучасні дослідження з ІАД у сфері оцінки та прогнозування фінансових ризиків демонструють стійке зміщення від класичних економетричних моделей до методів машинного навчання (МН) та ГН. Така тенденція зумовлена зростанням складності фінансових систем, багатовимірністю інформаційних потоків і необхідністю оперативного прогнозування ризиків в умовах високої ринкової волатильності. Особливого значення набувають гібридні нейромережеві архітектури, здатні інтегрувати різномірні дані та виявляти нелінійні закономірності фінансових процесів.

Виконуючи аналіз праць сучасних авторів в рамках релевантних тематик досліджень слід відмітити різні відмінності у шляхах адаптації МН та ГН для завдань оцінки та аналізу інвестиційних та фінансових ризиків. Наприклад, у роботі [6] запропоновано ієрархічну модель ГН з механізмом уваги для раннього попередження фінансових ризиків підприємств. Показано підвищення точності прогнозування порівняно зі статистичними та класичними МН підходами. Недоліком запропонованого підходу є обмежена інтерпретованість результатів та слабка адаптивність до індивідуального профілю інвестора. Автори [7] поєднують фінансові показники з текстовими даними звітності за допомогою BiLSTM з механізмом уваги. Водночас обмеженням виступає фокус на корпоративних ризиках без урахування макроекономічної динаміки, що знижує гнучкість застосування розроблених моделей на практиці в нестабільному інвестиційному кліматі.

Дослідниками в роботі [8] в рамках розробленого підходу запропоновано модифіковану глибинну ШНМ з алгоритмом зворотного поширення помилки для прогнозування фінансових дисбалансів. Метод демонструє високу точність, однак залишається чутливим до якості вхідних даних і має обмежену здатність до роботи з високорозмірними часовими рядами. Близькі результати також отримано у [9], де застосовано комбінований підхід згорткових ШНМ для аналізу фінансових показників різних типів підприємств. Перевагою є автоматичне виділення ознак, проте модель недостатньо враховує часові залежності ризикових процесів та не є достатньо адаптивною. У інших роботах, зокрема [10, 11] автори використовують прогнозування на базі ГН та CVaR для оптимізації портфеля та пропонують комбіноване застосування моделей ШНМ і статистичних економічних даних для кількісної оцінки інвестиційного ризику. Метод ефективно оцінює хвостові ризики, але обмежений стабільністю прогнозів при структурних зламах ринку, не беручи до уваги багатомірність ознак, у тому числі проблеми даних підходять полягають у відсутності механізмів багаторівневої інтеграції макрофакторів та поведінкових характеристик інвесторів.

Дослідження [12, 13] сфокусовані на ансамблевих підходах, що поєднують застосування моделей випадкового лісу та адаптивних моделей ГН для прогнозування фінансової нестабільності. Особливістю є запропонована інтеграція LSTM та CNN з портфельними моделями різного ризикового профілю. Недоліком у даному випадку є слабка універсальність при використанні різних класів активів, що є критичним для інвестиційних очікувань. Слід також відмітити доцільність ризик-орієнтованого підходу, зокрема, авторами [14, 15] запропоновано цікаву концепцію гібридної CNN-LSTM модель для ризик-прогнозування. Реалізація методу демонструє покращену здатність враховувати часові та просторові закономірності, але складність навчання та потреба у великих обсягах даних обмежують практичне застосування.

Таким чином, слід зазначити, що на базі узагальнення сучасних досліджень можна відмітити значний потенціал застосування гібридних моделей ГН для оцінки фінансових ризиків, однак більшість підходів залишаються вузькоспеціалізованими та недостатньо адаптивними до багатовимірного характеру ризикових процесів. Це обґрунтовує актуальність розробки комплексного методу багатовимірної оцінки фінансових ризиків

на основі гібридних моделей ГН, що має бути спрямований на подолання зазначених обмежень шляхом інтеграції багатовимірних даних та комбінованого впровадження адаптивності нейромережових архітектур.

Мета дослідження

Метою роботи є: розроблення методу багатовимірної оцінки фінансових ризиків на основі гібридних моделей глибинного навчання, здатного забезпечити підвищену точність прогнозування ризикових індикаторів та адаптивність до змін фінансового середовища.

Пропонований концептуальний базис методу

Запропонований метод багатовимірної оцінки фінансових ризиків розглядається як складова концепції застосування гібридних моделей ГН для інтелектуального аналізу фінансових ризиків [16]. Його сутність полягає у поєднанні механізмів глибинного представлення даних, стохастичного моделювання фінансових процесів та інтегральної багатокритеріальної оцінки ризику на основі латентних факторів, отриманих ШНМ [17]. В контексті запропонованої концепції [18] ризик інвестиційної діяльності розглядається як функція очікуваної доходності, волатильності, ліквідності та системних факторів ринку. Формалізація прихованих факторів ризику базується на положеннях багатовимірної статистики та теорії латентних змінних. Виявлення нелінійних залежностей між факторами ризику пропонується здійснювати на основі моделей ГН в контексті ансамблевого навчання, зокрема з розробкою та використанням рекурентних ШНМ, автоенкодерів та механізмів уваги. Концептуальна діаграма формалізації запропонованого методу наведена на рис.1.

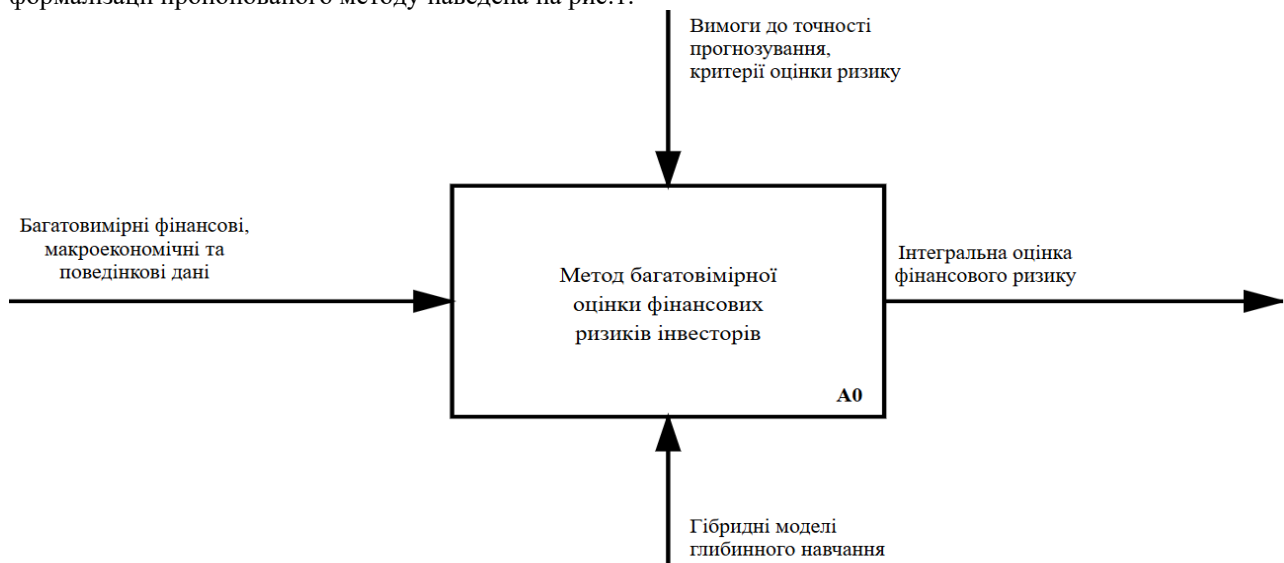


Рис. 1. Концептуальна діаграма формалізації запропонованого методу

Метод може бути декомпозований на наступну сукупність послідовних стадій:

1. Формування багатовимірного фінансового простору ознак. Це передбачає системну інтеграцію ринкових, макроекономічних та поведінкових показників, які є релевантними для інвесторів у єдину узгоджену структуру. На цьому етапі здійснюється обробка даних із урахуванням їх статистичних властивостей, часової узгодженості та взаємної кореляції. Особлива увага приділяється усуненню шумових компонент, нормалізації масштабів і синхронізації часових рядів, що забезпечує коректність подальшого аналізу.

2. Побудова латентного представлення ризикових факторів за допомогою комбінованої моделі ГН. Даний процес спрямовано на виявлення прихованих закономірностей у багатовимірних фінансових даних. Поєднання механізмів автоматичного виділення ознак із моделями часової динаміки дозволяє одночасно враховувати структурні залежності та інерційність фінансових процесів. У результаті формується компактний простір латентних факторів, який відображає ключові джерела ризику без надлишкової інформації.

3. Прогнозування динаміки ризикових індикаторів. Даний етап ґрунтується на використанні латентних факторів як узагальнених описів фінансового середовища. Модель враховує часові закономірності зміни ризиків і дозволяє виявляти потенційні тенденції у вихідних даних. Прогнозні оцінки формуються з урахуванням як історичної поведінки активів, так і їх поточного структурного стану.

4. Інтегральна оцінка фінансового ризику, базується на поєднанні різних складових ризику, що відображають волатильність, потенційні втрати та системні впливи ринку. Така інтеграція дозволяє перейти від фрагментарних показників до цілісної характеристики ризикового профілю інвестиційної діяльності. При цьому враховується динамічна зміна значущості окремих факторів залежно від економічної ситуації.

5. Адаптивна оптимізація параметрів моделі ГН, що забезпечує її здатність коректним чином реагувати на зміну ринкових умов і структури фінансових даних. Оптимізаційна процедура враховує одночасно якість відтворення латентних факторів, точність прогнозування та стабільність інтегральної оцінки ризику. Використання адаптивних алгоритмів навчання дозволяє автоматично коригувати параметри моделі без втручання експерта.

Математична формалізація методу

Порядок формування матриці фінансових спостережень виконується на базі виразу:

$$X = \{x_i(t)\}, i = 1..N, t = 1..T, \tag{1}$$

де $x_i(t)$ означає значення i -го фінансового показника у момент часу t , N є кількістю показників, T є довжиною часової вибірки. До складу ознак можуть входити доходності активів, показники волатильності, макроекономічні індикатори, індекси ринкових настроїв, показники ліквідності та інші характеристики інвестиційного середовища. Для усунення масштабних ефектів здійснюється нормалізація, зокрема:

$$x_i(t) = \frac{(x_i(t) - \mu_i)}{\sigma_i}, \tag{2}$$

де μ_i є середнім значенням i -го показника, σ_i є стандартним відхиленням цього показника.

Для побудови латентного простору факторів ризику пропонується використовувати гібридну архітектуру моделі ГН на базі автоенкодера з рекурентними шарами. Кодувальна частина мережі формує відображення на базі формули:

$$z(t) = f_{enc}(x(t), \theta), \tag{3}$$

де $z(t)$ є вектором латентних факторів у момент часу t , f_{enc} є функцією кодування, θ є параметрами мережі. θ інтерпретується як сукупність усіх настроюваних параметрів кодувальної частини гібридної архітектури ГН, що формує латентне представлення фінансових даних. Структурно включає вагові матриці лінійних перетворень, параметри згорткових або щільнозв'язаних шарів, коефіцієнти нормалізації, а також параметри механізмів регуляризації. Декодувальна частина відновлює початкові дані у відповідності з:

$$x_{hat}(t) = f_{dec}(z(t), \psi), \tag{4}$$

де ψ є сукупність параметрів рекурентного модуля моделі, який відповідає за відображення часової динаміки ризикових факторів. У випадку використання LSTM або GRU архітектур включає матриці переходів прихованих станів, вагові коефіцієнти вхідних, забувальних і вихідних шлюзів, а також відповідні вектори зміщень. Функція втрат автоенкодера визначається як:

$$L_{rec} = \frac{1}{T} \sum_t |x(t) - x_{hat}(t)|^2, \tag{5}$$

що забезпечує мінімізацію помилки реконструкції та формування інформативного латентного представлення. Для врахування часової залежності використовується рекурентний блок типу LSTM або GRU, який формує послідовність прихованих станів:

$$h(t) = g\{z(t), h(t-1), \psi\}, \tag{6}$$

де $h(t)$ є прихованим станом, ψ є параметрами рекурентної мережі.

Прогнозування ризикових індикаторів виконується на базі наступної функції:

$$y(t+1) = W * h(t) + \bar{b}, \tag{7}$$

де y_{t+1} є прогнозованим значенням ризикового індикатора, W є матрицею ваг, \bar{b} є вектором зміщення. Як цільові змінні можуть виступати показники волатильності портфеля, кредитного ризику або інтегрального ринкового ризику. Функція втрат прогнозованої частини визначається як:

$$L_{pred} = \frac{1}{T} \sum_t |y(t+1) - y_{hat}(t+1)|^2, \tag{8}$$

де $y_{hat}(t+1)$ є фактичним значенням показника. Для формування інтегральної оцінки ризику доцільно використання узагальненої функції ризику по 3 окремих релевантних складових, зокрема:

$$R = \alpha \cdot R_{vol} + \beta \cdot R_{loss} + \gamma \cdot R_{sys}, \tag{9}$$

де R є інтегральним ризиком, R_{vol} є ризиком волатильності, R_{loss} є ризиком очікуваних втрат, R_{sys} є системним ризиком, α, β, γ є ваговими коефіцієнтами. Ризик волатильності визначається як:

$$R_{vol} = \sqrt{V_{ar}(y(t))}, \tag{10}$$

де V_{ar} означає дисперсію прогнозованої доходності.

Ризик очікуваних втрат оцінюється через узагальнений Expected Shortfall:

$$R_{loss} = E[y(t) | y(t) < q_\alpha], \tag{11}$$

де q_α є квантилем розподілу доходності на рівні α .

Системний ризик визначається на основі латентних факторів за виразом:

$$R_{sys} = \frac{|z(t)|^2}{k}, \tag{12}$$

де k є розмірністю латентного простору, що визначає кількість прихованих факторів ризику, які модель здатна виділити з багатовимірного фінансового середовища. Вибір k не є довільним і обґрунтовується статистичними та економічними міркуваннями. Надмірне збільшення k може призвести до перенавчання моделі і втрати узагальнювальної здатності, занадто мала розмірність спричиняє втрату суттєвої інформації про структуру ризиків. Пропонується визначати k через аналіз сингулярного спектра матриці ознак, критерії інформаційної достатності та процедури валідації на відкладених вибірках. У фінансовому контексті типовими факторами для цього можуть виступати загальний ринковий ризик, галузеві фактори, ліквідність, інфляційні очікування та глобальні макроекономічні тенденції. Оптимізація параметрів моделі здійснюється шляхом мінімізації комбінованої функції втрат, яка має вигляд:

$$L_{total} = \lambda_1 \cdot L_{rec} + \lambda_2 \cdot L_{pred} + \lambda_3 \cdot R, \tag{13}$$

де $\lambda_1, \lambda_2, \lambda_3$ є коефіцієнтами регуляризації. Мінімізація виконується методом стохастичного градієнтного спуску або його адаптивних модифікацій, зокрема Adam чи RMSProp. Такий підхід забезпечує одночасну

оптимізацію як якості латентного представлення, так і точності прогнозування ризику. Важливою складовою методу є механізм адаптивної вагової корекції, який дозволяє змінювати коефіцієнти α, β, χ залежно від ринкових умов. Це реалізується через функцію:

$$a(t) = \text{soft max}(\overline{u(t)}), \quad (14)$$

де $\overline{u(t)}$ є вектором параметрів, що визначається допоміжною ШНМ. Даний вектор використовується для адаптивного визначення вагових коефіцієнтів інтегральної ризикової функції та визначає пріоритетність окремих компонент ризику залежно від поточної макроекономічної ситуації та ринкової кон'юнктури.

До складу макроекономічних факторів пропонується включати показники, які емпірично довели значущий вплив на фінансові ризики. Насамперед це темпи інфляції, які визначають реальну дохідність інвестицій і впливають на вартість капіталу.

Допоміжна ШНМ формує нелінійне відображення описаних вище факторів, що дозволяє враховувати складні взаємозалежності, наприклад одночасний вплив інфляції та процентних ставок на ринкову ліквідність або взаємозв'язок між валютними коливаннями та фондовими індексами. Технічно реалізується як багаточасова перцептронна або рекурентна архітектура невеликої глибини, оскільки макроекономічні показники мають нижчу частоту оновлення порівняно з фінансовими часовими рядами.

Результати експериментальних досліджень та їх аналіз

Експериментальне дослідження організоване у формі порівняльного моделювання, у межах якого реалізація запропонованого методу використовується для створення гібридної моделі ГН, яка зіставляється з базовими підходами, релевантними до тематики оцінки інвестиційних ризиків, зокрема, з класичними рекурентними ШНМ, ансамблевими методами МН. Це дозволяє оцінити не лише абсолютну ефективність методу, але й його переваги щодо стабільності прогнозів, адаптивності до макроекономічних змін і здатності працювати з багатовимірними даними. Зокрема, порівняльне дослідження проводиться із застосуванням LSTM без автоенкодера, модель Random Forest, градієнтний бустинг та статистичну модель GARCH.

Складність підбору релевантного датасету для оцінки інвестиційних ризиків зумовлена специфікою поєднання ринкових показників із макроекономічними індикаторами, що рідко зустрічається в межах єдиного готового ресурсу. Для проведення якісного експерименту науковий інтерес становлять такі набори даних як JPX Tokyo Stock Exchange Prediction та Jane Street Market Prediction для аналізу мікроструктури ринку, а також G-Research Crypto Forecasting та дані системи FRED для врахування високої волатильності та глобальних економічних циклів, але ці датасети містять лише часткові фрагменти корисних даних та не є вичерпними. У зв'язку з цим постає необхідність агрегації таких розрізнених джерел, що зумовлено вимогою формування багатовимірного вхідного тензора, який забезпечує всебічне охоплення чинників впливу на фінансову стабільність з точки зору оцінки ризиків.

З метою подолання проблеми дисбалансу та обмеженості вибірки екстремальних ризикових подій критично важливим є послідовне застосування трьох етапів синтетичної обробки, що включає SMOTE для попереднього вирівнювання, SMOGN для генерації рідкісних значень у регресійних задачах та метод Latent Space Augmentation для створення нових сценаріїв у латентному просторі автоенкодера. Такий комплексний підхід до формування даних дозволяє досягти високої репрезентативності синтетичного датасету та гарантує стійкість гібридної нейромережевої моделі під час її апробації в умовах реальної ринкової турбулентності.

Таким чином, формування експериментального датасету передбачає інтеграцію та синтетичну генерацію кількох груп фінансових та макроекономічних показників. До першої групи входять ринкові характеристики активів, зокрема щоденні доходності акцій або портфельних індексів, історична волатильність, обсяг торгів, спред між ціною купівлі та продажу, а також технічні індикатори, наприклад ковзні середні, RSI та індекс волатильності. Друга група містить макроекономічні фактори, серед яких інфляція, облікова ставка центрального банку, темпи зростання ВВП, рівень безробіття, індекси ділової активності та валютні курси резервних валют. Третя група включає індикатори системного ризику, такі як глобальні фондові індекси, ціни на енергоресурси та індекси фінансового стресу.

Структура збалансованого датасету в загальному виді: Feature 1–20, ринкові фінансові індикатори доходності, волатильності, ліквідності, кредитного ризику; Feature 21–40, макроекономічні фактори інфляція, процентні ставки, валютні індекси, індикатори економічної активності; Feature 41–60, поведінкові та портфельні характеристики інвестора структура активів, частота операцій, інвестиційний горизонт; Feature 61, інтегральний фінансовий обсяг портфеля; Risk, безперервний інтегральний показник ризику.

Агреговано вибірку на 50 тисяч часових записів, яка синтетично розширена до 300000 записів та відповідає інтервалу у 5–10 років щоденних даних. Кількість ознак становить від 61 показник, забезпечено рівномірне представлення періодів високої та низької волатильності.

Архітектура запропонованої моделі ГН реалізується як гібридна нейромережева система з декількома функціональними блоками. Загальна схема архітектури побудованої гібридної моделі ГН наведена на рис.2. Перед створення моделі агрегований набір даних збалансований за цільовими класами та розподілений на навчальну, валідаційну і тестову підвибіркі у пропорції приблизно 70–15–15 із випадковою стратифікацією для збереження статистичних характеристик. Для підвищення надійності оцінювання застосовувалась k-кратна кросвалідація ($k = 5$), що дозволило мінімізувати вплив випадкових флуктуацій даних на результати моделювання. Перед навчанням виконувались нормалізація числових ознак, усунення пропусків та контроль мультиколінеарності предикторів. Після проведення процесу обробки та нормалізації даних наступний блок виконує роль

автоенкодера для формування латентного представлення фінансових факторів. Загальна структура включає вхідний шар із кількістю нейронів, що дорівнює числу ознак, два прихованих шари розмірності 128 і 64 нейрони та латентний шар розмірності 16–32 нейрони. У якості функцій активації використовуються ReLU та GELU, регуляризацию реалізовано через dropout із коефіцієнтом близько 0,2.

Третій блок призначений для моделювання часової динаміки ризиків. Використано двошарову LSTM та GRU мережи з 64 і 32 нейронами відповідно. Довжина часової послідовності зазвичай становить від 20 до 60 кроків, що відповідає приблизно одному–трьом місяцям ринкових даних. Така конфігурація дозволяє враховувати середньострокову динаміку фінансових ризиків. Останній блок реалізує інтегральну оцінку ризику з адаптивним корегуванням ваг. Він складається з двох повнзв'язаних шарів з невеликою кількістю нейронів і вихідного шару регресії, функцією активації є softmax.

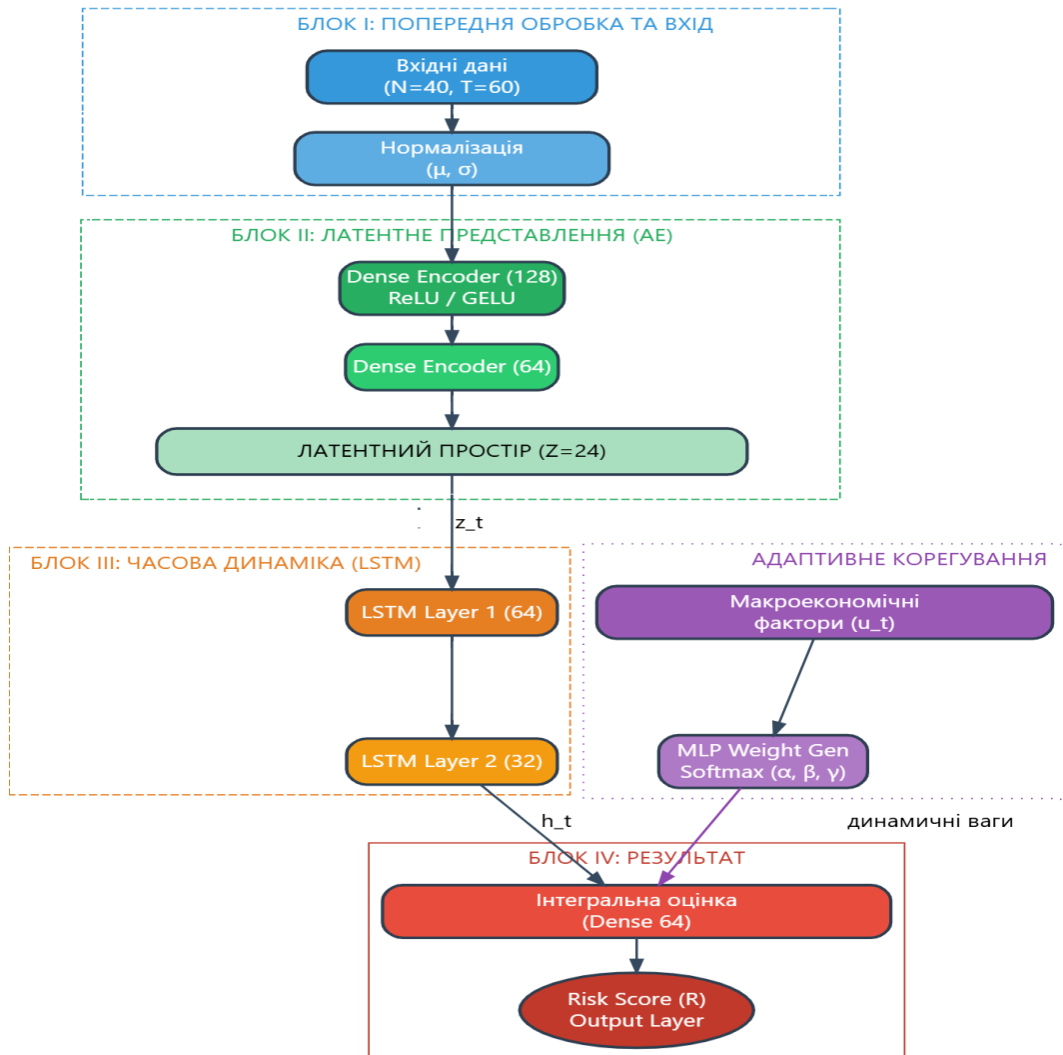


Рис. 2. Концептуальна діаграма формалізації запропонованого методу

Допоміжна модель ШНМ для адаптивного визначення ваг ризикових компонент реалізована як багатошаровий перцептрон з двома шарами по 32 нейрони, що отримує на вході агреговані макроекономічні показники. Вихід цієї моделі використовується для динамічного коригування ваг інтегральної функції ризику. Навчання моделі ГН здійснюється із застосуванням оптимізатора Adam зі стартовою швидкістю навчання приблизно 0,001. Розмір мінібатчу може становити 64 або 128 спостережень. Кількість епох навчання зазвичай знаходиться у межах 50–150 з алежно від складності датасету. Для запобігання перенавчанню доцільно застосовувати ранню зупинку та L2 регуляризацию.

Динаміка оцінки метрики MSE створеної гібридної моделі ГН на навчальній та валідаційній вибірках наведена на рис.3. На представленому графіку динаміки функції втрат під час навчання гібридної моделі простежується стійка тенденція до зменшення похибки як на навчальній, так і на валідаційній вибірках, що свідчить про адекватність архітектури моделі та коректність налаштування її гіперпараметрів. Початкові значення MSE перебувають на рівні приблизно 0.10–0.12, однак уже після перших 20–30 епох спостерігається істотне зниження до діапазону 0.03–0.05, що відображає швидке засвоєння моделлю закономірностей даних.

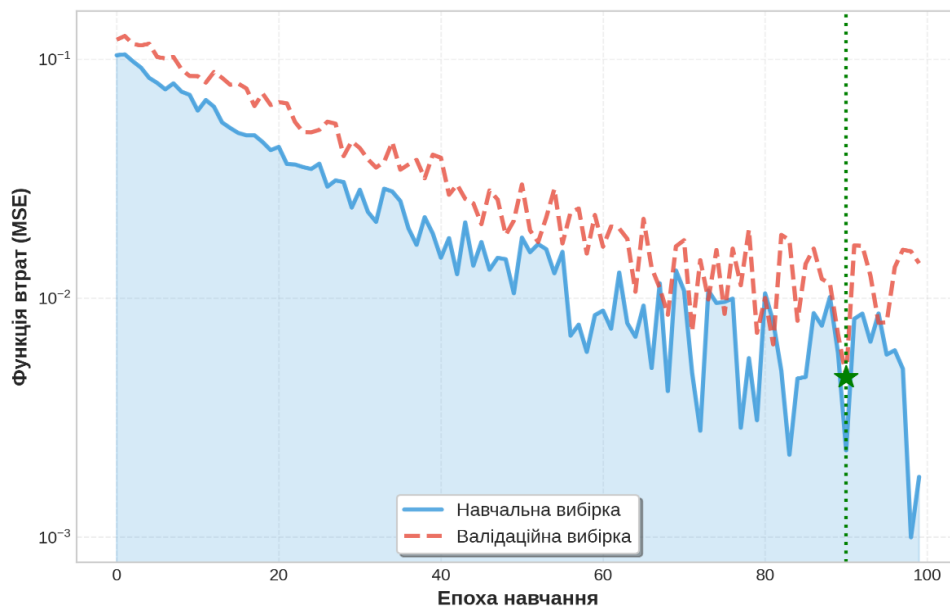


Рис. 3. Динаміка оцінки метрики MSE створеної гібридної моделі ГН

Подальше навчання характеризується поступовою стабілізацією функції втрат із незначними флуктуаціями, типовими для складних стохастичних оптимізаційних процедур. На завершальних етапах навчання значення MSE на навчальній вибірці досягає приблизно 0.005–0.007 із локальними мінімумами близько 0.003, тоді як на валідаційній вибірці воно стабілізується в межах 0.01–0.015. Така різниця між тренувальною та тестовою похибками є відносно невеликою, що свідчить про відсутність вираженого перенавчання та достатню узагальнювальну здатність моделі.

Висновки та перспективи

В рамках даної роботи розглянуто результати розробки метод багатовимірної оцінки фінансових ризиків на основі гібридних моделей глибинного навчання, який забезпечує узгоджене врахування різномірних фінансових та макроекономічних факторів і підвищує точність прогнозування ризикових індикаторів. Експериментальні дослідження продемонстрували стабільне зниження похибок прогнозування та покращення інтегральних метрик якості порівняно з базовими моделями, що підтверджує ефективність запропонованого підходу. Отримані результати свідчать про здатність методу адаптивно реагувати на зміну ринкових умов та забезпечувати більш надійну оцінку інвестиційних ризиків у динамічних середовищах.

Таким чином, запропонований метод багатовимірної оцінки фінансових ризиків на основі глибинного навчання є актуальним та апробованим на прикладі практичного завдання та дозволяє подолати обмеження традиційних методів аналізу, інтегрувати дані різної структури, виділяти фактори впливу та забезпечувати адаптивність моделей до динамічних умов ринку. Перспективність такого підходу полягає у можливості його використання для побудови систем інтелектуальної підтримки прийняття рішень, які підвищують надійність прогнозування та мінімізують інвестиційні ризики у середовищі з високим рівнем невизначеності.

Література

1. Jiang C. Deep learning-based risk assessment model for financial decision-making / C. Jiang, H. Liu, L. Zhao // *Expert Systems with Applications*. – 2023. – Vol. 228. – P. 120–138. – DOI: <https://doi.org/10.1016/j.eswa.2023.120138>.
2. Zhang S. A deep learning framework for multi-source financial risk prediction / S. Zhang, J. Wu, Y. Lin // *Knowledge-Based Systems*. – 2023. – Vol. 261. – P. 110–125. – DOI: <https://doi.org/10.1016/j.knsys.2023.110125>.
3. Li T. Hybrid transformer–LSTM model for financial risk analysis with heterogeneous data / T. Li, M. Chen // *Information Sciences*. – 2024. – Vol. 634. – P. 51–70. – DOI: <https://doi.org/10.1016/j.ins.2023.11.024>.
4. Wang X. Cross-modal deep learning for comprehensive financial risk evaluation / X. Wang, Z. Huang // *Neurocomputing*. – 2023. – Vol. 556. – P. 341–356. – DOI: <https://doi.org/10.1016/j.neucom.2023.04.112>.
5. Yu L. Investor behavior prediction using multi-dimensional deep neural networks / L. Yu, H. Yang // *Applied Intelligence*. – 2023. – Vol. 53. – P. 993–1012. – DOI: <https://doi.org/10.1007/s10489-022-03689-3>.
6. Chen P. Deep learning-based financial risk early warning model for listed companies / P. Chen, M. Ji // *Expert Systems with Applications*. – 2025. – DOI: <https://doi.org/10.1016/j.eswa.2025.127746>.
7. Li J. A deep learning approach of financial distress recognition / J. Li // *Entropy*. – 2023. – DOI: <https://doi.org/10.3934/era.2023240>.
8. Gu L. Optimized backpropagation neural network for risk prediction / L. Gu // *Scientific Reports*. – 2023. – DOI: <https://doi.org/10.1038/s41598-023-46528-8>.
9. Qin W. Financial risk forecast model based on CNN / W. Qin // *Computational Intelligence and Neuroscience*.

– 2022. – DOI: <https://doi.org/10.1155/2022/3652931>.

10. Huang X. Deep learning conditional value-at-risk based portfolio optimisation / X. Huang // *International Journal of Finance and Economics*. – 2024. – DOI: <https://doi.org/10.1002/ijfe.70012>.

11. Zhao H. Financial risk quantification through deep learning / H. Zhao // *ACM Proceedings*. – 2025. – DOI: <https://doi.org/10.1145/3762249.3762257>.

12. Zhang X. Hybrid deep learning financial risk prediction / X. Zhang // *ACM*. – 2025. – DOI: <https://doi.org/10.1145/3764727.3764749>.

13. Nguyen M. Deep learning framework for risk-aligned investing / M. Nguyen // *PLOS ONE*. – 2025. – DOI: <https://doi.org/10.1371/journal.pone.0330547>.

14. Shi X. Hybrid financial risk predictor using CNN-LSTM / X. Shi // *PeerJ Computer Science*. – 2025. – DOI: <https://doi.org/10.7717/peerj-cs.2661>.

15. Kumar S. Hybrid ML models for volatility prediction / S. Kumar // *Research in Economics*. – 2025. – DOI: <https://doi.org/10.1016/j.reveco.2025.1059056025000784>.

16. Рудніченко М.Д. Розробка проєкта модуля багатомірного аналізу фінансових даних з інвестицій / М.Д. Рудніченко, Д.В. Шведов // *Інформаційні технології і автоматизація – 2025, XVIII міжнародна науково-практична конференція. Одеса, 30-31 жовтня 2025 р.* - С.172-174.

17. Рудніченко М. Д. Проєкт інтелектуальної системи підтримки прийняття рішень з аналізу фінансових ризиків з інвестицій / М.Д. Рудніченко, Д.В. Шведов, Н.О. Шибайєва // *IV Міжнародна науково-практична інтернет-конференція «Інновації та перспективні шляхи розвитку інформаційних технологій» (ІПШРІТ-2025) 25 листопада 2025 року* С.112-113.

18. Рудніченко М. Концепція гібридної моделі глибинного навчання для інтелектуального аналізу фінансових ризиків / М. Рудніченко, Д. Шведов, І. Петров // *Інформаційні управляючі системи і технології (ІУСТ-ОДЕСА-2025). XIII Міжнародна науково-практична конференція (24–26 вересень 2025 р., Одеса).* - С.209-211.

References

1. Jiang C. Deep learning-based risk assessment model for financial decision-making / C. Jiang, H. Liu, L. Zhao // *Expert Systems with Applications*. – 2023. – Vol. 228. – P. 120–138. – DOI: <https://doi.org/10.1016/j.eswa.2023.120138>.

2. Zhang S. A deep learning framework for multi-source financial risk prediction / S. Zhang, J. Wu, Y. Lin // *Knowledge-Based Systems*. – 2023. – Vol. 261. – P. 110–125. – DOI: <https://doi.org/10.1016/j.knosys.2023.110125>.

3. Li T. Hybrid transformer–LSTM model for financial risk analysis with heterogeneous data / T. Li, M. Chen // *Information Sciences*. – 2024. – Vol. 634. – P. 51–70. – DOI: <https://doi.org/10.1016/j.ins.2023.11.024>.

4. Wang X. Cross-modal deep learning for comprehensive financial risk evaluation / X. Wang, Z. Huang // *Neurocomputing*. – 2023. – Vol. 556. – P. 341–356. – DOI: <https://doi.org/10.1016/j.neucom.2023.04.112>.

5. Yu L. Investor behavior prediction using multi-dimensional deep neural networks / L. Yu, H. Yang // *Applied Intelligence*. – 2023. – Vol. 53. – P. 993–1012. – DOI: <https://doi.org/10.1007/s10489-022-03689-3>.

6. Chen P. Deep learning-based financial risk early warning model for listed companies / P. Chen, M. Ji // *Expert Systems with Applications*. – 2025. – DOI: <https://doi.org/10.1016/j.eswa.2025.127746>.

7. Li J. A deep learning approach of financial distress recognition / J. Li // *Entropy*. – 2023. – DOI: <https://doi.org/10.3934/era.2023240>.

8. Gu L. Optimized backpropagation neural network for risk prediction / L. Gu // *Scientific Reports*. – 2023. – DOI: <https://doi.org/10.1038/s41598-023-46528-8>.

9. Qin W. Financial risk forecast model based on CNN / W. Qin // *Computational Intelligence and Neuroscience*. – 2022. – DOI: <https://doi.org/10.1155/2022/3652931>.

10. Huang X. Deep learning conditional value-at-risk based portfolio optimisation / X. Huang // *International Journal of Finance and Economics*. – 2024. – DOI: <https://doi.org/10.1002/ijfe.70012>.

11. Zhao H. Financial risk quantification through deep learning / H. Zhao // *ACM Proceedings*. – 2025. – DOI: <https://doi.org/10.1145/3762249.3762257>.

12. Zhang X. Hybrid deep learning financial risk prediction / X. Zhang // *ACM*. – 2025. – DOI: <https://doi.org/10.1145/3764727.3764749>.

13. Nguyen M. Deep learning framework for risk-aligned investing / M. Nguyen // *PLOS ONE*. – 2025. – DOI: <https://doi.org/10.1371/journal.pone.0330547>.

14. Shi X. Hybrid financial risk predictor using CNN-LSTM / X. Shi // *PeerJ Computer Science*. – 2025. – DOI: <https://doi.org/10.7717/peerj-cs.2661>.

15. Kumar S. Hybrid ML models for volatility prediction / S. Kumar // *Research in Economics*. – 2025. – DOI: <https://doi.org/10.1016/j.reveco.2025.1059056025000784>.

16. ІРудніченко М.Д. Розробка проєкта модуля багатомірного аналізу фінансових даних з інвестицій / М.Д. Рудніченко, Д.В. Шведов // *Інформаційні технології і автоматизація – 2025, XVIII міжнародна науково-практична конференція. Одеса, 30-31 жовтня 2025 р.* - С.172-174.

17. Рудніченко М. Д. Проєкт інтелектуальної системи підтримки прийняття рішень з аналізу фінансових ризиків з інвестицій / М.Д. Рудніченко, Д.В. Шведов, Н.О. Шибайєва // *IV Міжнародна науково-практична інтернет-конференція «Інновації та перспективні шляхи розвитку інформаційних технологій» (ІПШРІТ-2025) 25 листопада 2025 року* С.112-113.

18. Рудніченко М. Концепція гібридної моделі глибинного навчання для інтелектуального аналізу фінансових ризиків / М. Рудніченко, Д. Шведов, І. Петров // *Інформаційні управляючі системи і технології (ІУСТ-ОДЕСА-2025). XIII Міжнародна науково-практична конференція (24–26 вересень 2025 р., Одеса).* - С.209-211.