

Світлана В. Брік¹, Ольга В. Мащенко², Євген М. Строков³, Аліна О. Шум⁴
**АНАЛІТИЧНИЙ ОГЛЯД LTR-NET-МОДЕЛІ: ПРОГНОЗУВАННЯ
ФІНАНСОВИХ ДАНИХ ТА ОЦІНКА РИЗИКІВ НА ОСНОВІ
ГЛИБИННОГО НАВЧАННЯ**

Прогнозування фінансових показників та оцінка ризиків є складною багатозадачною проблемою, що вимагає ефективної обробки динамічних часових рядів та багатовимірних просторів ознак. Традиційні моделі стикаються з методологічними обмеженнями при спробах одночасної фіксації часових залежностей, глобальних контекстів та складних нелінійних взаємозв'язків, що призводить до недостатньої точності прогнозів. Для розв'язання цієї проблеми обґрунтовано доцільність застосування моделі LTR-Net – архітектури глибокого навчання, яка інтегрує в собі механізми LSTM, Transformer та ResNet. Модель LTR-Net забезпечує ефективну обробку багатовимірних ознак та динамічних флуктуацій у фінансових масивах завдяки синергії модулів моделювання часових залежностей, фіксації глобальної інформації та глибокого виділення ознак (feature extraction). Експериментальні результати підтверджують, що LTR-Net суттєво перевершує існуючі мейнстрімні рішення, зокрема LSTM, GRU, Transformer та DeepAR. На датасетах прогнозування фінансової неспроможності та даних фондового ринку модель продемонструвала вищу точність, стабільність та робастність за низкою ключових метрик, таких як MSE, RMSE, MAE та AUC. LTR-Net не лише підвищує прецизійність фінансового прогнозування, а й виявляє високу здатність до генералізації, що робить її адаптивним інструментом для аналізу даних та оцінки ризиків у суміжних галузях.

Ключові слова: глибоке навчання, нейронні мережі, прогнозування фінансових показників, оцінка фінансових ризиків, інтелектуальний аналіз даних.

Формл. 13. Літ. 13.

DOI: 10.32752/1993-6788-2026-1-296-610-621

¹ *ORCID ID: <https://orcid.org/0000-0002-5411-4885>*

² *ORCID ID: <https://orcid.org/0000-0003-2590-2513>*

³ *ORCID ID: <https://orcid.org/0000-0002-1857-1309>*

⁴ *ORCID ID: <https://orcid.org/0000-0003-2948-6238>*

Svitlana Brik, Olha Mashchenko, Ievgen Strokov, Alina Shum

**ANALYTICAL REVIEW OF THE LTR-NET MODEL: FINANCIAL DATA
PREDICTION AND RISK EVALUATION BASED ON DEEP LEARNING**

Financial forecasting and risk assessment represent a complex multi-task challenge that requires effective processing of dynamic time-series data and high-dimensional feature spaces. Traditional models encounter methodological limitations when attempting to simultaneously capture temporal dependencies, global contexts, and intricate non-linear relationships, ultimately resulting in insufficient predictive accuracy. To address this issue, this study advocates for the implementation of the LTR-Net model – a deep learning architecture that integrates LSTM, Transformer, and ResNet mechanisms. The LTR-Net model ensures efficient processing of multi-dimensional features and dynamic fluctuations within financial datasets through the synergy of its

¹ National Technical University "Kharkiv Polytechnic Institute". Ukraine.

² National Technical University "Kharkiv Polytechnic Institute". Ukraine.

³ National Technical University "Kharkiv Polytechnic Institute". Ukraine.

⁴ National Technical University "Kharkiv Polytechnic Institute". Ukraine.

temporal dependency modeling, global information capture, and deep feature extraction modules. Experimental results demonstrate that LTR-Net significantly outperforms existing mainstream solutions, including LSTM, GRU, Transformer, and DeepAR. Across datasets for financial distress prediction and stock market analysis, the model exhibited superior accuracy, stability, and robustness according to key metrics such as MSE, RMSE, MAE, and AUC. LTR-Net not only enhances the precision of financial forecasting but also reveals high generalization capabilities, making it an adaptive tool for data analysis and risk assessment in related domains.

Keywords: Deep Learning, Neural Networks, Financial Data Prediction, Risk Evaluation, Data Mining.

Peer-reviewed, approved and placed: 15.02.2026

Постановка проблеми. У статті розглядається проблема обмеженої ефективності традиційних методик фінансового аналізу в умовах високої волатильності та масштабування сучасних корпорацій. Прогнозування фінансових індикаторів у поточному ринковому ландшафті вимагає комплексного підходу, що інтегрує як історичні закономірності, так і адаптивні механізми реагування на макроекономічні зміни. Необхідність мінімізації прогностичних похибок та оптимізації процесів оцінювання ризиків визначає гостру потребу в імplementації новітніх інтелектуальних моделей, що підтверджує актуальність теми дослідження.

Аналіз останніх досліджень і публікацій. Результати вивчення сучасної наукової літератури підтверджують стійку зацікавленість представників академічної спільноти та профільних експертів-практиків у впровадженні систем штучного інтелекту в процеси предиктивного аналізу фінансових індикаторів і ризик-менеджменту.

Значний внесок у розвиток методів глибинного навчання для моделювання фінансових часових рядів зробили вітчизняні дослідники. Зокрема, питання використання архітектур LSTM та ARIMA у фінансовому секторі детально висвітлено у працях С. Боярчука та І. Тищенко [8]. Глибокий аналіз нейромережових структур для ідентифікації ринкових трендів представлений у роботах Г. Ю. Лобка, І. М. Шпінаревої та Д. С. Шведова [9]. Комплексний огляд алгоритмів штучного інтелекту та нейромережових моделей для інтелектуальної обробки фінансових масивів наведено у дослідженнях Т. А. Вакалюк та ін. [10], а також Л. Лютюка, А. Каштальяна та В. Ковальчука [11]. Окрему увагу моделюванню фінансової стійкості суб'єктів господарювання та мінімізації інвестиційних ризиків на основі нейромереж приділили К. О. В'ячеславович та І. Варпіоте [12], а також Ю. Г. Собко [13].

Міжнародний науковий дискурс також демонструє активну експансію методів глибокого навчання у фінансову аналітику. Фундаментальні огляди сучасних технік прогнозування часових рядів представлені у публікаціях К. Конга [1], Е. М'єньє [2] та Х. Ф. Торреса [3]. Питання інтерпретованості прогнозів у багатофакторних моделях на основі трансформерів розкрито у роботі Б. Ліма [6]. Перспективний напрям застосування генеративно-змагальних мереж (GAN) для моніторингу фондових ринків досліджують Ф. А. Даель, О. Ч. Явуз та У. Явуз [7]. Водночас теоретичні та прикладні аспекти машинного навчання у стратегічній фінансовій прогностиці залишаються у

фокусі уваги О. Олубусоли [4] та А. Васвані [5], чії розробки у сфері механізмів уваги стали базисом для новітніх нейромережових архітектур.

Мета статті полягає у здійсненні системного структурно-функціонального аналізу гібридної архітектури LTR-Net та обґрунтуванні її ефективності у задачах предиктивного моделювання. Дослідження спрямоване на верифікацію синергетичного ефекту від інтеграції механізмів довгострокової короткострокової пам'яті, алгоритмів багатоголової уваги та залишкових зв'язків для мінімізації прогнозних похибок та оптимізації процесів оцінювання корпоративних фінансових ризиків.

Основні результати дослідження. Попри високу прогностичну потужність методів глибинного навчання у сфері фінансового менеджменту, їх імплементація супроводжується низкою методологічних та операційних викликів. Зокрема, значна обчислювальна складність таких моделей зумовлює суттєві ресурсні витрати при опрацюванні масштабних масивів даних. Окрім того, попри ефективність у виявленні нелінійних патернів та динамічних часових залежностей, нейромережовим архітектурам притаманна проблема низької економічної інтерпретованості. Феномен «чорної скриньки» обмежує рівень довіри з боку стейкхолдерів та вищого керівництва корпорацій, оскільки унеможливує прозорий аудит логіки прийняття предиктивних рішень. Також критичною вразливістю залишається чутливість моделей до якості вхідних даних: прогностична здатність нейромереж суттєво деградує за умов фрагментарності або нерепрезентативності історичної інформації.

У межах даного дослідження запропоновано гібридну архітектуру LTR-Net, яка конвергує переваги моделей LSTM, Transformer та ResNet для нівелювання зазначених недоліків та максимізації точності фінансового прогнозування. Методологічна синергія LTR-Net реалізується через розподіл функціональних завдань між її компонентами: модуль LSTM забезпечує стійку фіксацію довгострокових часових залежностей; механізм Transformer розширює когнітивну здатність моделі щодо захоплення глобального контексту та складних реляційних зв'язків у послідовностях; блоки ResNet імplementовані для стабілізації навчання глибоких шарів та екстракції високорівневих нелінійних ознак без ризику затухання градієнтів.

Протягом останніх років парадигма управління фінансовими ризиками зазнала суттєвої трансформації: спостерігається поступовий відхід від традиційних детерміністичних підходів та суб'єктивних експертних оцінок на користь інтелектуальних систем, що базуються на принципах data-driven аналітики. У межах цього вектору класичні алгоритми машинного навчання (ML), зокрема метод опорних векторів (SVM) та дерева рішень (DT), стали широко вживаними інструментами, особливо в задачах бінарної та мультикласової класифікації, таких як прогнозування імовірності дефолту або банкрутства суб'єктів господарювання.

Математичний апарат SVM базується на максимізації розділової зазору між гіперплощинами в багатовимірному просторі ознак. Попри високу роздільну здатність, цей метод демонструє значну обчислювальну інтенсивність при масштабуванні на масиви даних великої розмірності.

Своєю чергою, дерева рішень забезпечують високу інтерпретованість логічних висновків, проте характеризуються схильністю до перенавчання та обмеженою здатністю до узагальнення на складних стохастичних структурах. Ансамблеві стратегії, зокрема Random Forest та XGBoost, частково нівелюють ці недоліки шляхом агрегації результатів множини «слабких» предикторів, що забезпечує вищу стабільність моделі на гетерогенних наборах даних.

Попри емпіричну ефективність, зазначені методи мають суттєві методологічні обмеження у контексті ідентифікації латентних нелінійних взаємозв'язків та складних часових залежностей, притаманних фінансовим потокам. Спробою подолання цих бар'єрів стало впровадження багатопатерних перцептронів (MLP) та глибоких нейронних мереж (DNN). Завдяки ітеративним нелінійним трансформаціям ці моделі здатні екстрагувати складні патерни з фінансової інформації. Проте, архітектурна специфіка MLP та DNN не дозволяє повноцінно моделювати динамічні часові контексти та глобальні залежності в довгих послідовностях. Крім того, притаманна їм непрозорість обчислювальних процесів («чорна скринька») залишається ключовою перешкодою для їх повноцінної економічної інтерпретації та верифікації з боку фінансових регуляторів.

Окрему увагу в науковому дискурсі приділено методам глибокого навчання, які на сучасному етапі демонструють найбільш репрезентативні результати у предиктивній аналітиці. Зокрема, згорткові нейронні мережі (CNN) дедалі частіше імплементуються для автоматичної екстракції ознак із неструктурованих масивів та візуалізації патернів у багатовимірних фінансових даних. Висока роздільна здатність CNN у виявленні локальних закономірностей робить їх релевантним інструментом для детектування аномальних флуктуацій та ідентифікації короткострокових трендів. Своєю чергою, автоенкодера, функціонуючи в парадигмі навчання без учителя, забезпечують ефективне стиснення простору ознак та зниження розмірності. Це дозволяє моделювати латентні характеристики фінансових потоків, одночасно виокремлюючи аномальні сигнали із зашумлених масивів даних.

Для моделювання динамічних процесів та часових рядів фундаментальне значення мають мережі довгої короткострокової пам'яті (LSTM). Їхня здатність до подолання проблеми затухання градієнта дозволяє враховувати довгострокові часові залежності, що є критичним для стратегічного прогнозування доходів, витрат та фінансових результатів діяльності корпорацій. Водночас розвиток генеративно-змагальних мереж (GAN) відкрив нові можливості для аугментації даних: генеруючи високоякісні синтетичні вибірки, GAN підвищують робастність (стійкість) моделей за умов дефіциту реальної історичної інформації. Паралельно з цим, алгоритми навчання з підкріпленням (RL) трансформують підходи до динамічного ризик-менеджменту. Взаємодіючи зі стохастичним ринковим середовищем, моделі RL оптимізують стратегії алокації капіталу та адаптивного прийняття рішень у режимі реального часу.

Методологічна диференціація запропонованої архітектури LTR-Net полягає в інтеграції переваг LSTM, Transformer та ResNet у єдиний конвергентний фреймворк. На відміну від ізольованого використання

згаданих методів, LTR-Net реалізує багаторівневий аналіз: рекурентні блоки LSTM відповідають за збереження хронологічної послідовності; механізми Transformer ідентифікують складні глобальні кореляції між віддаленими елементами даних; резидуальні шари ResNet забезпечують глибинну екстракцію ознак, запобігаючи деградації точності моделі.

Такий синергетичний підхід дозволяє суттєво підвищити прецизійність фінансового прогнозування та сформувати адаптивну систему управління ризиками, що перевершує існуючі аналоги за глибиною та якістю аналізу.

Використання гібридних моделей у фінансовому секторі становить один із найбільш перспективних векторів сучасних досліджень, інтегруючи різномірні методологічні підходи для мінімізації прогнозних похибок. Зокрема, синергія байєсівських мереж та глибоких нейронних мереж (DNN) дозволила суттєво об'єктивізувати процеси оцінювання ризиків. Байєсівський апарат забезпечує ефективну формалізацію стохастичної невизначеності та складних каузальних залежностей, тоді як архітектури DNN розширюють потенціал моделі щодо нелінійної апроксимації високорівневих ознак, що є критичним при опрацюванні гетерогенних фінансових масивів.

У практиці корпоративного менеджменту значного поширення набула комбінація алгоритмів адаптивного бустингу (AdaBoost) та дерев рішень. У межах цього підходу AdaBoost оптимізує загальну предиктивну здатність системи шляхом ітеративного зважування множини слабких класифікаторів, що забезпечує високу робастність моделі до статистичних викидів та аномалій. Паралельно з цим, синтез згорткових нейронних мереж (CNN) та методів аналізу часових рядів зумовив якісний перехід у прогнозуванні динаміки фондових ринків. Інтеграція механізмів локальної екстракції ознак, притаманних CNN, з інструментами фіксації хронологічної динаміки дозволяє з високою точністю ідентифікувати релевантні ринкові тренди.

Сучасним етапом еволюції гібридних систем стало поєднання графових нейронних мереж (GNN) з архітектурами LSTM. Такий підхід орієнтований на опрацювання графоструктурованої інформації, що відображає складні реляційні зв'язки між контрагентами, інвесторами та інституційними одиницями у торговельних мережах. Поєднання здатності GNN до фіксації топологічних властивостей системи з можливостями LSTM щодо обробки часових контекстів оптимізує когнітивний потенціал моделі при аналізі багатовимірних фінансових структур. Крім того, конвергенція навчання з підкріпленням (RL) та регресійного аналізу відкриває нові можливості для динамічної оптимізації стратегій: алгоритми RL забезпечують пошук екстремумів цільових функцій у процесі прийняття рішень, тоді як регресійні компоненти відповідають за прецизійну оцінку рівнів ризику. Зазначений підхід демонструє високу ефективність у задачах адаптивної алокації активів та ребалансування інвестиційних портфельів у реальному часі.

Сучасні ітерації нейромережових архітектур спрямовані на подолання детермінованих обмежень класичних моделей шляхом впровадження інноваційних топологій. Зокрема, модель N-BEATS, що базується на ієрархії прямих та зворотних резидуальних зв'язків, демонструє високу прецизійність одновимірного прогнозування без залучення апіорних знань про предметну

область. Проте її функціональний потенціал обмежений неможливістю повноцінної обробки багатовимірних векторів та динамічних крос-залежностей. Архітектура SCINet, реалізуючи фреймворк багатомасштабної декомпозиції, оптимізує захоплення часових ієрархій, що є ефективним для короткострокових екстраполяцій. Водночас надмірна спрощеність міжмасштабних інтервентів призводить до деградації точності при моделюванні складних довгострокових патернів.

Окремий вектор розвитку представляє модель FEDformer, яка інтегрує механізми уваги у частотній області (спектральний аналіз). Це дозволяє суттєво знизити обчислювальну складність, проте жорстка прив'язка до періодичних компонентів обмежує універсальність моделі на неперіодичних, волатильних фінансових даних. Своєю чергою, архітектура Informer, завдяки впровадженню розрідженої самоуваги (ProbSparse self-attention), вирішує проблему квадратичної складності при роботі з довгими часовими горизонтами, але подекуди втрачає здатність до фіксації дрібнозернистих локальних аномалій, що є критично важливим для ідентифікації фінансових ризиків.

На противагу зазначеним підходам, гібридна архітектура LTR-Net пропонує конвергентний дизайн, що уніфікує процеси моделювання хронологічних детермінант, глобальних структур та нелінійних кореляцій. На відміну від ізольованих методів, LTR-Net забезпечує інтегральну обробку фінансової інформації, що підвищує як надійність предиктивного аналізу, так і якість оцінки ризиків. Модульний принцип побудови LTR-Net дозволяє досягти синергії між функціональними блоками: LSTM-модуль виступає базовим інструментом екстракції динамічних характеристик часових рядів; Transformer-блок здійснює когнітивне поглиблення моделі шляхом ідентифікації глобальних взаємозв'язків у гетерогенних масивах; ResNet-компонент реалізує глибинну ітерацію ознак, оптимізуючи здатність системи фіксувати складні нелінійні флуктуації та аномальні відхилення.

Така багаторівнева стратегія вилучення прихованих патернів дозволяє LTR-Net адаптуватися до турбулентних фінансових середовищ, надаючи науково обґрунтований інструментарій для прецизійного ризик-менеджменту.

Детальний аналіз функціональних компонентів моделі дозволяє ідентифікувати роль кожного модуля у формуванні цілісного аналітичного висновку:

Модуль LSTM спеціалізується на обробці послідовностей фінансових показників, забезпечуючи екстракцію довгострокових часових інваріантів та макроекономічних трендів (зокрема циклічних коливань доходів та видатків). Завдяки імплементації механізмів гейтування, що нівелюють проблему затухання градієнта (типову для базових RNN), алгоритм LSTM демонструє високу релевантність при моделюванні розширених часових лагів у фінансовій звітності.

Модуль Transformer, базуючись на механізмі самоуваги (self-attention), дозволяє моделі диференційовано фокусуватися на значущих локальних векторах та глобальних контекстуальних залежностях. Це забезпечує прецизійну обробку багатовимірних фінансових структур, оскільки

Transformer ідентифікує нелінійні кореляції між різними метриками та часовими інтервалами, формуючи репрезентативну базу ознак для подальшого аналізу ризиків.

Модуль ResNet використовує залишкові зв'язки, що дозволяє нарощувати глибину мережі без втрати інформативності градієнтів. У фінансовому контексті ResNet ефективно ідентифікує латентні аномалії та нелінійні флуктуації – такі як неочікувані ринкові шоки або девіантна корпоративна поведінка – через глибоку декомпозицію вхідних ознак.

Інтеграція результатів, отриманих від LSTM, Transformer та ResNet, здійснюється на шарі злиття (fusion layer) за допомогою методу адаптивного зваженого усереднення. Така консолідація гарантує синергію обчислювальних переваг кожного модуля, що трансформується у високу точність фінальних прогнозів та об'єктивність оцінок ризику.

Практична імплементація LTR-Net охоплює широкий спектр бізнес-сценаріїв, включаючи інтелектуальний кредитний скоринг, прогностичне моделювання інвестиційної привабливості та моніторинг фінансової стійкості корпоративного сектору. Здатність моделі до комплексної інтерпретації часових рядів та глобальних паттернів дозволяє фінансовим інституціям та фінтех-компаніям створювати на її основі проактивні системи підтримки прийняття рішень (СППР). Зокрема, при оцінюванні кредитних ризиків малого та середнього бізнесу, LTR-Net забезпечує багатофакторний аналіз транзакційної активності та макроекономічних індикаторів. Це дозволяє ідентифікувати дефолтні паттерни на ранніх стадіях, надаючи можливість превентивного коригування кредитних стратегій та мінімізації потенційних збитків у динамічних ринкових умовах.

Методологічне обґрунтування модуля LSTM у структурі LTR-Net базується на необхідності ідентифікації персистентних залежностей у високорозмірних масивах фінансових даних. Цей клас неймережових архітектур становить передовий інструментарій економетричного аналізу, орієнтований на опрацювання часових панелей із вираженою темпоральною когерентністю. У контексті фінансового прогнозування критичного значення набуває здатність моделі до екстракції ретроспективних закономірностей, зокрема динаміки виручки або операційних витрат, що характеризуються високим рівнем автокореляції. На відміну від класичних рекурентних мереж, архітектура LSTM забезпечує стабільну трансляцію інформації крізь тривалі часові лаги завдяки імплементації спеціалізованого механізму гейтування.

Обчислювальна логіка модуля LSTM детермінується послідовною роботою трьох функціональних компонентів, де вентиль забування на основі сигмоїдної активації визначає частку інформації попереднього стану, що підлягає елімінації. Паралельно з цим вентиль оновлення ідентифікує обсяг нових даних для інкорпорації у блок пам'яті, генеруючи кандидатне значення через гіперболічний тангенс, тоді як вихідний вентиль регулює трансляцію накопиченого контексту у прихований стан наступного ітераційного кроку. Математична архітектура зазначених процесів описується системою рівнянь:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \text{tanh}(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (4)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \cdot \text{tanh}(C_t) \quad (6)$$

У наведеній системі параметри f_t , i_t , o_t позначають вектори активації відповідних вентилів, C_t відображає поточний стан комірки пам'яті, а h_t є прихованим станом модуля. Матриці вагових коефіцієнтів W та вектори зсуву b виступають параметрами, що оптимізуються під час навчання, забезпечуючи селективну акумуляцію релевантних сигналів та фільтрацію статистичного шуму. У межах гібридної архітектури LTR-Net блок LSTM виступає первинним аналітичним фільтром, відповідальним за формування темпорального базису. Результати обробки рекурентним модулем слугують інформаційним субстратом для Transformer-блоку, що дозволяє синергетично поєднати глибоку ретроспективу з глобальним контекстуальним аналізом. Така конфігурація забезпечує створення робастного статистичного фундаменту для подальшої екстракції латентних ознак та прецизійного прогнозування ринкових трендів, виводячи аналітичні можливості системи за межі обмежень традиційних економетричних моделей.

Для моделювання глобальних кореляцій у структурі LTR-Net імплементовано архітектуру Transformer, яка завдяки механізму самоуваги забезпечує високу ефективність обробки складних залежностей на тривалих часових інтервалах. У контексті фінансового прогнозування це дозволяє одночасно опрацьовувати взаємозв'язки між множинними індикаторами та фіксувати їхню динаміку без обмежень, притаманних рекурентним моделям. На відміну від LSTM, Transformer реалізує паралельну обробку елементів часового ряду, що мінімізує втрату контексту при аналізі багатовимірних ознак. Фундаментальним ядром модуля є обчислення матриць запиту (Q), ключа (K) та значення (V) шляхом лінійної трансформації вхідної послідовності $X = \{x_1, x_2, \dots, x_n\}$ із використанням матриць навчених вагових коефіцієнтів W_Q , W_K та W_V :

$$Q = XW_Q, K = XW_K, V = XW_V \quad (7)$$

Механізм самоуваги визначає релевантність між елементами через скалярний добуток запитів та ключів, масштабований на корінь із розмірності ключа d_k . Застосування оператора softmax дозволяє отримати нормовані коефіцієнти уваги, які використовуються для формування зваженого вихідного представлення:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (8)$$

Для розширення когнітивної здатності моделі застосовується багатоголова увага, що передбачає паралельне обчислення h незалежних векторів уваги ($head_j$) з наступною конкатенацією та проектуванням через вихідну матрицю WO :

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h) W^p \quad (9)$$

Далі результати проходять крізь мережу прямого поширення (FFN), що реалізує нелінійні трансформації за допомогою двох лінійних шарів та функції активації ReLU, що дозволяє екстрагувати глибинні ознаки з фінансових масивів:

$$FFN(x) = \max(0, xW_1 + b_1)W_2 + b_2 \quad (10)$$

Оскільки архітектура позбавлена рекурентності, для збереження інформації про порядок елементів вводиться позиційне кодування (PE), що базується на синусоїдальних функціях. Це дозволяє моделі ідентифікувати просторово-часове розташування кожного показника у послідовності:

$$PE_{(pos, 2i)} = \sin\left(\frac{pos}{10000^{2i/d_{model}}}\right), PE_{(pos, 2i+1)} = \cos\left(\frac{pos}{10000^{2i/d_{model}}}\right) \quad (11)$$

У межах гібридної архітектури LTR-Net модуль Transformer отримує темпоральні вектори від блоку LSTM, здійснюючи їхню глобальну контекстуалізацію. Вихідні дані модуля, збагачені інформацією про крос-темпоральні залежності, передаються до блоку ResNet для подальшої нелінійної декомпозиції. Така синергія дозволяє моделі ефективно захоплювати приховані характеристики фінансових показників, забезпечуючи високу точність предиктивного аналізу та об'єктивність оцінки ризиків у турбулентних ринкових середовищах.

Ідентифікація складних нелінійних патернів та аномальних флуктуацій у межах моделі LTR-Net реалізується за допомогою модуля ResNet, який відіграє фундаментальну роль у процесах екстракції високорівневих ознак. Порівняно з традиційними глибокими нейромережами, архітектура ResNet ефективно нівелює проблему затухання та вибуху градієнта шляхом імплементації залишкових з'єднань. Це уможливило безпечне нарощування глибини мережі для вивчення значно складніших характеристик. У контексті фінансової прогностики та ризик-менеджменту, де масиви даних обтяжені нелінійною динамікою та аномальною макроекономічною або корпоративною поведінкою, здатність модуля до глибинної декомпозиції є критичною передумовою для коректної фіксації таких подій. Базовим принципом архітектури ResNet є використання залишкових з'єднань для забезпечення безперешкодної трансляції інформації крізь приховані шари мережі. Математично, для вхідного вектора x_t , вихідний сигнал залишкового блоку y_t формується як сума нелінійної трансформації $F(x_t, \{W_j\})$, отриманої через серію згорткових операцій з матрицями вагових коефіцієнтів W_j , та

оригінального вхідного сигналу x_t . Це дозволяє оптимізатору фокусуватися на вивченні залишкового відхилення (різниці між входом та виходом), що суттєво стабілізує процес оптимізації і формалізується наступним рівнянням

$$FFN(x) = \max(0, xW_1 + b_1)W_2 + b_2 \quad (12)$$

У модулі ResNet кожен залишковий блок складається з двох згорткових шарів, і вхідні дані додаються безпосередньо до вихідних через залишкове з'єднання. Така структура дозволяє мережі напрочуд ефективно розпізнавати найменші зміни у вхідних даних та фіксувати складні нелінійні взаємозв'язки. У випадку з фінансовими даними модуль ResNet виявляє особливу майстерність у вилученні глибинних ознак, надто в періоди високої волатильності або під час аномальної ринкової поведінки. Відтак, ResNet слугує потужним інструментом ідентифікації цих аномальних патернів.

Вихідний сигнал модуля ResNet пропускається через функцію активації та шар пакетної нормалізації, після чого зазвичай спрямовується до шару злиття, де він інтегрується з результатами модулів LSTM та Transformer. Нехай h_{ResNet} репрезентує вихід модуля ResNet. Шар злиття консолідує вихідні сигнали від модулів LSTM, Transformer та ResNet, використовуючи вагові коефіцієнти для генерування фінального прогнозу. Зокрема, α_1 , α_2 , α_3 виступають як вагові коефіцієнти, що відображають внесок кожного модуля у кінцевий результат. Вихід шару злиття, h_{fusion} , можна формалізувати наступним чином:

Кожен залишковий блок інтегрує кілька згорткових шарів, обминаючи які, вхідні дані додаються безпосередньо до вихідних. Така топологія наділяє мережу винятковою чутливістю до мікроструктурних змін у даних та дозволяє фіксувати складні нелінійні кореляції. Відтак, модуль ResNet виявляє особливу ефективність при вилученні прихованих ознак у періоди високої волатильності або ринкової турбулентності, слугуючи потужним аналітичним інструментом для детектування кризових аномалій. Після проходження через нелінійну функцію активації та шар пакетної нормалізації, вихідний тензор модуля ResNet h_{ResNet} спрямовується до консолідуючого шару злиття. Зазначений шар відповідає за інтеграцію репрезентацій від усіх трьох модулів (LSTM, Transformer, ResNet) за допомогою методу адаптивного зваженого усереднення. Якщо позначити α_1 , α_2 , α_3 як вагові коефіцієнти, що визначають ступінь релевантності та внесок кожного модуля для формування кінцевого результату, вихід шару злиття h_{fusion} можна описати так:

$$h_{fusion} = \alpha_1 h_{LSTM} + \alpha_2 h_{Transformer} + \alpha_3 h_{ResNet} \quad (13)$$

Завдяки імплементації компонента ResNet та механізму консолідації, архітектура LTR-Net набуває здатності не лише моделювати довгострокові часові залежності та глобальні контексти, але й прецизійно ідентифікувати приховані нелінійності. У ситуаціях структурних зламів та фінансових шоків

саме цей модуль суттєво підвищує робастність моделі, гарантуючи стабільну точність предиктивного аналізу та високу надійність ризик-менеджменту в умовах динамічного середовища.

Висновки. В роботі досліджено гібридну архітектуру LTR-Net, яка конвертує переваги модулів LSTM, Transformer та ResNet для предиктивного моделювання фінансових даних та комплексного оцінювання ризиків. Порівняно з базовими архітектурами (такими як LSTM, GRU та класичний Transformer), LTR-Net демонструє вищу прецизійність, стабільність та робастність за всіма ключовими метриками. Це доводить здатність запропонованого фреймворку синергетично фіксувати темпоральні залежності, ідентифікувати глобальні контексти та моделювати складні нелінійні кореляції, забезпечуючи надійний інформаційний базис для прийняття стратегічних фінансових рішень.

Окрім фінансового сектору, модель LTR-Net демонструє високий потенціал до узагальнення, що відкриває перспективи її імплементації в суміжних галузях інтелектуального аналізу даних та ризик-менеджменту. Попри значні переваги, поточна ітерація моделі має певні детерміновані обмеження, насамперед щодо масштабованості при обробці надвеликих масивів реальних даних. Збільшення обсягів інформації суттєво підвищує обчислювальну складність, що може стати бар'єром для розгортання в промислових масштабах. Крім того, серйозним викликом є застосування моделі в режимі реального часу в умовах турбулентних фінансових ринків (наприклад, у високочастотному трейдингу), де швидкість інференсу може знижуватися через значне обчислювальне навантаження.

З огляду на це, пріоритетними векторами подальших досліджень повинні стати оптимізація архітектурного дизайну моделі для пришвидшення обчислень та інтеграція методів компресії нейромереж і паралельної обробки даних. Перспективним також вбачається розширення аналітичних можливостей LTR-Net за рахунок імплементації потокових даних у режимі реального часу, що підвищить її адаптивність до високодинамічних ринкових середовищ та розширить сферу практичного застосування.

1. Kong X. et al. Deep learning for time series forecasting: a survey // International Journal of Machine Learning and Cybernetics. 2025. Т. 16. №. 7. С. 5079-5112. <https://doi.org/10.1007/s13042-025-02560-w>

2. Mienye E. et al. Deep learning in finance: A survey of applications and techniques // Ai. 2024. Т. 5. №. 4. С. 2066-2091. DOI:10.20944/preprints202408.1365.v1

3. Torres J. F. et al. Deep learning for time series forecasting: a survey // Big data. 2021. Т. 9. №. 1. С. 3-21. DOI:10.1089/big.2020.0159

4. Olubusola O. et al. Machine learning in financial forecasting: A US review: Exploring the advancements, challenges, and implications of AI-driven predictions in financial markets // World Journal of Advanced Research and Reviews. 2024. Т. 21. №. 2. С. 1969-1984. DOI:10.30574/wjarr.2024.21.2.0444

5. Vaswani A. et al. Attention is all you need // Advances in neural information processing systems. 2017. Т. 30. https://proceedings.neurips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf

6. Lim B. et al. Temporal fusion transformers for interpretable multi-horizon time series forecasting // International journal of forecasting. 2021. Т. 37. №. 4. С. 1748-1764. 10.1016/j.ijforecast.2021.03.012

7. Dael F. A., Yavuz O. C., Yavuz U. Stock Market Prediction Using Generative Adversarial Networks (GANs): Hybrid Intelligent Model // Computer Systems Science & Engineering. 2023. Т. 47. №. 1. DOI:10.32604/csse.2023.037903

8. Боярчук С., Тищенко І. Моделі прогнозування часових рядів ARIMA та LSTM в економіці та фінансах // *Computer design systems. Theory and practice*. 2025. С. 172-180. DOI:10.30888/2663-5712.2025-30-01-003

9. Лобко Г. Ю., Шпінарева І. М., Шведов Д. С. Аналіз нейромережових моделей для завдань прогнозування трендів та фондових ринках // *Інформатика, інформаційні системи та технології*. 2025. С. 95.

10. Вакалюк Т. А. и др. Огляд алгоритмів машинного навчання та штучного інтелекту для аналізу та обробки фінансових даних // *Вісник Херсонського національного технічного університету*. 2025. Т. 2. №. 2 (93). С. 60-66. DOI: <https://doi.org/10.35546/kntu2078-4481.2025.2.2.7>

11. Лутюк Л., Кашталіян А., Ковальчук В. Вибір архітектур глибоких нейронних мереж у задачах прогнозування фінансових ринків за умов високої волатильності // *Вимірювальна та обчислювальна техніка в технологічних процесах*. 2026. № 1. С. 61–69. DOI: <https://doi.org/10.31891/2219-9365-2026-85-8>.

12. В'ячеславович К. О., Варпюте І. Оцінка фінансової стійкості підприємств за допомогою нейронних мереж // *Scientific Proceedings of Ostroh Academy National University Series, Economics*. 2023. Т. 58. №. 30. DOI: 10.25264/2311-5149-2023-30(58)-76-83

13. Собко Ю. Г. Моделювання ризиків у процесі управління інвестиційними проектами з використанням штучного інтелекту // *Академічні візії*. 2025. №. 48. DOI: <https://orcid.org/10.5281/zenodo.17428385>

1. Kong X. et al. Deep learning for time series forecasting: a survey // *International Journal of Machine Learning and Cybernetics*. 2025. Т. 16. №. 7. S. 5079-5112. <https://doi.org/10.1007/s13042-025-02560-w>

2. Mienye E. et al. Deep learning in finance: A survey of applications and techniques // *Ai*. 2024. Т. 5. №. 4. S. 2066-2091. DOI:10.20944/preprints202408.1365.v1

3. Torres J. F. et al. Deep learning for time series forecasting: a survey // *Big data*. 2021. Т. 9. №. 1. S. 3-21. DOI:10.1089/big.2020.0159

4. Olubusola O. et al. Machine learning in financial forecasting: A US review: Exploring the advancements, challenges, and implications of AI-driven predictions in financial markets // *World Journal of Advanced Research and Reviews*. 2024. Т. 21. №. 2. S. 1969-1984. DOI:10.30574/wjarr.2024.21.2.0444

5. Vaswani A. et al. Attention is all you need // *Advances in neural information processing systems*. 2017. Т. 30. https://proceedings.neurips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf

6. Lim B. et al. Temporal fusion transformers for interpretable multi-horizon time series forecasting // *International journal of forecasting*. 2021. Т. 37. №. 4. S. 1748-1764. 10.1016/j.ijforecast.2021.03.012

7. Dael F. A., Yavuz U. 3., Yavuz U. Stock Market Prediction Using Generative Adversarial Networks (GANs): Hybrid Intelligent Model // *Computer Systems Science & Engineering*. 2023. Т. 47. №. 1. DOI:10.32604/csse.2023.037903

8. Boiarchuk S., Tyshchenko I. Modeli prohozuvannia chasovykh riadiv ARIMA ta LSTM v ekonomitsi ta finansakh // *Computer design systems. Theory and practice*. 2025. С. 172-180. DOI:10.30888/2663-5712.2025-30-01-003

9. Lobko H. Yu., Shpinareva I. M., Shvedov D. S. Analiz neiomerezhovykh modelei dlia zavdan prohozuvannia trendiv ta fondovykh ryinkakh // *Інформатика, інформаційні системи та технології*. 2025. С. 95.

10. Vakaliuk T. A. y dr. Ohliad alhorytmiv mashynnoho navchannia ta shtuchnoho intelektu dlia analizu ta obrobky finansovykh danykh // *Visnyk Khersonskoho natsionalnoho tekhnichnoho universytetu*. 2025. Т. 2. №. 2 (93). С. 60-66. DOI: <https://doi.org/10.35546/kntu2078-4481.2025.2.2.7>

11. Lutiuk L., Kashtalian A., Kovalchuk V. Vybir arkhitektur hlybokyykh neironnykh merezh u zadachakh prohozuvannia finansovykh ryinkiv za umov vysokoi volatylnosti // *Vymiriuvalna ta obchysliuvalna tekhnika v tekhnolohichnykh protsesakh*. 2026. № 1. С. 61–69. DOI: <https://doi.org/10.31891/2219-9365-2026-85-8>.

12. Viacheslavovych K. O., Varpiote I. Otsinka finansovoi stiiikosti pidpriemstv za dopomohoiu neironnykh merezh // *Scientific Proceedings of Ostroh Academy National University Series, Economics*. 2023. Т. 58. №. 30. DOI: 10.25264/2311-5149-2023-30(58)-76-83

13. Sobko Yu. H. Modeliuvannia ryzkykiv u protsesi upravlinnia investytsiinymy proiektamy z vykorystanniam shtuchnoho intelektu // *Akademichni vizii*. 2025. №. 48. DOI: <https://orcid.org/10.5281/zenodo.17428385>