

УДК 336.7:004.8

**Перегуда Юлія Андріївна**

доктор економічних наук, доцент,  
доцент кафедри глобальної економіки  
Національний університет біоресурсів  
і природокористування України;  
заступник завідувача кафедри організації  
туристичної діяльності,  
професор кафедри організації туристичної  
діяльності  
Навчально-наукового інституту  
управління, економіки та бізнесу  
Міжрегіональна Академія управління  
персоналом

ORCID: 0000-0002-1434-2509

<https://doi.org/10.25313/3083-7782-2026-5-3>

## ГІБРИДНІ МОДЕЛІ ШІ У ФІНАНСОВОМУ ПРОГНОЗУВАННІ

**Анотація.** Вступ. Фінансове прогнозування належить до прикладних сфер, у яких помилка моделі швидко набуває економічної форми: втрати ліквідності, неправильного ціноутворення ризику, неефективної інвестиційної позиції або хибного сигналу для банківського, монетарного чи регуляторного рішення. У сучасних умовах прогнозування фінансових часових рядів ускладнюється не лише зростанням обсягів даних, а й режимною нестабільністю, волатильністю, інформаційними шоками, алгоритмічною торгівлею та підвищенням складності фінансової поведінки. За таких умов одиначні моделі часто не охоплюють усю структуру фінансового сигналу. Класичні економетричні підходи зберігають значення для аналізу авторегресійності та волатильності, але мають обмеження щодо нелінійності й багатовимірності. Моделі машинного та глибокого навчання краще працюють із нелінійними залежностями й великими наборами ознак, однак створюють ризики непрозорості, нестійкості та складності аудиту.

**Мета.** Метою статті є обґрунтування теоретико-методичних засад застосування гібридних моделей штучного інтелекту у фінансовому прогнозуванні та розроблення архітектури їх використання для фінансових часових рядів з урахуванням прогнозної точності, режимної стійкості, пояснюваності результатів і модельного ризику.

**Матеріали і методи.** Інформаційну базу дослідження становлять наукові публікації з економетричного, машинного й глибокого прогнозування, праці з пояснюваного штучного інтелекту, міжнародні звіти щодо використання ШІ у фінансах, а також відкриті дані НБУ. Методологічно стаття спирається на систематизацію джерел, порівняльний аналіз модельних підходів, структурно-функціональне моделювання, узагальнення результатів емпіричних досліджень і принцип walk-forward validation для часових рядів.

**Результати.** У статті обґрунтовано багатосарову інтерпретацію фінансового часового ряду, у межах якої виокремлено лінійний, волатильний, нелінійний, шумовий і режимний шари. Систематизовано основні типи гібридних моделей штучного інтелекту у фінансовому прогнозуванні: послідовні, декомпозиційні, ансамблеві, стекінгові та пояснювані архітектури. Сформовано архітектуру гібридної моделі, яка поєднує збір даних, попередню обробку, декомпозицію сигналу, базові моделі, агрегування прогнозів, послідовну часову валідацію, пояснюваність і контроль модельного ризику. На офіційних даних НБУ емпірично проілюстровано режимну неоднорідність українського фінансового контексту у 2020–2026 рр. на прикладі динаміки курсу USD/UAH та облікової ставки НБУ. Обґрунтовано, що прогнозна точність не є тотожною фінансовій ефективності рішення, оскільки практичне використання прогнозу потребує врахування ліквідності, транзакційних витрат, регуляторних обмежень, лімітів ризику та процедур людського перегляду.

**Перспективи.** Подальші дослідження доцільно спрямувати на повне емпіричне тестування запропонованої архітектури на щоденних фінансових рядах НБУ з порівнянням наївного прогнозу, ARIMA/GARCH, XGBoost, LSTM та гібридних моделей за MAE, RMSE, SMAPE, точністю прогнозування напряму зміни й помилкою за валютними та монетарними режимами. Окремого значення на-



Copyright © The Author(s).

This is an open access article distributed under the terms of the Creative Commons Attribution License 4.0 (<https://creativecommons.org/licenses/by/4.0/>)

буває оцінювання того, як прогнозна помилка трансформується у фінансовий ефект для банків, інвесторів, імпортерів, експортерів і регуляторів.

**Ключові слова:** фінансове прогнозування, гібридні моделі, штучний інтелект, часові ряди, ARIMA, GARCH, XGBoost, LSTM, Transformer, пояснюваний ШІ, модельний ризик, НБУ.

**Постановка проблеми.** Фінансове прогнозування належить до прикладних сфер, у яких помилка моделі швидко набуває економічної форми: втрати ліквідності, хибного ціноутворення ризику, неефективної інвестиційної позиції або помилкового сигналу для монетарного, банківського чи портфельного рішення. У сучасних умовах прогнозування фінансових рядів ускладнюється не лише зростанням обсягів інформації та різною частотністю даних. Більш суттєвою є нестійкість самої структури фінансових сигналів: відносно короткі стабільні режими змінюються шокowymi епізодами, ринкова реакція прискорюється під впливом алгоритмічної торгівлі, а використання близьких джерел даних і подібних модельних архітектур може підсилювати кореляцію поведінки учасників ринку.

Міжнародні інституції фіксують швидке поширення штучного інтелекту у фінансовому секторі. МВФ пов'язує застосування ШІ на ринках капіталу з потенційним поліпшенням ризик-менеджменту, ліквідності та ринкового моніторингу, але одночасно вказує на ризики зростання швидкості ринку, посилення волатильності у стресових умовах, непрозорості, операційної залежності від ключових постачальників технологічних послуг, кіберризиків і ринкового маніпулювання [1]. Рада з фінансової стабільності серед основних уразливостей називає концентрацію третіх сторін, кореляцію ринкової поведінки, кіберризиків, модельний ризик, якість даних і управління моделями [2]. ОЕСР також підкреслює подвійний характер ШІ у фінансах: технологія може підвищувати добробут користувачів і ефективність ринку, але здатна посилювати наявні та формувати нові ризики [3].

Для України питання фінансового прогнозування має додаткову складність через поєднання ринкових, воєнних, валютно-регуляторних і монетарних чинників. Відкриті набори НБУ містять дані щодо офіційних курсів гривні, UONIA, облікової ставки, результатів розміщення облігацій внутрішньої державної позики, банківських процентних ставок, депозитів, кредитів, монетарних агрегатів та інших показників, які можуть бути використані для побудови прогнозних моделей [4]. Наявність відкритої статистичної бази не усуває методичної проблеми: фінансові ряди за 2020–2025 роки та доступні спостереження 2026 року формувалися в різних режимах, тому модель, навчена на всій історії без урахування структурних зсувів, може відтворювати середню динаміку, але втрачати якість під час зміни валютного, процентного або ринкового режиму.

Класичні економетричні моделі зберігають аналітичну цінність, оскільки дають формалізовану рамку для оцінювання авторегресійності, тренду, сезонності, волатильності та реакції ряду на попередні шоки. Їхня результативність обмежується тоді, коли фінансовий ряд містить нелінійні залежності, приховані режими, взаємодію багатьох факторів і суттєву шумову компоненту. Моделі машинного та глибокого навчання краще працюють із високорозмірними ознаками й нелінійними зв'язками, однак створюють іншу методичну проблему: прогноз може демонструвати прийнятну точність на тестовому відрізку, але залишатися слабо інтерпретованим, нестійким до зміни ринкового режиму та складним для аудиту.

За таких умов центральним стає не протиставлення економетрики і штучного інтелекту, а побудова гібридної архітектури, у якій кожний компонент виконує окрему функцію в межах прогновної задачі. Проблема статті полягає у визначенні методичних умов, за яких гібридна модель ШІ у фінансовому прогнозуванні є не механічним поєднанням алгоритмів, а функціонально цілісною системою: від підготовки даних, виявлення режимних зсувів і декомпозиції сигналу до оцінювання точності, пояснення результату та контролю модельного ризику.

**Аналіз останніх досліджень і публікацій.** Методична основа фінансового прогнозування тривалий час формувалася в межах аналізу часових рядів, зокрема авторегресійних моделей, моделей ковзного середнього та їхніх інтегрованих модифікацій. Праця Дж. Бокса, Г. Дженкінса, Г. Рейнсела та Г. Лjung сформувала класичну процедуру побудови моделей часових рядів, що охоплює ідентифікацію структури ряду, оцінювання параметрів, діагностику залишків і використання моделі для прогнозування [5]. Для фінансових рядів окреме значення має моделювання умовної волатильності. Узагальнена авторегресійна умовна гетероскедастичність Т. Боллерслева розширила ARCH-підхід через включення минулих умовних дисперсій до рівняння поточної умовної дисперсії, що створило основу для аналізу волатильності як змінної в часі характеристики фінансового ряду [6].

Перехід до нейромережових моделей був пов'язаний із потребою враховувати довгі часові залежності, нелінійні зв'язки та складні патерни послідовностей. Архітектура LSTM, запропонована С. Гохрайтером і Ю. Шмідгубером, була розроблена для подолання проблеми довгих часових лагів і затухання градієнтів за рахунок комірок пам'яті та вентильних механізмів, які регулюють доступ до потоку інформації [7]. Паралельно розвивалися ансамблеві алгоритми машинного навчання. XGBoost, описаний Т. Ченом

і К. Гестріном, став одним із найпоширеніших інструментів градієнтного бустингу завдяки поєднанню деревних ансамблів, регуляризованої цільової функції, масштабованої реалізації, алгоритму роботи з розрідженими даними та ефективного наближеного пошуку розбиттів [8].

Подальший розвиток моделей послідовностей пов'язаний із механізмами уваги. Архітектура Transformer, запропонована А. Васвані та співавторами, відмовилася від рекурентної та згорткової структури й побудувала обробку послідовностей на механізмі self-attention [9]. Первинно модель розроблялася для задач машинного перекладу та ширшого класу задач перетворення послідовностей, однак її логіка згодом стала основою для довгогоризонтного прогнозування часових рядів. Для фінансових застосувань це важливо через потребу виявляти залежності між віддаленими подіями, ринковими індикаторами, лаговими реакціями та взаємопов'язаними фінансовими змінними.

Окремий напрям досліджень пов'язаний із пояснюваністю моделей. SHAP, запропонований С. Лундбергом і С.-І. Лі, забезпечив уніфіковану рамку для інтерпретації прогнозів складних моделей через оцінювання внеску кожної ознаки у конкретне прогнозне значення [10]. У фінансовому прогнозуванні пояснюваність має не допоміжне, а методичне значення: модель, яка прогнозує курс, ставку, індекс або волатильність без зрозумілого внеску ознак і без перевірки стабільності результатів, має обмежену придатність для банківського ризик-менеджменту, інвестиційного аналізу або регуляторного моніторингу.

Емпіричні дослідження підтвердили потенціал глибокого навчання для фінансових рядів, але водночас показали залежність результатів від періоду, витрат і ринкового режиму. Т. Фішер і К. Краусс застосували LSTM до прогнозування напрямів руху акцій S&P 500 за 1992–2015 рр. і показали перевагу над моделями без механізму пам'яті, зокрема random forest, стандартною глибокою нейромережею та логістичною регресією. Водночас автори зафіксували, що після 2010 р. надлишкова прибутковість LSTM-стратегії після врахування транзакційних витрат істотно знизилася [11]. Ф. Рундо, Ф. Трента, А. Л. ді Сталло та С. Баттіато систематизували використання машинного навчання в кількісних фінансах, наголосивши на його здатності працювати з високорозмірними, складними й нелінійними фінансовими даними [12]. О.Б. Сезер, М.У. Гюделек і А.М. Озбайоглу у систематичному огляді фінансового прогнозування з використанням глибокого навчання показали зростання ролі CNN, LSTM, DBN, GRU та інших моделей у прогнозуванні індексів, валют, товарних активів і фінансових сигналів [13].

Сучасний фронт досліджень зміщується від одиничних моделей до гібридних структур. Д. Стемпень і Р. Слєпачук порівняли гібридні підходи, що поєднують ARIMA/ARFIMA з SVM, XGBoost і LSTM, на прикладі S&P 500 та Bitcoin. Їхній висновок має принципове значення: результативність гібридної моделі залежить не від самого факту поєднання економетричного й нейромережевого або машинного блоку, а від способу зв'язку лінійної та нелінійної компонент прогнозуальної задачі [14]. Дж.-Ч. Лі, Л.-П. Сун, С. Ву і Ч. Тао запропонували модель CEEMDAN-Informer-LSTM, у якій фінансовий сигнал спочатку розкладається на частотні компоненти, після чого Informer використовується для прогнозування високочастотних складових, а LSTM — для низькочастотних компонентів. Такий підхід дав змогу поєднати декомпозицію шумного фінансового сигналу з різними прогнозними можливостями моделей для компонентів різної частоти [15].

Для довгогоризонтного прогнозування часових рядів значущими стали й Transformer-подібні моделі. Y. Liu та співавтори запропонували iTransformer, який змінює спосіб подання багатовимірного часового ряду: окремі часові ряди розглядаються як variate tokens, а механізм уваги використовується для фіксації багатовимірних кореляцій між ними [16]. Такий підхід є перспективним для фінансових задач, де курс, ставка, ліквідність, індекси, макроекономічні змінні та зовнішні ринкові фактори не функціонують як незалежні сигнали.

Попри розвинену літературу, залишаються невирішені питання. По-перше, частина досліджень оцінює точність моделей без достатнього аналізу їхньої режимної стійкості. По-друге, у фінансових публікаціях нерідко змішуються прогнозна точність і торговельна доцільність, хоча низька помилка прогнозу не гарантує позитивного фінансового результату після врахування транзакційних витрат, ліквідності та регуляторних обмежень. По-третє, пояснюваність часто подається як технічне доповнення до моделі, а не як умова використання прогнозу у фінансовому управлінні. По-четверте, для українських фінансових рядів потрібна спеціальна логіка валідації, оскільки 2020–2025 роки та доступні спостереження 2026 року охоплюють кілька різних режимів валютної, монетарної й ринкової динаміки.

**Метою статті** є обґрунтування теоретико-методичних засад застосування гібридних моделей штучного інтелекту у фінансовому прогнозуванні та розроблення архітектури їх використання для фінансових часових рядів з урахуванням прогнозуальної точності, режимної стійкості, пояснюваності результатів і модельного ризику.

Для досягнення мети поставлено такі завдання: визначити специфіку фінансового часового ряду як об'єкта гібридного моделювання; систематизувати основні типи гібридних моделей III у фінансовому прогнозуванні; окреслити архітектуру прикладної моделі для роботи з фінансовими часовими рядами; сформулювати протокол валідації прогнозів на основі офіційних фінансових даних; визначити умови, за яких модельний прогноз може бути використаний у фінансовому рішенні.

**Матеріали і методи.** Інформаційну базу дослідження становлять наукові публікації з економетричного, машинного й глибинного прогнозування, праці з пояснюваного штучного інтелекту, міжнародні звіти щодо використання ШІ у фінансах, а також відкриті дані НБУ, придатні для побудови та перевірки прогнозних моделей фінансових часових рядів. Методологічно стаття спирається на систематизацію джерел, порівняльний аналіз модельних підходів, структурно-функціональне моделювання, узагальнення результатів емпіричних досліджень і принцип послідовної часової валідації з рухомим прогнозним походженням (*walk-forward validation*), який використовується для перевірки моделей часових рядів без порушення хронологічного порядку спостережень [17]. Під час інтерпретації прогнозної якості враховано також досвід M4 forecasting competition, у межах якого результативність прогнозування пов'язувалася не лише зі складністю окремої моделі, а й із коректним дизайном перевірки, порівнянням із еталонними підходами, ансамблюванням і стійкістю результатів на різних часових рядах [18].

**Виклад основного матеріалу.** Фінансовий часовий ряд відрізняється від багатьох виробничих, демографічних або технологічних рядів тим, що формується в середовищі очікувань, інформаційних шоків і стратегічної поведінки учасників. Ціна активу, валютний курс, короткострокова ставка або спред не є механічним продовженням минулих значень. У кожному спостереженні поєднуються фундаментальні фактори, ліквідність, регуляторні обмеження, поведінкові реакції, зовнішній інформаційний фон і технічна структура ринку.

Для цілей гібридного моделювання фінансовий ряд доцільно розглядати як багатошарову структуру. Лінійний шар охоплює інерцію, лагові зв'язки та короткострокову авторегресійну компоненту. Волатильний шар відображає зміну умовної дисперсії й концентрацію ризику в окремих періодах. Нелінійний шар пов'язаний із пороговими ефектами, асиметрією реакцій і взаємодією багатьох ознак. Шумовий шар містить випадкові коливання, мікроструктурні ефекти та інформаційні перешкоди. Режимний шар фіксує переходи між стабільними, кризовими, адміністративно обмеженими або постшоковими станами ринку.

Одинична модель зазвичай охоплює лише частину цих шарів. ARIMA-подібна модель фіксує авторегресійну структуру, але має обмеження щодо нелінійності. GARCH-підхід описує умовну волатильність, однак не вирішує завдання багатовимірного прогнозування з великою кількістю ознак. XGBoost ефективно агрегує лаги, технічні індикатори та нелінійні взаємодії, але не має внутрішньої пам'яті послідовності. LSTM враховує часові залежності, проте чутлива до довжини вибірки, масштабування даних і перенавчання (*overfitting*). Transformer-подібні моделі перспективні для довгих залежностей і багатовимірних рядів, але потребують обережної адаптації до фінансових даних, де шум часто переважає над стабільним сигналом.

Гібридна модель має методичний сенс тоді, коли її компоненти розподілені за функціями. Декомпозиція виділяє шум і частотні складові; економетричний блок описує лінійну або волатильну структуру; бустинг працює з табличними ознаками; неймережа фіксує часову нелінійність; модуль пояснюваності діагностує внесок змінних у прогноз. За такої побудови гібридизація є не простим додаванням алгоритмів, а способом узгодити різні типи інформації у фінансовому ряді.

Типологія в табл. 1 показує, що гібридність не можна зводити до формули «класична модель плюс неймережа». Для фінансового прогнозування важливішими є спосіб інтеграції компонентів, контроль

Таблиця 1

**Типологія гібридних моделей штучного інтелекту у фінансовому прогнозуванні**

Тип гібридизації	Методична логіка	Типове поєднання моделей	Прогнозна функція	Основний ризик
Послідовна модель	Результат першого блоку стає входом для другого	ARIMA + XGBoost; ARIMA + LSTM	Відокремлення лінійної та нелінійної компонент	Накопичення помилок між етапами
Декомпозиційна модель	Ряд розкладається на тренд, шум або частотні компоненти	CEEMDAN / VMD / wavelet + LSTM / Informer	Зниження шуму та спеціалізація моделей за компонентами	Ризик витоку інформації під час декомпозиції
Ансамблева модель	Кілька моделей формують прогноз, який агрегується зважуванням	ARIMA, GARCH, XGBoost, LSTM, Transformer	Підвищення стійкості прогнозу	Надмірна складність і слабка інтерпретація ваг
Стекінг	Метамодель навчається комбінувати прогнози базових моделей	Базові моделі + meta-learner	Адаптивне поєднання різних прогнозних сигналів	Перенавчання на коротких рядах
Гібрид із пояснюваністю	До прогнозного блоку додається модуль інтерпретації	XGBoost / LSTM + SHAP / важливість ознак	Переведення прогнозу у формат фінансового сигналу	Нестійкість пояснення в різних режимах

Джерело: складено автором на основі [3; 10; 14; 15]

витоку інформації, стійкість у різних режимах і здатність пояснити результат. Наприклад, ARIMA-LSTM може працювати як послідовна модель, у якій ARIMA описує лінійну структуру, а LSTM — залишкову нелінійність. Така сама комбінація буде методично слабкою, якщо залишки не мають стабільної структури або якщо нейромережа навчається на інформації, недоступній у момент прогнозу.

Для прикладного використання у фінансовому прогнозуванні сформовано архітектуру, у якій гібридність охоплює не тільки прогнозний блок, а повний цикл роботи з моделлю: збір даних, попередню обробку, декомпозицію ряду, навчання базових моделей, агрегування прогнозів, валідацію, пояснення та переведення результату у фінансове рішення. На рис. 1 узагальнено повний цикл використання гібридної моделі у фінансовому прогнозуванні: від формування масиву фінансових даних і побудови ознак до декомпозиції сигналу, навчання базових моделей, агрегування прогнозів, послідовної часової валідації, пояснення результатів і контролю модельного ризику.

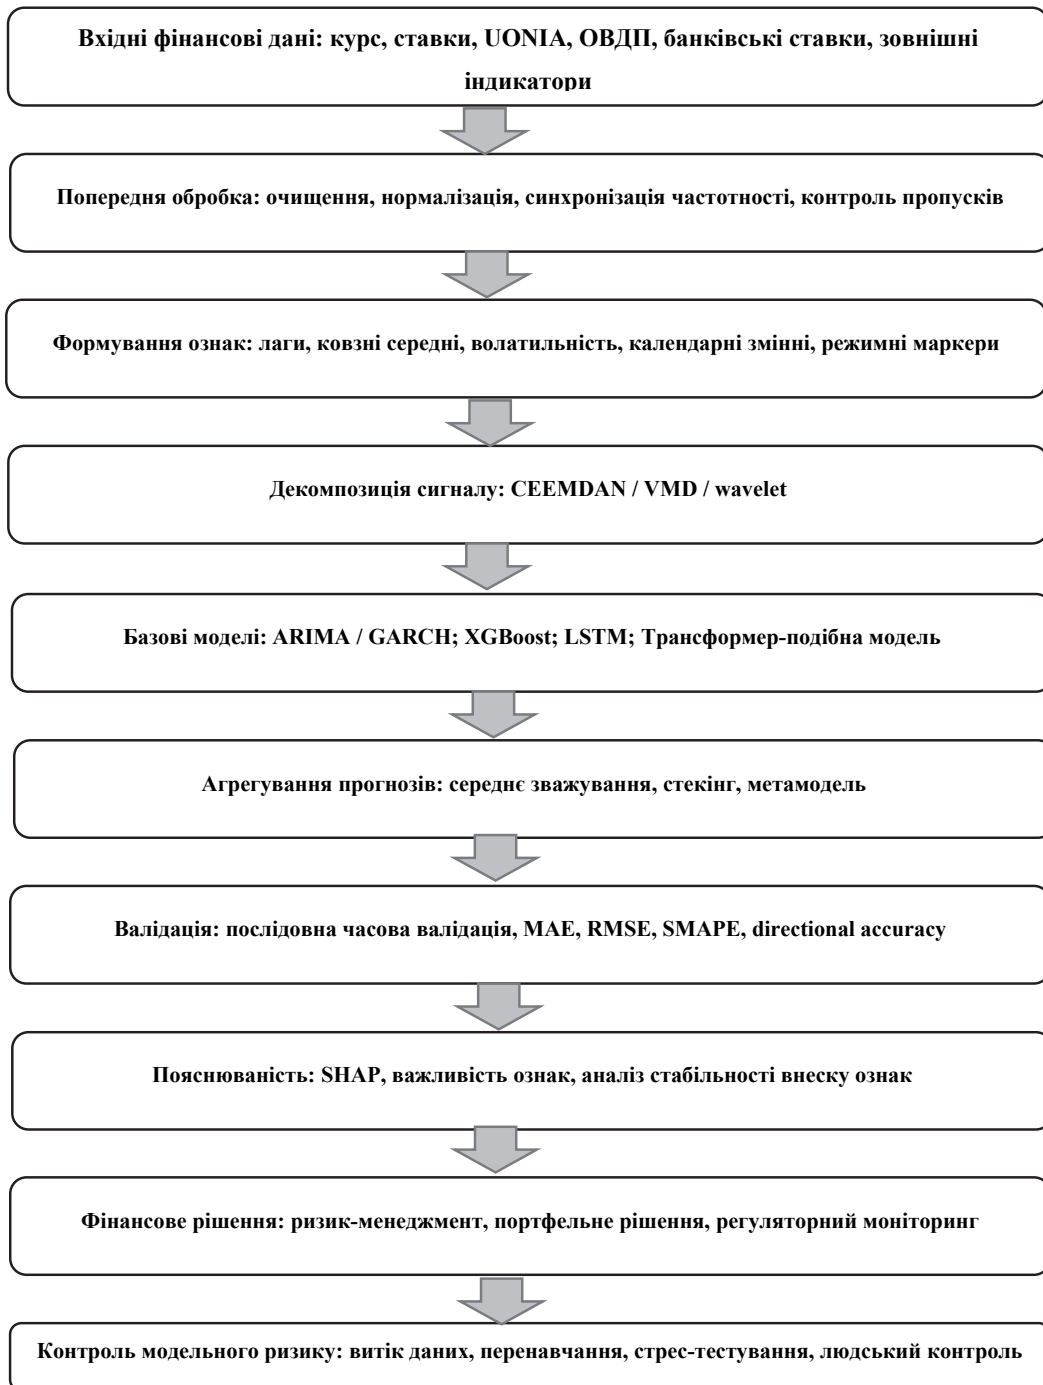


Рис. 1. Архітектура гібридної моделі фінансового прогнозування

Джерело: складено автором

Подана архітектура має два контури. Перший є прогнозним: від даних до агрегованого прогнозу. Другий є контрольним: валідація, пояснюваність і фінансове рішення. Без контрольного контуру модель залишається технічною процедурою, але не стає інструментом управління. Для банку, інвестиційної компанії або регулятора важливим є не лише числове значення прогнозу, а й розуміння джерел сигналу, стабільності помилки та меж застосування моделі.

Емпіричну ілюстрацію потреби в режимно-чутливій валідації сформовано на офіційних фінансових даних НБУ. Український фінансовий контекст у 2020–2026 рр. характеризується поєднанням довоєнного плаваючого валютного режиму, воєнної фіксації курсу, адміністративної корекції фіксованого рівня та переходу до керованої гнучкості. За даними НБУ, офіційний курс USD/UAH становив 28,2746 грн/дол. США на кінець 2020 р. і 27,2782 грн/дол. США на кінець 2021 р. Після початку повномасштабної війни курс було зафіксовано на рівні 29,2549 грн/дол. США, а 21 липня 2022 р. змінено фіксований рівень до 36,5686 грн/дол. США. З 3 жовтня 2023 р. НБУ перейшов до режиму керованої гнучкості. На кінець 2023 р. офіційний курс становив 37,9824 грн/дол. США, на кінець 2024 р. — 42,0390 грн/дол. США, на кінець 2025 р. — 42,3878 грн/дол. США, а 29 квітня 2026 р. — 44,0735 грн/дол. США [4]. Наведені значення курсу використано як емпіричні маркери різних валютних режимів, що дає змогу обґрунтувати потребу в режимній розмітці та окремому аналізі прогнозної помилки за фазами валютної динаміки.

Рис. 2 підтверджує, що офіційний курс USD/UAH у 2020–2026 рр. не можна інтерпретувати як однорідний часовий ряд. Період до лютого 2022 р., фіксований воєнний режим, корекція фіксованого курсу та керована гнучкість мають різну економічну природу. Для гібридної моделі це означає потребу не лише в лагових і технічних ознаках, а й у режимних маркерах, навчанні в ковзному вікні, послідовній часовій валідації та окремому аналізі помилки за валютними режимами. Без такого поділу модель може змішувати періоди з різною економічною природою курсоутворення й переоцінювати власну прогнозну якість.

Другий емпіричний зріз пов'язаний із процентним режимом. У червні 2022 р. НБУ підвищив облікову ставку до 25% річних, пояснюючи рішення потребою стабілізувати інфляційні очікування та знизити тиск на валютному ринку. У 2024 р. ставка знижувалася до 13,0–13,5%, у 2025 р. посилення монетарних умов привело до підвищення ставки до 15,5%, а з 30 січня 2026 р. її було знижено до 15,0% річних [4]. Дані щодо облікової ставки НБУ доступні з 25.06.1992, що дає змогу будувати довгі ряди для процентного прогнозування та валідації моделей.

Рис. 3 показує, що процентне середовище також змінювалося режимно. Різне підвищення ставки у 2022 р., подальший цикл пом'якшення, повторне посилення монетарних умов у 2025 р. та обережне зниження на початку 2026 р. означають, що прогнозування курсу, UONIA або короткострокових ставок не може спиратися лише на попередні значення прогнозованого показника. До моделі мають входити монетарні ознаки, режимні змінні та контроль структурних зсувів, оскільки зміна процентного режиму

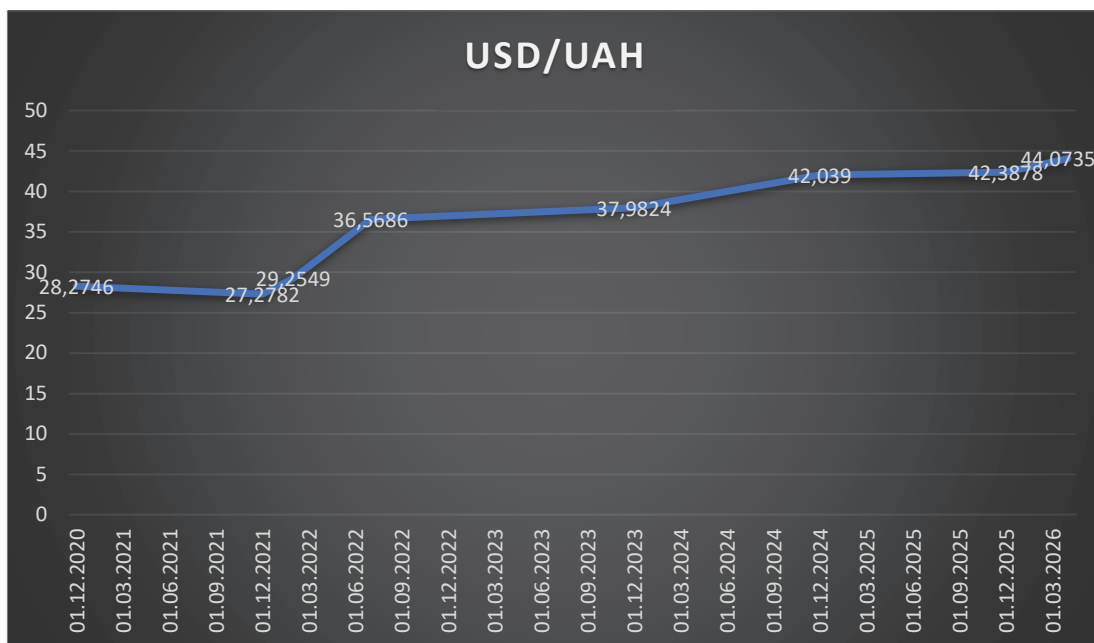


Рис. 2. Режимні зсуви офіційного курсу USD/UAH у 2020–2026 рр.

Джерело: побудовано автором за даними НБУ



Рис. 3. Динаміка облікової ставки НБУ у 2022–2026 рр.

*Джерело: побудовано автором за даними НБУ*

впливає на вартість гривневих інструментів, очікування учасників ринку, попит на валюту та дохідність альтернативних фінансових активів.

Прикладний емпіричний контур статті сформовано навколо офіційних фінансових рядів НБУ. Базовим об'єктом прогнозування в запропонованому протоколі визначено офіційний курс гривні до долара США або євро. Розширений варіант передбачає поєднання курсу, UONIA, облікової ставки, результатів розміщення ОВДП, банківських процентних ставок та режимних маркерів. API НБУ дає змогу отримувати офіційні курси за датою або діапазоном дат, щоденні показники UONIA з 22 червня 2020 р., дані щодо облікової ставки, результати розміщення ОВДП, кредити, депозити, банківські процентні ставки та агреговані показники діяльності банків [4].

Для фінансового прогнозування в умовах структурних змін некоректним є випадкове ділення даних на навчальну й тестову вибірку. Такий поділ руйнує часовий порядок і може створити ілюзію високої точності. Більш придатною є walk-forward схема: модель навчається на попередньому вікні, прогнозує наступний період, після чого вікно зсувається. Такий підхід дозволяє оцінити не тільки середню помилку, а й деградацію якості в окремих режимах.

Метрики оцінювання мають відповідати фінансовій задачі. MAE показує середню абсолютну помилку в одиницях прогнозованого показника. RMSE сильніше карає великі помилки, тому корисна для кризових відрізків. SMAPE дає масштабно зіставну оцінку, хоча для рядів із малими значеннями потребує обережної інтерпретації. Для фінансового рішення остання метрика має самостійне значення, оскільки невелика помилка рівня може поєднуватися з неправильним сигналом щодо напрямку.

Формування ознак має спиратися на економічну логіку. Для курсового ряду до набору ознак можуть входити лаги курсу, ковзні середні, волатильність за вікном, диференціали ставок, день тижня, місяць, маркери фіксованого курсу, адміністративної корекції, керованої гнучкості та зміни облікової ставки. Для ринкових індексів додаються обсяги торгів, технічні індикатори, лаги дохідності, зовнішні індекси й проксі-ознаки настроїв. Для банківських показників важливими стають ліквідність, процентні ставки, балансова структура, очікування та регуляторні зміни.

Декомпозиційний блок доцільний тоді, коли ряд містить сильний шум або різні частотні компоненти. SEEMDAN, VMD або wavelet-перетворення можуть розділити високочастотні коливання й повільніші компоненти. Далі для кожного шару можна підібрати різну модель: високочастотну частину прогнозувати Informer або Transformer-подібною архітектурою, низькочастотну — LSTM чи ARIMA, залишковий шум — не прогнозувати або обробляти окремо. Критичною умовою є виконання декомпозиції всередині кожного навчального вікна, інакше модель отримає інформацію з майбутніх спостережень.

Ансамблювання слід оцінювати не за кількістю включених моделей, а за стабільністю внеску. Проста середня кількох прогнозів може бути кращою за складний стекінг, якщо вибірка коротка або ринкові режими нестабільні. Метамоделювання у стекінг-рішенні потребує окремого шару валідації, інакше вона навчиться

Таблиця 2

**Методичний протокол перевірки гібридної моделі на офіційних фінансових даних НБУ**

Елемент протоколу	Методичне рішення	Обґрунтування для фінансового прогнозування
Об'єкт прогнозу	Офіційний курс USD/UAH або EUR/UAH; альтернативно — UONIA чи короткострокова ставка	Ряди є офіційними, регулярними та доступними через відкриті джерела НБУ
Період спостереження	2020–2026 рр. з окремим маркуванням валютних і монетарних режимів	Дає змогу відокремити довоєнну, шокову, фіксовану та керовано-гнучку фази
Базові моделі	Наївне прогнозування, ARIMA / GARCH, XGBoost, LSTM	Простий бенчмарк потрібний для перевірки, чи створює складна модель додану прогнозу цінність
Гібридні моделі	ARIMA-XGBoost, ARIMA-LSTM, CEEMDAN / VMD-LSTM, стекінговий ансамбль	Дають змогу перевірити, чи покращує функціональна гібридизація результат порівняно з одиничними моделями
Схема перевірки	Послідовна часова валідація із незмінним порядком спостережень	Зменшує ризик витoku майбутньої інформації та імітує реальний прогнозний режим
Метрики	MAE, RMSE, SMAPE, точність прогнозування на пряму зміни, помилка за режимами	Поеднують величину помилки, масштабну зіставність і здатність передбачати на пряму зміни
Блок пояснюваності	SHAP для табличних моделей; аналіз лагів, ознак і режимних маркерів	Показує, які змінні формують прогноз і чи є внесок ознак економічно осмисленим
Контроль модельного ризику	Перевірка на витік інформації, порівняння з бенчмарк-моделями, ретроспективне тестування за режимами	Не дозволяє замінити реальну прогнозу якість складністю архітектури

Джерело: складено автором на основі [4; 14; 17; 18]

на помилках тестової частини. Для фінансових часових рядів надмірно складна метамодель часто створює кращу історичну підгонку, але гірший реальний прогноз.

Табл. 3 переводить загальні обмеження фінансового прогнозування у вимоги до гібридної архітектури. Якщо головною проблемою ряду є волатильність, базовим компонентом має бути модель, що її описує. Якщо проблема полягає у взаємодії багатьох ознак, доцільні бустинг або Transformer-подібні моделі. Якщо ряд є шумним і містить різні частотні компоненти, доречною стає декомпозиція. Якщо модель використовується для управлінського рішення, обов'язковим є блок пояснюваності та контроль модельного ризику.

Таблиця 3

**Перетворення методичних ризиків фінансового прогнозування на елементи гібридної архітектури**

Джерело проблеми	Прояв у фінансовому ряді	Модельний ризик	Елемент гібридної архітектури	Контрольний інструмент
Лінійна інерція	Лагові залежності курсу, ставки або індексу	Недооцінка базової авторегресійної структури	ARIMA / ARIMAX	Порівняння з найвним прогнозом та бенчмарком ARIMA
Волатильність	Концентрація великих змін у кризові періоди	Заниження ризику в спокійних інтервалах	GARCH / EGARCH або режимні ознаки	RMSE за окремими режимами
Нелінійність	Порогові реакції, асиметрія, взаємодія багатьох факторів	Слабка якість лінійної моделі	XGBoost / Random Forest / LSTM	Послідовна часова валідація
Шум і частотна неоднорідність	Короткі коливання навколо тренду або фіксованого рівня	Перенавчання на випадкових змінах	CEEMDAN / VMD / wavelet + окремі моделі	Декомпозиція лише всередині навчального вікна
Режимний зсув	Фіксований курс, керована гнучкість, зміна ставки	Деградація моделі після зміни режиму	Режимні маркери, навчання в ковзному вікні	Помилка за режимами
Непрозорість прогнозу	Неможливість пояснити внесок ознак	Обмежена придатність для ризик-менеджменту	SHAP / feature importance	Звіт щодо пояснюваності моделі
Управлінське застосування	Прогноз не дорівнює фінансовому рішення	Помилкове використання моделі	Контур управління модельним ризиком	Людський перегляд, стрес-тестування, ліміти ризику

Джерело: складено автором

Гібридна архітектура для українських фінансових даних має такий робочий вигляд. На першому етапі формується набір офіційних даних: курс, UONIA, облікова ставка, результати розміщення ОВДП, банківські процентні ставки, календарні та режимні маркери. На другому етапі ряд очищується, нормалізується та перетворюється на лагові й технічні ознаки. На третьому етапі за потреби виконується декомпозиція сигналу. На четвертому етапі навчаються базові моделі: ARIMA або GARCH для лінійно-волатильного блоку, XGBoost для табличних ознак, LSTM або Трансформер-подібна модель для послідовних залежностей. На п'ятому етапі прогнози агрегуються. На шостому етапі результат проходить walk-forward оцінювання, пояснення та режимну діагностику.

Важливо відокремлювати прогнозу модель від торговельної або управлінської стратегії. Модель може добре прогнозувати рівень курсу, але не давати корисного рішення щодо позиції, якщо помилка більша за потенційний фінансовий ефект або якщо рішення обмежене регуляторними нормами. Для банківського ризик-менеджменту прогноз курсу або ставки має оцінюватися разом зі сценаріями ліквідності, лімітами відкритої валютної позиції, капітальними вимогами та внутрішніми процедурами контролю. Для інвестиційної задачі потрібне зіставлення прогнозу з трансакційними витратами, прослизанням, ліквідністю та ризиком просідання вартості портфеля.

Пояснюваність прогнозу не повинна підміняти причинність. SHAP / feature importance або інші методи інтерпретації показують внесок ознак у рішення моделі, але не доводять економічну причинність між змінними. Тому результати пояснюваного ШІ треба трактувати як діагностику моделі, а не як доказ економічного закону. Якщо внесок ознаки стабільний у різних walk-forward вікнах і узгоджується з фінансовою логікою, довіра до моделі зростає. Якщо внесок різко змінюється без економічного пояснення, модель потребує додаткової перевірки.

Моделний ризик у гібридних архітектурах має кілька джерел. Перше — витік даних, коли майбутня інформація потрапляє в навчання через некоректну нормалізацію, декомпозицію або формування ознак у гібридних архітектурах. Друге — перенавчання, посилене великою кількістю гіперпараметрів. Третє — нестійкість на кризових режимах. Четверте — непрозорість ансамблю, де складно визначити, яка модель сформувала критичний сигнал. П'яте — технологічна залежність від зовнішніх бібліотек, хмарних сервісів або постачальників даних.

Для зниження цих ризиків до протоколу використання гібридної моделі потрібно включити журнал версій даних, опис джерел, фіксацію навчальних вікон, контроль гіперпараметрів, порівняння з простими бенчмарк-моделями, ретроспективне тестування за режимами, звіт щодо пояснюваності, стрес-тестування і процедуру людського перегляду прогнозу. У фінансах модель не повинна автоматично перетворюватися на рішення; вона має формувати аналітичний сигнал, який перевіряється в межах політики ризику.

Науковий результат статті полягає у розмежуванні трьох рівнів гібридності. Перший рівень — алгоритмічний, коли поєднуються різні моделі. Другий рівень — функціональний, коли кожний компонент виконує окреме завдання: очищення сигналу, опис лінійності, виявлення нелінійності, агрегування прогнозу, пояснення. Третій рівень — управлінський, коли прогноз вбудовується в процедуру прийняття фінансового рішення з контролем ризиків і обмежень. Для фінансового прогнозування повноцінною можна вважати лише таку гібридну модель, яка охоплює всі три рівні.

**Висновки і перспективи подальших досліджень.** Проведене дослідження показало, що застосування гібридних моделей штучного інтелекту у фінансовому прогнозуванні має наукове й прикладне значення лише за умови функціонального розподілу ролей між компонентами моделі. Гібридизація не повинна зводитися до механічного поєднання класичної економетричної моделі та нейромережі. Її методична цінність виникає тоді, коли кожний блок виконує окрему функцію: економетричний компонент описує лінійну або волатильну структуру ряду, алгоритми машинного навчання працюють із багатовимірними ознаками та нелінійними взаємодіями, нейромережеві моделі фіксують часові залежності, декомпозиційні методи знижують шумову неоднорідність, а модулі пояснюваності й валідації забезпечують контроль придатності прогнозу для фінансового рішення.

У статті обґрунтовано багатопарову інтерпретацію фінансового часового ряду, у межах якої виокремлено лінійний, волатильний, нелінійний, шумовий і режимний шари. Такий підхід дозволяє пояснити, чому одинична модель часто не охоплює всю структуру фінансового сигналу. ARIMA-подібні моделі корисні для авторегресійної логіки, GARCH-підходи — для умовної волатильності, XGBoost — для табличних ознак і нелінійних взаємодій, LSTM і Transformer-подібні архітектури — для послідовних залежностей, а SHAP та інші методи пояснюваності — для діагностики внеску ознак у прогноз. На цій основі сформовано типологію гібридних моделей у фінансовому прогнозуванні та розмежовано послідовні, декомпозиційні, ансамблеві, стекінгові й пояснювані гібридні архітектури.

Запропоновано методичний протокол перевірки гібридної моделі на офіційних фінансових даних НБУ. Він охоплює вибір об'єкта прогнозування, порівняння з простими еталонними моделями, використання послідовної часової валідації, оцінювання за MAE, RMSE, SMAPE, точністю прогнозування напряму

зміни, пояснюваністю результатів і контролем модельного ризику. Для банківського ризик-менеджменту, інвестиційної діяльності й регуляторного моніторингу прогноз має оцінюватися не лише за середньою помилкою, а й за ліквідністю, трансакційними витратами, лімітами ризику, регуляторними обмеженнями та можливістю людського перегляду.

Науковий результат статті полягає у розмежуванні трьох рівнів гібридності фінансового прогнозування: алгоритмічного, функціонального й управлінського, що дає змогу відокремити просте комбінування моделей від повноцінної архітектури прийняття фінансового рішення. Алгоритмічний рівень передбачає поєднання різних моделей; функціональний — закріплення за кожним компонентом окремої ролі в обробці фінансового сигналу; управлінський — вбудовування прогнозу в процедуру прийняття фінансового рішення з контролем ризиків. Повноцінною для фінансового прогнозування можна вважати лише таку гібридну модель, яка охоплює всі три рівні.

Перспективи подальших досліджень полягають у проведенні повного емпіричного тестування запропонованої архітектури на щоденних фінансових рядах НБУ з порівнянням наївним прогнозом, ARIMA/GARCH, XGBoost, LSTM та ARIMA-XGBoost або ARIMA-LSTM за режимами валютної й монетарної динаміки. Окремого розвитку потребує оцінювання того, як прогнозна помилка трансформується у фінансовий ефект для банку, інвестора, імпортера, експортера або регулятора.

### ДОДАТКОВА ІНФОРМАЦІЯ

**ФІНАНСУВАННЯ:** Автори не отримували фінансування для цього дослідження.

**ЗАЯВА ПРО ДОСТУПНІСТЬ ДАНИХ:** Не застосовується.

**КОНФЛІКТ ІНТЕРЕСІВ:** Автори заявляють про відсутність конфлікту інтересів.

### Література

1. Global Financial Stability Report, October 2024: Steadying the Course: Uncertainty, Artificial Intelligence, and Financial Stability. Washington, DC: IMF, 2024. URL: <https://www.imf.org/en/publications/gfsr/issues/2024/10/22/global-financial-stability-report-october-2024> (дата звернення: 29.03.2026).
2. The Financial Stability Implications of Artificial Intelligence. Basel: FSB, 2024. URL: <https://www.fsb.org/2024/11/the-financial-stability-implications-of-artificial-intelligence/> (дата звернення: 29.03.2026).
3. Regulatory Approaches to Artificial Intelligence in Finance. *OECD Artificial Intelligence Papers*. 2024. No. 24. DOI: <https://doi.org/10.1787/f1498c02-en>
4. Developer API. *Національний банк України*. URL: <https://bank.gov.ua/en/open-data/api-dev> (дата звернення: 29.03.2026).
5. Box G. E. P., Jenkins G. M., Reinsel G. C., Ljung G. M. *Time Series Analysis: Forecasting and Control*. 5th ed. Hoboken: Wiley, 2015. 712 p.
6. Bollerslev T. Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*. 1986. Vol. 31, Issue 3. P. 307–327. DOI: [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
7. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997. Vol. 9. Issue 8. P. 1735–1780. DOI: <https://doi.org/10.1162/neco.1997.9.8.1735>
8. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD. International Conference on Knowledge Discovery and Data Mining*. 2016. P. 785–794. DOI: <https://doi.org/10.1145/2939672.2939785>
9. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser L., Polosukhin I. Attention Is All You Need. *Advances in Neural Information Processing Systems*. 2017. Vol. 30. URL: <https://arxiv.org/abs/1706.03762> (дата звернення: 29.03.2026).
10. Lundberg S. M., Lee S.-I. A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems*. 2017. Vol. 30. URL: <https://arxiv.org/abs/1705.07874> (дата звернення: 29.03.2026).
11. Fischer T., Krauss C. Deep Learning with Long Short-Term Memory Networks for Financial Market Predictions. *European Journal of Operational Research*. 2018. Vol. 270, Issue 2. P. 654–669. DOI: <https://doi.org/10.1016/j.ejor.2017.11.054>
12. Rundo F., Trenta F., di Stallo A. L., Battiato S. Machine Learning for Quantitative Finance Applications: A Survey. *Applied Sciences*. 2019. Vol. 9, Issue 24. Article 5574. DOI: <https://doi.org/10.3390/app9245574>
13. Sezer O. B., Gudelek M. U., Ozbayoglu A. M. Financial Time Series Forecasting with Deep Learning: A Systematic Literature Review: 2005–2019. *Applied Soft Computing*. 2020. Vol. 90. Article 106181. DOI: <https://doi.org/10.1016/j.asoc.2020.106181>
14. Stempień D., Ślepaczuk R. Hybrid Models for Financial Forecasting: Combining Econometric, Machine Learning, and Deep Learning Models. *arXiv*. 2025. DOI: <https://doi.org/10.48550/arXiv.2505.19617>

15. Li J.-C., Sun L.-P., Wu X., Tao C. Enhancing Financial Time Series Forecasting with Hybrid Deep Learning: CEEMDAN-Informer-LSTM Model. *Applied Soft Computing*. 2025. Vol. 177. Article 113241. DOI: <https://doi.org/10.1016/j.asoc.2025.113241>
16. Liu Y., Hu T., Zhang H., Wu H., Wang S., Ma L., Long M. iTransformer: Inverted Transformers Are Effective for Time Series Forecasting. *arXiv*. 2023. URL: <https://arxiv.org/abs/2310.06625> (дата звернення: 29.03.2026).
17. Hyndman R. J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne: OTexts, 2021. URL: <https://otexts.com/fpp3/> (дата звернення: 29.03.2026).
18. Makridakis S., Spiliotis E., Assimakopoulos V. The M4 Competition: 100,000 Time Series and 61 Forecasting Methods. *International Journal of Forecasting*. 2020. Vol. 36, Issue 1. P. 54–74. DOI: <https://doi.org/10.1016/j.ijforecast.2019.04.014>

## References

1. *Global Financial Stability Report, October 2024: Steadying the Course: Uncertainty, Artificial Intelligence, and Financial Stability*. (2024). Washington, DC: IMF. Retrieved from <https://www.imf.org/en/publications/gfsr/issues/2024/10/22/global-financial-stability-report-october-2024>
2. *The Financial Stability Implications of Artificial Intelligence*. (2024). Basel: FSB. Retrieved from <https://www.fsb.org/2024/11/the-financial-stability-implications-of-artificial-intelligence/>
3. OECD. (2024). Regulatory approaches to artificial intelligence in finance. *OECD Artificial Intelligence Papers*, 24. <https://doi.org/10.1787/f1498c02-en>
4. National Bank of Ukraine. (n.d.). *Developer API*. Retrieved from <https://bank.gov.ua/en/open-data/api-dev>
5. Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control* (5th ed.). Hoboken, NJ: Wiley.
6. Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307–327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
7. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
8. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). <https://doi.org/10.1145/2939672.2939785>
9. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30. Retrieved from <https://arxiv.org/abs/1706.03762>
10. Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30. Retrieved from <https://arxiv.org/abs/1705.07874>
11. Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
12. Rundo, F., Trenta, F., di Stallo, A. L., & Battiato, S. (2019). Machine learning for quantitative finance applications: A survey. *Applied Sciences*, 9(24), Article 5574. <https://doi.org/10.3390/app9245574>
13. Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*, 90, Article 106181. <https://doi.org/10.1016/j.asoc.2020.106181>
14. Stempień, D., & Ślepaczuk, R. (2025). Hybrid models for financial forecasting: Combining econometric, machine learning, and deep learning models. *arXiv*. <https://doi.org/10.48550/arXiv.2505.19617>
15. Li, J.-C., Sun, L.-P., Wu, X., & Tao, C. (2025). Enhancing financial time series forecasting with hybrid deep learning: CEEMDAN-Informer-LSTM model. *Applied Soft Computing*, 177, Article 113241. <https://doi.org/10.1016/j.asoc.2025.113241>
16. Liu, Y., Hu, T., Zhang, H., Wu, H., Wang, S., Ma, L., & Long, M. (2023). iTransformer: Inverted transformers are effective for time series forecasting. *arXiv*. Retrieved from <https://arxiv.org/abs/2310.06625>
17. Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). Melbourne: OTexts. Retrieved from <https://otexts.com/fpp3/>
18. Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54–74. <https://doi.org/10.1016/j.ijforecast.2019.04.014>

Дата першого надходження статті до видання: 01.04.2026

Дата прийняття статті до друку після рецензування: 28.04.2026

Дата публікації: 04.05.2026

**Pereguda Yuliya**

*Doctor of Economics, Associate Professor,  
Associate Professor of the Department of  
Global Economics  
National University of Life and  
Environmental Sciences of Ukraine  
Deputy Head of the Department of  
Organization of Tourism Activities,  
Professor at the Department of Organization  
of Tourism Activities  
Educational and Scientific Institute of  
Management, Economics and Business  
Interregional Academy of Personnel  
Management*

## HYBRID AI MODELS IN FINANCIAL FORECASTING

**Summary.** Introduction. Financial forecasting is an applied field in which model errors are rapidly transformed into economic consequences: liquidity losses, incorrect risk pricing, inefficient investment positions, or misleading signals for banking, monetary, portfolio, or regulatory decisions. In the current environment, financial time series forecasting is complicated not only by the growing volume of data but also by regime instability, volatility, information shocks, algorithmic trading, and the increasing complexity of financial behaviour. Under such conditions, single-model approaches often fail to capture the full structure of a financial signal. Classical econometric models remain useful for analysing autoregressive patterns and volatility, but they are limited in dealing with nonlinearities and high-dimensional feature spaces. Machine learning and deep learning models are better suited to nonlinear relationships and large sets of predictors, but they generate additional risks related to opacity, overfitting, instability, and limited auditability.

**Purpose.** The purpose of the article is to substantiate the theoretical and methodological foundations for applying hybrid artificial intelligence models in financial forecasting and to develop an architecture for their use in financial time series forecasting, taking into account predictive accuracy, regime stability, explainability, and model risk.

**Materials and methods.** The information base of the study consists of scientific publications on econometric, machine learning, and deep learning forecasting, studies on explainable artificial intelligence, international reports on the use of AI in finance, and open data from the National Bank of Ukraine. Methodologically, the article relies on the systematisation of sources, comparative analysis of modelling approaches, structural and functional modelling, generalisation of empirical research findings, and the principle of walk-forward validation for time series.

**Results.** The article substantiates a multilayer interpretation of financial time series by distinguishing linear, volatility, nonlinear, noise, and regime layers. The main types of hybrid AI models in financial forecasting are systematised, including sequential, decomposition-based, ensemble, stacking, and explainable hybrid architectures. The article develops a hybrid forecasting architecture that combines data collection, preprocessing, feature engineering, signal decomposition, base models, forecast aggregation, walk-forward validation, explainability, and model risk control. Based on official data from the National Bank of Ukraine, the article demonstrates the regime heterogeneity of the Ukrainian financial context in 2020–2026 using the dynamics of the USD/UAH exchange rate and the NBU key policy rate. It is shown that predictive accuracy is not identical to the financial usefulness of a decision, since practical application of a forecast requires consideration of liquidity, transaction costs, regulatory constraints, risk limits, and human oversight procedures.

**Discussion.** Further research should focus on full empirical testing of the proposed architecture using daily financial time series from the National Bank of Ukraine. Such testing should compare naive forecast, ARIMA/GARCH, XGBoost, LSTM, and hybrid models using MAE,

*RMSE, SMAPE, directional accuracy, and error estimates by currency and monetary regimes. A separate research direction should examine how forecasting errors are transformed into financial effects for banks, investors, importers, exporters, and regulators.*

**Key words:** *financial forecasting, hybrid models, artificial intelligence, time series, ARIMA, GARCH, XGBoost, LSTM, Transformer, explainable AI, model risk, National Bank of Ukraine.*