

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
Харківський національний університет імені В.Н. Каразіна
Факультет математики і інформатики
Кафедра теоретичної та прикладної інформатики

Кваліфікаційна робота магістр
на тему “ВИКОРИСТАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ
ПРОГНОЗУВАННЯ ВОЛАТИЛЬНОСТІ ФОНДОВИХ РИНКІВ НА ОСНОВІ
МАКРОЕКОНОМІЧНИХ ПОКАЗНИКІВ ТА ЗОВНІШНІХ ШОКОВИХ
ФАКТОРІВ”

Виконала: студентка 6 курсу, групи МФ-61
спеціальність 122 «Комп’ютерні науки»
освітньо-наукова програма «Теоретична і
прикладна інформатика»
Свиридова Дар’я Михайлівна
Керівник: Панченко Артем Сергійович

АНОТАЦІЯ

СВИРИДОВА ДАР'Я МИХАЙЛІВНА. ВИКОРИСТАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ ПРОГНОЗУВАННЯ ВОЛАТИЛЬНОСТІ ФОНДОВИХ РИНКІВ НА ОСНОВІ МАКРОЕКОНОМІЧНИХ ПОКАЗНИКІВ ТА ЗОВНІШНІХ ШОКОВИХ ФАКТОРІВ – Кваліфікаційна робота на здобуття освітнього рівня магістр – Харківський національний університет імені В. Н. Каразіна, Міністерства освіти і науки України, Харків, 2026.

Дипломна робота присвячена розробці моделі прогнозування волатильності фондових ринків в умовах складної динаміки, міжсекторних залежностей та впливу зовнішніх факторів.

Дослідження охоплює побудову багатокомпонентної системи, що поєднує графове моделювання міжсекторних зв'язків, аналіз зовнішніх факторів та нейромережеву модель прогнозування з використанням сучасних методів машинного навчання. Запропонований підхід дозволяє інтегрувати фінансові, макроекономічні, інституційні та соціально-культурні дані в єдину модель.

У вступі обґрунтовано актуальність теми, сформульовано мету та задачі дослідження, визначено об'єкт і предмет дослідження. Методи дослідження включають теорію графів для моделювання міжсекторних залежностей, методи аналізу часових рядів, машинне та глибоке навчання (графові нейронні мережі, трансформери), а також ймовірнісне моделювання.

У першому розділі проведено аналіз існуючих підходів до прогнозування волатильності, включаючи економетричні та машинно-навчальні моделі, а також методи врахування зовнішніх факторів.

У другому розділі представлено розроблену архітектуру моделі, що поєднує графові залежності, часову динаміку та екзогенні змінні, описано pipeline підготовки даних, включаючи нормалізацію, узгодження частот та формування ознак.

У третьому розділі реалізовано навчання моделі, проведено walk-forward валідацію, оцінено якість прогнозів та виконано порівняльний аналіз з базовими підходами.

У роботі вирішена задача побудови адаптивної моделі прогнозування волатильності, здатної враховувати складну структуру фінансових ринків та зовнішні впливи.

Наукова новизна полягає у розробці комплексного підходу, що поєднує графові моделі, трансформерні архітектури та екзогенні фактори в єдиній системі прогнозування. Практичне значення полягає у створенні програмної системи, що дозволяє виконувати прогнозування волатильності та аналіз ризиків для підтримки інвестиційних рішень.

Сукупність отриманих результатів дозволяє вважати поставлену мету досягнутою.

ABSTRACT

SVYRYDOVA DARIA MYKHAILIVNA. APPLICATION OF MACHINE LEARNING METHODS FOR STOCK MARKET VOLATILITY FORECASTING BASED ON MACROECONOMIC INDICATORS AND EXTERNAL SHOCK FACTORS – Master's Thesis – V. N. Karazin Kharkiv National University, Ministry of Education and Science of Ukraine, Kharkiv, 2026.

The thesis is devoted to the development of a model for stock market volatility forecasting under conditions of complex dynamics, inter-sector dependencies, and external influences.

The study covers the design of a multi-component system that combines graph-based modeling of sector relationships, external factor analysis, and a neural forecasting model using modern machine learning approaches. The proposed framework enables the integration of financial, macroeconomic, institutional, and socio-cultural data into a unified predictive system.

The introduction substantiates the relevance of the research, defines the goal and objectives, and specifies the object and subject of the study. The research methods include graph theory for modeling inter-sector dependencies, time series analysis, machine and deep learning (graph neural networks, transformers), and probabilistic modeling.

The first chapter provides an analysis of existing approaches to volatility forecasting, including econometric and machine learning models, as well as methods for incorporating external factors.

The second chapter presents the proposed model architecture, integrating graph structures, temporal dynamics, and exogenous variables, and describes the data processing pipeline, including normalization, frequency alignment, and feature engineering.

The third chapter implements model training, applies walk-forward validation, evaluates forecasting performance, and provides a comparative analysis with baseline approaches.

The thesis addresses the problem of constructing an adaptive volatility forecasting model capable of capturing the complex structure of financial markets and external influences.

The scientific novelty lies in the development of an integrated approach that combines graph-based models, transformer architectures, and exogenous factors within a unified forecasting system. The practical significance lies in the implementation of a software system for volatility forecasting and risk analysis to support investment decision-making.

The obtained results confirm that the stated objective has been achieved.

ЗМІСТ

ВСТУП	3
РОЗДІЛ 1. АНАЛІЗ ПІДХОДІВ ДО ПРОГНОЗУВАННЯ ВОЛАТИЛЬНОСТІ ФОНДОВИХ РИНКІВ	5
1.1. Класичні моделі волатильності та проблематика її вимірювання	5
1.2. Реалізована волатильність та еталонні моделі	7
1.3. Режимні моделі та структурні злами.....	10
1.4. Класичні ML-підходи.....	13
1.5. Глибоке навчання	16
1.6. Спілловери та зв'язаність	20
1.7. Графові методи	24
1.8. Ризикові метрики та оцінка	28
1.9. Зовнішні фактори	33
Висновки до розділу 1	38
РОЗДІЛ 2. РОЗРОБКА ТА РЕАЛІЗАЦІЯ МОДЕЛІ ПРОГНОЗУВАННЯ.....	41
2.1. Загальна архітектура системи.....	41
2.1.1. Концептуальна схема моделі.....	41
2.1.2. Повна архітектурна схема моделі.....	44
2.1.3. Формалізація задачі	46
2.2. Архітектура моделі	47
2.2.1. Графова модель ринку (Round 1).....	47
2.2.2. Аналіз зовнішніх факторів (Round 2)	49
2.2.3. Dual Graph Encoder	51
2.2.4. Temporal Transformer.....	52

2.2.5. Cross-Attention (інтеграція зовнішніх факторів).....	53
2.2.6. Regime Detection.....	55
2.2.7. Mixture of Experts	56
2.2.8. Quantile Regression Output.....	57
2.3. Датасети	58
2.3.1. Секторні фінансові дані.....	58
2.3.2. Інституційні фактори.....	59
2.3.3. Соціально-культурні фактори	61
2.4. Нормалізація та підготовка даних	62
2.4.1. Фінансові дані	62
2.4.2. WGI.....	63
2.4.3. WVS.....	65
2.4.4. Узгодження частот	67
2.5. Навчання моделі	69
2.5.1. Триетапний pipeline	69
2.5.2. Walk-forward валідація.....	72
2.5.3. Loss-функції.....	73
2.5.4. Метрики	74
2.6. Інференс та застосування	76
2.6.1. Генерація прогнозів	76
2.6.2. API	77
2.7. Інтерпретація моделі.....	78
Висновки до розділу 2	79
РОЗДІЛ 3. ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ТА АНАЛІЗ	
РЕЗУЛЬТАТІВ МОДЕЛІ	83

3.1. Загальна постановка експерименту.....	83
3.2. Аналіз міжсекторної кореляційної структури ринку.....	85
3.3. Аналіз групових напрямлених впливів між секторами.....	88
3.4. Аналіз впливу інституційних факторів WGI.....	93
3.5. Аналіз впливу соціально-культурних факторів WVS.....	98
3.6. Оцінювання якості фінальної прогнозовної моделі Round 3	104
3.7. Аналіз стійкості результатів у часі	109
3.8. Аналіз результатів за ринковими режимами	111
3.9. Інтерпретація отриманих результатів та практичне значення моделі	114
Висновки до розділу 3	117
ВИСНОВКИ.....	119
СПИСОК ДЖЕРЕЛ ТА ЛІТЕРАТУРИ	122

ВСТУП

Актуальність теми. Стрімке зростання складності фінансових ринків, збільшення обсягів торгівлі та підвищення ролі зовнішніх факторів вимагають розробки адаптивних підходів до прогнозування волатильності. Класичні економетричні моделі, засновані на припущеннях стаціонарності та обмеженій кількості факторів, не забезпечують необхідної гнучкості в умовах структурних зламів, режимних змін та екзогенних шоків. Актуальність дослідження полягає у створенні науково обґрунтованого підходу до інтеграції міжсекторних залежностей, часової динаміки та зовнішніх факторів у єдиній моделі прогнозування.

Мета та задачі дослідження. Метою дипломної роботи є розробка моделі прогнозування волатильності фондових ринків на основі машинного навчання з урахуванням міжсекторних взаємозв'язків та зовнішніх факторів. Для досягнення зазначеної мети були поставлені та вирішені наступні задачі:

1. Аналіз існуючих підходів до моделювання та прогнозування волатильності фінансових ринків.
2. Аналіз сучасних методів машинного навчання та їх застосування у задачах фінансового прогнозування.
3. Формалізація задачі прогнозування волатильності з урахуванням багатовимірних часових рядів та екзогенних факторів.
4. Розробка архітектури моделі, що поєднує графові підходи, часове моделювання та механізми уваги.
5. Програмна реалізація багатокомпонентного pipeline обробки даних та навчання моделі.
6. Визначення критеріїв оцінки якості прогнозування та реалізація їх розрахунку.
7. Проведення експериментального дослідження та аналіз отриманих результатів.

Об’єктом дослідження є процеси формування та динаміки волатильності фондових ринків як складної багатовимірної системи.

Предметом дослідження є математичні моделі, методи та алгоритми прогнозування волатильності, зокрема методи машинного навчання, графові моделі та підходи до інтеграції екзогенних факторів.

Методи дослідження. Дослідження виконано із застосуванням наступних принципів та методів:

1. Методи теорії графів для моделювання міжсекторних залежностей фінансового ринку.
2. Методи аналізу часових рядів для опису динаміки фінансових показників.
3. Методи машинного та глибокого навчання, зокрема графові нейронні мережі, трансформерні архітектури та механізми уваги.
4. Методи ймовірнісного моделювання, зокрема квантільна регресія для оцінювання невизначеності прогнозів.
5. Об’єктно-орієнтоване програмування (мова Python) для реалізації системи обробки даних, навчання та інференсу моделі.

Наукова новизна отриманих результатів полягає у розробці комплексного підходу до прогнозування волатильності, що поєднує графове представлення міжсекторних залежностей, нейромережеву модель з урахуванням часової динаміки та зовнішніх факторів, а також поетапний pipeline підготовки даних.

Практичне значення отриманих результатів полягає у створенні програмної системи для прогнозування волатильності, оцінювання ризиків та аналізу впливу факторів на ринкову динаміку, що може бути використана для підтримки інвестиційних рішень і подальших досліджень.

Дипломна робота складається зі вступу, трьох розділів основної частини, висновків та списку літератури. Обсяг роботи 128 сторінок друкованого тексту, містить 25 ілюстрацій, 12 таблиць, експериментальні графіки та результати моделювання.

РОЗДІЛ 1. АНАЛІЗ ПІДХОДІВ ДО ПРОГНОЗУВАННЯ ВОЛАТИЛЬНОСТІ ФОНДОВИХ РИНКІВ

1.1. Класичні моделі волатильності та проблематика її вимірювання

Волатильність є однією з базових характеристик фінансового ринку, що відображає ступінь мінливості дохідностей активу та використовується як кількісна міра ринкового ризику. У класичному статистичному підході вона найчастіше інтерпретується як стандартне відхилення дохідностей за певний часовий проміжок, тобто як величина σ , що узагальнює інтенсивність коливань цінового процесу [1]. Така форма вимірювання є зручною для базового аналізу, однак вона не повністю відображає часову неоднорідність фінансових рядів, оскільки реальна ринкова динаміка характеризується періодами різної інтенсивності коливань.

Одним із ключових емпіричних фактів фінансових часових рядів є умовна гетероскедастичність, тобто змінність дисперсії у часі. Це означає, що волатильність не є сталою величиною: періоди високої мінливості мають тенденцію групуватися разом, так само як і періоди відносної стабільності. Така властивість відома як кластеризація волатильності й стала однією з причин появи моделей ARCH, у яких поточна умовна дисперсія залежить від квадратів попередніх залишків [2].

Узагальненням ARCH-підходу стала модель GARCH, яка враховує не лише попередні шоки, а й лагові значення самої умовної дисперсії [3]. Завдяки цьому GARCH-модель краще описує інерційність волатильності та її здатність зберігатися протягом певного часу після ринкових збурень. Саме тому моделі GARCH-сімейства стали базовим економетричним інструментом для аналізу та прогнозування волатильності фінансових активів.

Подальший розвиток цього напрямку був пов'язаний із необхідністю врахування асиметричної реакції ринку на позитивні та негативні шоки. У моделі EGARCH така асиметрія враховується через логарифмічне моделювання умовної дисперсії, що дозволяє описувати різний вплив сприятливих і несприятливих новин на волатильність [4]. Це важливо, оскільки на фінансових ринках негативні інформаційні шоки часто спричиняють сильнішу реакцію волатильності, ніж позитивні шоки аналогічної величини.

Інший варіант урахування асиметрії запропоновано у GJR-GARCH, де негативні шоки мають окремий вплив на умовну дисперсію [5]. Такий підхід дозволяє краще моделювати так званий leverage effect, тобто ситуацію, коли падіння цін активів супроводжується зростанням майбутньої волатильності. Отже, розширення GARCH-сімейства стало спробою наблизити класичні моделі до реальної поведінки фінансових ринків.

Водночас класичні моделі волатильності мають принципові обмеження. По-перше, вони здебільшого орієнтовані на відносно стабільну параметричну структуру, тоді як фінансові ринки можуть переходити між різними станами, зокрема фазами зростання, спаду або кризової турбулентності. Ідея моделювання таких переходів була формалізована у підході Markov switching, де параметри процесу залежать від прихованого режиму, у якому перебуває система [6]. Для задач прогнозування волатильності це означає, що одна й та сама модель із фіксованими параметрами може бути недостатньою для опису різних фаз ринку.

По-друге, класичні моделі часто розглядають окремий актив або ринок ізольовано. Така постановка задачі є обмеженою, оскільки сучасні фінансові ринки функціонують як взаємопов'язана система, де шоки можуть поширюватися між активами, секторами та країнами. У дослідженнях, присвячених прогнозуванню реалізованих коваріацій, підкреслюється, що ігнорування структурних зв'язків між активами призводить до втрати важливої інформації про міждринкову динаміку та ускладнює побудову точних прогнозів [7].

Таким чином, класичні моделі волатильності, зокрема ARCH, GARCH та їх асиметричні розширення, забезпечують важливу теоретичну основу для аналізу фінансових часових рядів. Вони дозволяють формалізувати змінність дисперсії у часі, врахувати кластеризацію волатильності та частково описати асиметричну реакцію ринку на інформаційні шоки [2–5]. Проте їх обмеження, пов'язані з припущенням відносної стабільності параметрів, слабкою адаптацією до режимних змін та ізольованим розглядом активів, обумовлюють необхідність переходу до більш гнучких моделей, здатних враховувати структурні зміни, міжринкові залежності та складну нелінійну динаміку фінансових ринків [6, 7].

1.2. Реалізована волатильність та еталонні моделі

Подальший розвиток моделей волатильності пов'язаний із переходом від умовної дисперсії, що оцінюється в межах параметричних моделей, до більш безпосереднього вимірювання фактичної мінливості ринку. Одним із ключових інструментів такого підходу є реалізована волатильність (realized volatility, RV), яка ґрунтується на агрегуванні внутрішньоденних дохідностей і використовується як більш точний проксі латентної волатильності [1]. На відміну від класичного вимірювання волатильності через стандартне відхилення дохідностей, RV дозволяє врахувати більшу кількість інформації про рух цін у межах торгового дня, тому краще відображає фактичну інтенсивність ринкових коливань [1].

Теоретичною основою realized-підходу є припущення, що інтегрована дисперсія неперервного цінового процесу може бути апроксимована сумою квадратів високочастотних дохідностей [1]. Це робить RV важливим елементом сучасної фінансової економетрики, оскільки вона дає змогу перейти від непрямого оцінювання волатильності до її більш емпірично насиченого представлення. У контексті задач прогнозування це особливо важливо, оскільки

якість прогнозу значною мірою залежить не лише від обраної моделі, а й від того, наскільки коректно виміряно саму цільову змінну [1].

Однією з найважливіших властивостей реалізованої волатильності є ефект довгої пам'яті (long memory), який проявляється у стійкій залежності поточного рівня волатильності від її попередніх значень на різних часових горизонтах. Для опису цієї властивості Corsi запропонував HAR-RV модель, що представляє realized volatility як комбінацію добової, тижневої та місячної компонент [8]. Такий підхід дозволяє описати багатомасштабну природу волатильності без формального використання складних фракційно-інтегрованих моделей, що є важливим з погляду інтерпретованості та практичного застосування [8].

HAR-RV стала одним із найбільш поширених еталонних підходів у прогнозуванні реалізованої волатильності, оскільки поєднує простоту оцінювання з можливістю відтворювати основні стилізовані факти фінансових часових рядів [8]. У порівнянні з класичними GARCH-моделями, які описують умовну дисперсію через лагові шоки та попередні значення дисперсії [2, 3], HAR-RV безпосередньо працює з realized-показником і тому краще пристосована до задач, де важливо врахувати різні горизонти ринкової пам'яті [8].

Подальшим розвитком realized-підходів стала модель Realized GARCH, яка поєднує логіку класичних GARCH-моделей із використанням realized measures як додаткового інформаційного джерела [9]. У цій моделі умовна дисперсія не розглядається лише як прихована величина, що виводиться з дохідностей, а узгоджується з емпірично спостережуваними realized-показниками [9]. Завдяки цьому Realized GARCH дозволяє зменшити розрив між латентною волатильністю та її фактичними ринковими проксі, що підвищує якість оцінювання і прогнозування [9].

Водночас використання realized volatility не усуває всіх проблем вимірювання. Високочастотні дані можуть містити мікроструктурний шум, ефекти нерівномірної торгівлі та різкі стрибки цін, які спотворюють просту суму квадратів внутрішньоденних дохідностей [10]. Для зменшення таких викривлень у літературі застосовуються робастні оцінювачі, зокрема bipower variation та

related realized measures, які дозволяють відокремлювати неперервну компоненту волатильності від стрибкових рухів [10]. Це має значення для подальшого моделювання, оскільки некоректний проксі волатильності може спричинити помилкові висновки щодо якості прогнозової моделі [10].

Окремою проблемою є порівняння моделей за умов, коли сама волатильність є неспостережуваною, а її realized-проксі є лише наближенням. Patton показує, що використання недосконалих проксі може впливати на результати forecast comparison, тому вибір функції втрат має бути робастним до похибок вимірювання [11]. У цьому контексті QLIKE часто розглядається як одна з придатних функцій втрат для порівняння прогнозів волатильності, оскільки вона краще поводить за умов наявності measurement error у проксі-змінній [11]. Отже, оцінювання моделей волатильності має спиратися не лише на RMSE або MAE, а й на loss-функції, які коректніше враховують природу самої цільової змінної [11].

Попри переваги RV, HAR-RV та Realized GARCH, ці підходи мають важливе обмеження: більшість із них фокусуються на окремому активі або окремому часовому ряді й недостатньо враховують міжринкові та міжсекторні залежності. У дослідженнях з прогнозування реалізованих коваріацій підкреслюється, що моделювання волатильності без урахування взаємозв'язків між активами втрачає суттєву частину інформації про структуру ринку [7]. Це особливо важливо для задачі прогнозування секторної волатильності, оскільки шоки можуть поширюватися між галузями, активами та ринками, формуючи складну систему залежностей [7].

Таким чином, реалізована волатильність і пов'язані з нею еталонні моделі, зокрема HAR-RV та Realized GARCH, забезпечують важливу базу для сучасного прогнозування волатильності. Вони дозволяють точніше вимірювати ринкову мінливість, враховувати long memory ефекти та узгоджувати умовну дисперсію з realized-показниками [1, 8, 9]. Водночас проблеми мікроструктурного шуму, недосконалості volatility proxies, вибору функцій втрат і слабого врахування міжринкових залежностей обумовлюють необхідність переходу до більш

складних моделей, здатних поєднувати realized-підходи з графовими структурами, зовнішніми факторами та методами машинного навчання [7, 10, 11].

1.3. Режимні моделі та структурні злами

Фінансові ринки рідко залишаються в одному стабільному стані протягом тривалого часу. Періоди відносного зростання можуть змінюватися фазами спаду, кризової турбулентності або підвищеної невизначеності, що безпосередньо впливає на рівень волатильності, структуру кореляцій та якість прогнозування. Саме тому припущення про сталість параметрів моделі, характерне для багатьох класичних підходів, є суттєвим обмеженням під час аналізу фінансових часових рядів [6].

Базовим підходом до формального опису таких змін є моделі з перемиканням режимів. У моделі Markov switching, запропонованій Дж. Гамільтоном, динаміка часового ряду залежить від прихованого стану системи, а перехід між станами задається марковським процесом [6]. Це означає, що один і той самий фінансовий ряд може описуватися різними параметрами залежно від того, у якому ринковому режимі він перебуває. Для задач прогнозування волатильності така логіка є принципово важливою, оскільки періоди стабільності та кризові періоди мають різну структуру ризику [6].

Подальшим розвитком цієї ідеї є приховані марковські моделі (Hidden Markov Models, HMM), у яких реальний режим ринку не спостерігається безпосередньо, але може бути оцінений на основі динаміки спостережуваних змінних [12]. У фінансовому контексті такими змінними можуть виступати дохідності, волатильність, GARCH-оцінки умовної дисперсії, технічні індикатори або їх комбінації. HMM дозволяють ідентифікувати латентні стани ринку та використовувати ці стани як окремі ознаки у подальших прогнозних моделях [12].

З практичної точки зору ринкові режими часто інтерпретуються як фази bull market, bear market та crisis regime. Перша фаза відповідає відносно сприятливій динаміці зростання, друга — періодам зниження або переоцінки ризику, а третя — станам різкого зростання волатильності, посилення невизначеності та нестабільності міжринкових зв'язків [6]. Такий поділ не є суто описовим: він дозволяє моделі враховувати, що однакові за величиною зміни дохідностей можуть мати різне значення залежно від поточного стану ринку.

У сучасних гібридних підходах НММ часто використовуються не як самостійна кінцева модель, а як блок формування режимних ознак. Наприклад, у дослідженні, присвяченому trading strategy для SPY ETF, Hidden Markov Models застосовувалися для виділення трьох станів волатильності: low, moderate та high volatility [13]. При цьому режими будувалися як на сирих дохідностях, так і на GARCH-adjusted returns, після чого відповідні regime labels використовувалися як додаткові вхідні ознаки для LSTM та DNN моделей [13]. Такий підхід демонструє, що режимна інформація може бути інтегрована у нейромережеву архітектуру як компактне представлення поточного стану ринку.

У контексті цієї роботи режимна логіка є особливо релевантною, оскільки запропонована модель орієнтована не лише на прогнозування окремого ряду, а на врахування секторної динаміки та змін ринкового середовища. Якщо волатильність секторів оцінюється незалежно від режиму, модель ризикує змішати принципово різні ринкові ситуації в один узагальнений шаблон. Наприклад, зв'язки між секторами в період стабільного зростання можуть суттєво відрізнятися від зв'язків у кризовий період, коли кореляції часто посилюються, а шоки поширюються швидше [7].

Саме тому режимні ознаки можуть бути використані як проміжний шар між класичним вимірюванням волатильності та більш складною архітектурою прогнозування. У такій постановці ринковий режим не замінює основні фінансові змінні, а доповнює їх, пояснюючи, у якому структурному контексті ці змінні формуються. Це створює основу для адаптивних моделей, де одна й та

сама вхідна динаміка може оброблятися по-різному залежно від поточного режиму [13].

Для узагальнення ролі режимних моделей у задачах прогнозування волатильності доцільно виділити їхні основні функції, наведені у таблиці 1.1.

Таблиця 1.1 — Роль режимних моделей у прогнозуванні волатильності

Підхід	Основна ідея	Роль у прогнозуванні
Markov switching	Параметри часового ряду залежать від прихованого режиму	Дозволяє врахувати структурні зміни та зміну фаз ринку [6]
HMM	Режими не спостерігаються прямо, а оцінюються за даними	Дає змогу виділяти low / medium / high volatility states [12, 13]
HMM + GARCH features	Режими будуються з урахуванням умовної волатильності	Підвищує чутливість моделі до змін ринкового середовища [3, 13]
Regime labels у DL-моделях	Режим використовується як додаткова ознака	Дозволяє нейромережі навчатися режимно-залежних патернів [13]

Водночас режимні моделі мають низку обмежень. Однією з головних проблем є вибір кількості режимів: занадто мала кількість станів може спростити реальну структуру ринку, тоді як занадто велика — призвести до нестійких оцінок і перенавчання [12]. Крім того, параметри режимних моделей можуть бути чутливими до вибірки, періоду оцінювання та способу попередньої обробки даних. Це особливо критично для фінансових ринків, де історичні закономірності можуть швидко втрачати актуальність після криз, регуляторних змін або зовнішніх шоків [6].

Ще одним обмеженням є те, що класичні Markov switching та HMM-підходи зазвичай описують режими окремого часового ряду, але не завжди враховують складну мережеву структуру ринку. У задачах секторного прогнозування цього

недостатньо, оскільки режим може змінюватися не лише всередині окремого сектору, а й на рівні всієї системи міжсекторних зв'язків [7]. Тому для подальшого розвитку моделі режимна інформація має поєднуватися з графовим представленням ринку, зовнішніми факторами та адаптивними нейромережевими механізмами.

Таким чином, режимні моделі та підходи до виявлення структурних зламів є важливим етапом переходу від статичного прогнозування волатильності до адаптивного моделювання фінансових ринків. Markov switching дозволяє формалізувати зміну параметрів між прихованими станами, НММ забезпечує практичний інструмент виявлення латентних ринкових фаз, а використання режимних ознак у гібридних моделях створює основу для врахування різної поведінки ринку в періоди стабільності, спаду та кризової турбулентності [6, 12, 13]. Для цієї роботи це є логічним підґрунтям подальшої побудови моделі, здатної адаптуватися до змін ринкового середовища та не розглядати волатильність як процес із незмінною структурою.

1.4. Класичні ML-підходи

Після розвитку економетричних та режимних моделей окремим напрямом прогнозування волатильності стали класичні методи машинного навчання. На відміну від ARCH/GARCH-підходів, які задають жорстку параметричну форму залежності між минулими шоками та умовною дисперсією [2, 3], ML-моделі дозволяють працювати з ширшим набором ознак і виявляти нелінійні залежності між фінансовими, технічними та макроекономічними змінними [14]. Це робить їх корисними в задачах, де ринкова динаміка не може бути повністю описана лише лагами дохідності або волатильності.

До класичних ML-підходів у фінансовому прогнозуванні належать регресійні моделі, Support Vector Regression (SVR), Random Forest, Gradient Boosting та XGBoost. Регресійні моделі використовуються як базовий

інтерпретований підхід, що дозволяє оцінити зв'язок між цільовою змінною та набором факторів. Їх перевагою є простота та прозорість, однак вони мають обмежену здатність відображати нелінійні залежності, які є характерними для фінансових часових рядів [14].

SVR є більш гнучким підходом, оскільки дозволяє моделювати нелінійні залежності за допомогою ядерних функцій. У задачах прогнозування волатильності SVR може працювати з лагами реалізованої волатильності, технічними індикаторами та зовнішніми змінними, формуючи прогноз без прямого припущення про конкретну економетричну структуру процесу [14]. Проте якість SVR істотно залежить від вибору ядра, параметрів регуляризації та налаштування ширини ϵ -зони, що підвищує ризик нестабільності результатів на різних вибірках.

Random Forest належить до ансамблевих tree-based моделей і використовує сукупність дерев рішень, побудованих на різних підвибірках даних та ознак. Такий підхід дозволяє зменшити ризик перенавчання окремого дерева та краще враховувати нелінійні взаємодії між предикторами [14]. Для фінансових даних це важливо, оскільки вплив факторів на волатильність часто є неадитивним: один і той самий технічний або макроекономічний сигнал може мати різне значення залежно від ринкового режиму, рівня ризику та попередньої динаміки [6, 13].

Близьким за логікою, але більш послідовним підходом є gradient boosting, зокрема XGBoost. На відміну від Random Forest, який будує дерева відносно незалежно, boosting-моделі додають нові дерева так, щоб вони виправляли помилки попередніх. Це робить XGBoost ефективним у задачах з великою кількістю ознак, де потрібно виділити складні нелінійні взаємозв'язки між лагами, технічними індикаторами та зовнішніми змінними [14].

Емпіричні результати сучасних досліджень показують, що традиційні ML-моделі можуть перевищувати еталонні економетричні підходи за точністю прогнозу. Зокрема, у роботі, присвяченій прогнозуванню волатильності за допомогою CNN-BiLSTM-Attention, SVR, Random Forest та XGBoost

порівнюються з HAR-RV, LSTM та глибокими гібридними моделями [14]. За показниками MSE, RMSE і MAE ці класичні ML-моделі демонструють кращі результати, ніж HAR-RV, що підтверджує їхню здатність ефективніше працювати з нелінійними предикторами [14].

Для узагальнення ролі класичних ML-моделей у задачах прогнозування волатильності доцільно виділити їхні основні переваги та обмеження.

Порівняльну характеристику подано у табл. 1.2.

Таблиця 1.2 — Класичні ML-підходи у прогнозуванні волатильності

Підхід	Основна перевага	Основне обмеження
Регресійні моделі	Простота, інтерпретованість, зручність як baseline	Обмежена здатність описувати нелінійні залежності [14]
SVR	Моделювання нелінійних зв'язків через ядрові функції	Чутливість до вибору ядра та гіперпараметрів [14]
Random Forest	Стійкість до шуму, робота з нелінійними взаємодіями	Слабке пряме врахування часової послідовності [14]
XGBoost	Висока точність на табличних ознаках, послідовне виправлення помилок	Ризик перенавчання та потреба в ретельному налаштуванні [14]

Водночас важливо підкреслити, що класичні ML-підходи не розв'язують повністю проблему часової структури фінансових рядів. Більшість із них працює з даними як із табличною матрицею ознак, тому часовий порядок не враховується безпосередньо, а лише задається через ручне створення лагів, ковзних статистик або технічних індикаторів [14]. Це означає, що модель може виявити нелінійний зв'язок між ознаками, але не обов'язково здатна коректно відтворити довготривалі часові залежності, які є характерними для волатильності [8].

Це обмеження особливо суттєве для задачі прогнозування фондових ринків з урахуванням зовнішніх факторів. Макроекономічні індикатори,

індекси фінансового стресу, політична невизначеність та технічні показники можуть мати різну частоту оновлення, різні лаги впливу та різну силу сигналу залежно від ринкового режиму [15]. У дослідженні Latif та ін. показано, що інтеграція макроекономічних і технічних індикаторів підвищує якість прогнозування, а серед значущих факторів виділяються VIX, Financial Stress Index та Economic Policy Uncertainty [15]. Для класичних ML-моделей це означає потребу в ретельному feature engineering, оскільки без правильно сформованих лагів і частотного узгодження модель може втратити важливу часову інформацію.

Таким чином, класичні ML-підходи є важливим проміжним етапом між економетричними моделями та глибоким навчанням. SVR, Random Forest і XGBoost здатні краще за класичні лінійні моделі працювати з нелінійними залежностями та різнорідними ознаками [14]. Проте їхня слабкість полягає в тому, що часова структура ряду не моделюється природно, а має бути попередньо закодована через лаги, rolling-ознаки або інші інженерні перетворення [8, 14]. Саме це обмеження пояснює подальший перехід до глибоких нейромережових моделей, які здатні безпосередніше працювати з послідовностями та складною динамікою фінансових ринків.

1.5. Глибоке навчання

Глибоке навчання стало наступним етапом розвитку моделей прогнозування фінансових часових рядів після класичних економетричних і традиційних ML-підходів. Його перевага полягає у здатності автоматично формувати внутрішні представлення даних і виявляти складні нелінійні залежності, які не завжди можуть бути задані вручну через лаги, rolling-ознаки або технічні індикатори [16]. Для задач прогнозування волатильності це особливо важливо, оскільки фінансові ряди поєднують короткострокові шоки, довгострокову пам'ять, режимні зміни та вплив зовнішніх факторів [8, 13].

Одним із перших класів глибоких моделей, які активно застосовувалися до фінансових часових рядів, стали рекурентні нейронні мережі (Recurrent Neural Networks, RNN). Їхня архітектура дозволяє враховувати попередні стани послідовності, що робить RNN природним інструментом для аналізу часової динаміки [17]. Водночас класичні RNN мають суттєве обмеження, пов'язане з проблемами зникання та вибуху градієнтів, через що вони недостатньо ефективно зберігають довгострокові залежності у фінансових рядах [17].

Для подолання цих обмежень були розроблені LSTM-моделі, які використовують механізми “воріт” для контролю збереження, оновлення та забування інформації у пам’яті мережі [17]. Завдяки цьому LSTM краще пристосована до задач, де поточний стан ринку залежить не лише від останніх спостережень, а й від віддалених попередніх подій. У фінансовому прогнозуванні LSTM часто використовується разом із GARCH-ознаками, HMM-режимами, технічними індикаторами та макроекономічними змінними, що дозволяє поєднати економетричну інтерпретованість із здатністю нейромереж до нелінійного узагальнення [13].

Близькою до LSTM архітектурою є GRU, яка також використовує механізми керування інформаційним потоком, але має простішу структуру та меншу кількість параметрів [17]. Це робить GRU привабливою для фінансових задач, де важлива не лише точність, а й обчислювальна ефективність. У сучасних дослідженнях GRU часто використовується в гібридних моделях, зокрема разом з Informer або декомпозиційними методами, що дозволяє розділяти часовий ряд на компоненти різної складності та обробляти їх різними блоками моделі [18].

Окремим напрямом є використання згорткових нейронних мереж (Convolutional Neural Networks, CNN) для вилучення ознак із фінансових часових рядів. На відміну від RNN/LSTM/GRU, які фокусуються на послідовній залежності, CNN добре виявляють локальні патерни у вхідних даних, зокрема короткострокові імпульси, локальні зміни тренду та мікроструктурні сигнали [16]. У гібридних архітектурах CNN часто застосовується як feature extraction

блок перед рекурентним або attention-шаром, що дозволяє спочатку виділити локальні закономірності, а потім передати їх у модель часової залежності [14].

Прикладом такого підходу є CNN-BiLSTM-Attention модель для прогнозування волатильності з використанням змішаної частоти даних [14]. У ній CNN використовується для вилучення локальних ознак, BiLSTM — для опрацювання двонапрямленої часової залежності, а attention-механізм — для зважування найбільш значущих компонент інформації [14]. Така архітектура є релевантною для задачі цієї роботи, оскільки вона демонструє можливість поєднання фінансових рядів із зовнішніми чинниками різної частоти, що відповідає ідеї інтеграції ринкових, макроекономічних та інституційних показників [14, 15].

Механізми уваги (attention) стали важливим кроком у розвитку глибоких моделей часових рядів, оскільки дозволяють моделі не лише послідовно обробляти дані, а й виділяти найбільш релевантні часові моменти або групи ознак [17]. Для прогнозування волатильності це означає, що модель може надавати більшу вагу тим періодам, де спостерігалися різкі зміни ризику, зовнішні шоки або зміна ринкового режиму [13, 14]. У порівнянні з класичними RNN-підходами attention-механізми краще пристосовані до задач, де важлива взаємодія між віддаленими часовими точками [17].

На основі attention-механізмів сформувався окремий клас Transformer-моделей. У часових рядах Transformers дають змогу моделювати довгі залежності без послідовної обробки кожного кроку, що підвищує масштабованість і робить їх ефективними для багатогоризонтного прогнозування [19]. У літературі підкреслюється, що Transformer-варіанти, зокрема Informer, Autoformer, FEDformer, Crossformer та PatchTST, часто демонструють високу якість на задачах довгих послідовностей, хоча потребують значних обчислювальних ресурсів і ретельного контролю стабільності навчання [18, 19].

Для задач фінансового прогнозування особливо важливими є Transformer-моделі з пояснювальними змінними, оскільки вони дозволяють поєднувати

історичні ринкові дані з макроекономічними, технічними, політичними або сентиментними факторами [19]. Такий підхід безпосередньо узгоджується з логікою цієї роботи, де прогнозування секторної волатильності має враховувати не лише внутрішню динаміку секторів, а й зовнішнє інформаційне середовище [15, 19].

Для узагальнення ролі основних глибоких архітектур у прогнозуванні волатильності доцільно подати їх порівняльну характеристику у табл. 1.3.

Таблиця 1.3 — Основні архітектури глибокого навчання у прогнозуванні волатильності

Архітектура	Основна роль	Ключове обмеження
RNN	Базове моделювання послідовностей	Слабке збереження довгострокових залежностей [17]
LSTM	Обробка довгих часових залежностей через механізми пам'яті	Висока кількість параметрів і ризик перенавчання [13, 17]
GRU	Спрощене рекурентне моделювання з меншою кількістю параметрів	Може втрачати частину складної довгострокової структури [17, 18]
CNN	Вилучення локальних патернів та короткострокових сигналів	Не моделює довгі залежності без додаткових блоків [14, 16]
Attention / Transformer	Виявлення релевантних часових і факторних залежностей	Обчислювальна складність і нестабільність навчання [18, 19]

Попри високу точність, глибокі моделі мають низку суттєвих проблем. Передусім вони часто розглядаються як black-box системи, оскільки внутрішні представлення, сформовані багатьма шарами, важко інтерпретувати у термінах економічної логіки [16, 17]. Для фінансового прогнозування це є критичним,

оскільки модель має не лише давати точний прогноз, а й бути придатною для аналізу ризику, пояснення впливу факторів і прийняття управлінських рішень.

Другою проблемою є нестабільність навчання та чутливість до вибору архітектури, гіперпараметрів, періоду вибірки й способу нормалізації даних [18, 19]. У фінансових часових рядах це посилюється через структурні зміни, зміну режимів і нерівномірність зовнішніх шоків [6, 13]. Тому висока точність deep learning моделей на одному періоді не гарантує їхньої стабільності на іншому, особливо в умовах кризової турбулентності.

Таким чином, глибоке навчання забезпечує потужний інструментарій для прогнозування волатильності завдяки здатності працювати з нелінійними залежностями, довгими часовими послідовностями та різнорідними джерелами даних [16, 17, 19]. RNN, LSTM і GRU дозволяють моделювати часову динаміку, CNN — вилучати локальні ознаки, а attention/Transformer-механізми — інтегрувати довгострокові та факторні залежності [14, 17, 19]. Водночас black-box природа, обчислювальна складність і нестабільність навчання обумовлюють потребу у поєднанні deep learning із економетричними бенчмарками, режимною логікою, пояснюваністю та робастною валідацією [11, 13, 18].

1.6. Спілловери та зв'язаність

У попередніх підрозділах було розглянуто підходи, що моделюють волатильність окремого активу, сектору або ринку. Проте для сучасних фінансових систем така постановка є недостатньою, оскільки ринки функціонують як взаємопов'язана система, де шоки можуть передаватися між активами, секторами, країнами та класами інструментів [7]. Саме тому важливим напрямом досліджень стали спілловери волатильності та зв'язаність (connectedness), які дозволяють оцінити не лише власну динаміку ринку, а й те, як він передає або отримує шоки від інших елементів системи [20].

Одним із найвпливовіших підходів у цьому напрямі є індекс спілловерів Diebold–Yilmaz, що ґрунтується на ідеї вимірювання внеску шоків одного ринку у прогнозу помилку іншого ринку [20]. Такий підхід дозволяє кількісно оцінити загальний рівень зв'язаності системи, а також визначити, які ринки виступають переважно передавачами шоків, а які — їх отримувачами [20]. Для задач прогнозування волатильності це має принципове значення, оскільки джерело ризику може перебувати не в самому секторі, а в іншому ринку або групі активів.

Методологічною основою Diebold–Yilmaz framework є векторна авторегресія (Vector Autoregression, VAR), у межах якої кожна змінна моделюється як функція власних лагових значень і лагових значень інших змінних системи [20]. На основі VAR-моделі виконується декомпозиція дисперсії помилки прогнозу (Forecast Error Variance Decomposition, FEVD), що дозволяє визначити, яка частка прогнозованої невизначеності однієї змінної пояснюється шоками інших змінних [20]. У сучасних реалізаціях часто використовується generalized FEVD, що зменшує залежність результатів від порядку змінних у VAR-системі [21].

У контексті фінансових ринків такий підхід дозволяє будувати кілька типів показників зв'язаності: загальний індекс спілловерів, directional spillovers “from” та “to”, а також net spillovers, які показують чистий внесок ринку як передавача або отримувача шоків [20]. Це дає змогу перейти від простого опису волатильності до аналізу системної структури ризику. Наприклад, якщо певний сектор має високий net spillover “to others”, він може розглядатися як потенційне джерело поширення нестабільності, тоді як сектор із високим net spillover “from others” є більш залежним від зовнішніх збурень [20].

Окреме значення має розрізнення спілловерів дохідностей і спілловерів волатильності. Спілловери дохідностей часто відображають поступові зміни фундаментальних очікувань, тоді як спілловери волатильності можуть мати більш різкий характер, оскільки пов'язані з швидкою передачею інформації та реакцією ринку на шоки [22]. У дослідженні глобальних фондових індексів за 2000–2024 роки показано, що динамічні return spillovers мають відносно плавні

тренди, тоді як volatility spillovers частіше демонструють різкі сплески, особливо в кризові періоди [22]. Це підтверджує необхідність окремого аналізу саме волатильнісної зв'язаності для задач ризикового прогнозування.

Для відображення зміни зв'язаності у часі застосовуються rolling-window та time-varying підходи. Замість оцінювання одного статичного індексу на всій вибірці, модель переоцінюється на ковзних вікнах, що дозволяє відстежувати динаміку спілловів у різні ринкові періоди [22]. Такий підхід є особливо важливим для аналізу структурних зламів, оскільки рівень міжринкової зв'язаності може суттєво змінюватися під час фінансових криз, пандемій, геополітичних шоків або періодів монетарної нестабільності [6, 22].

Для узагальнення основних компонентів connectedness-підходу доцільно подати їх у табл. 1.4.

Таблиця 1.4 — Основні компоненти аналізу спілловів і зв'язаності

Компонент	Зміст	Роль у прогнозуванні волатильності
VAR	Моделює взаємозалежність кількох часових рядів через лаги	Формує базу для оцінювання міжринкових зв'язків [20]
FEVD	Розкладає прогнозу помилку на внески шоків різних змінних	Дозволяє кількісно оцінити передачу шоків [20, 21]
Total spillover index	Вимірює загальний рівень зв'язаності системи	Показує системну інтенсивність ризику [20]
Directional spillovers	Визначають напрями передачі шоків між ринками	Відокремлюють transmitters та receivers [20, 22]
Rolling-window connectedness	Оцінює зміну спілловів у часі	Дозволяє виявляти кризові сплески та структурні злами [22]

Порівняно з одномірними моделями волатильності, *connectedness*-підходи краще узгоджуються із задачами секторного аналізу. Якщо ціль полягає не лише у прогнозуванні волатильності одного активу, а у виявленні того, як різні сектори реагують на зовнішні шоки, то важливо враховувати не тільки власні лаги сектору, а й інформацію про інші частини ринку [7, 20]. У цьому сенсі спілловери формують перехід від локального прогнозування до системного представлення ринкової динаміки.

Водночас класична Diebold–Yilmaz методологія має певні обмеження. По-перше, VAR-моделі потребують стаціонарності та можуть ставати нестабільними за великої кількості змінних [20]. По-друге, FEVD-based *connectedness* добре описує структуру зв'язаності, але сам по собі переважно має пояснювальний, а не прогнозний характер [23]. По-третє, за великої кількості активів або секторів виникає проблема високої розмірності, що вже була характерна для багатовимірних моделей реалізованої волатильності [7].

Саме ці обмеження зумовили перехід до поєднання *connectedness*-аналізу з методами машинного та глибокого навчання. У дослідженні Del Nero та Giudici класичний Diebold–Yilmaz підхід використовується для побудови фактичних *return* і *volatility spillovers* між чотирнадцятьма основними фондовими індексами, після чого рекурентні нейронні мережі застосовуються вже для прогнозування цих спілловерів [23]. Емпірично показано, що GRU демонструє кращу прогнозу якість порівняно з іншими рекурентними архітектурами, що пояснюється її здатністю враховувати складні нелінійні залежності та довготривалі часові зв'язки [23].

Окремим напрямом розвитку є мережеві та графові підходи. Якщо *spillover index* вимірює силу й напрям передачі шоків, то графове представлення дозволяє формалізувати ринок як систему вузлів і ребер, де вузлами можуть бути активи, сектори або країни, а ребрами — кореляції, коваріації, спілловери чи інші форми залежностей [7]. У дослідженнях реалізованих коваріацій підкреслюється, що графова структура містить інформацію про взаємозалежність активів і може покращувати прогнозування *realized covariance matrices* [7]. Для секторної моделі

це означає, що взаємодія між галузями має розглядатися не як побічний ефект, а як окремий інформаційний шар.

Мережеві підходи також природно поєднуються з deep learning архітектурами. У чернетці проєкту вже закладено логіку використання graph-based representation для врахування кореляцій, спільного руху секторів та динаміки міжринкових зв'язків, що узгоджується із сучасним переходом від VAR/FEVD connectedness до LSTM–GNN та dynamic GNN моделей. У такій постановці граф не лише описує зв'язаність після факту, а може використовуватися як структурний вхід у прогнозну модель.

Таким чином, аналіз спілловєрів і зв'язаності є необхідним етапом переходу від індивідуального моделювання волатильності до системного прогнозування фінансових ринків. Diebold–Yilmaz framework на основі VAR і FEVD дозволяє кількісно оцінювати напрями та силу передачі шоків [20, 21], rolling-window підходи відображають зміну зв'язаності в часі [22], а ML/DL та графові моделі розширюють цей аналіз у прогнозному напрямі [7, 23]. Для цієї роботи це створює методологічну основу для врахування секторних взаємозв'язків, поширення зовнішніх шоків і побудови моделі, яка не розглядає ринки як ізольовані часові ряди.

1.7. Графові методи

Подальшим розвитком підходів до аналізу спілловєрів і міжринкової зв'язаності є графове представлення фінансових ринків. Якщо VAR/FEVD-підходи дозволяють кількісно оцінити передачу шоків між ринками [20, 21], то графові методи дають змогу формалізувати саму структуру залежностей між активами, секторами або індексами [7]. У такому представленні фінансові об'єкти розглядаються як вузли графа, а зв'язки між ними — як ребра, що можуть відображати кореляції, коваріації, спілловєри, спільний рух або умовні залежності [7].

Графове представлення є особливо релевантним для задач прогнозування волатильності, оскільки фінансові ринки не функціонують як набір ізольованих часових рядів. Волатильність одного сектору може залежати не лише від його власної історії, а й від стану суміжних секторів, загального ринкового режиму та сили міжсекторних зв'язків [7, 20]. Саме тому у графових моделях прогнозування важливою стає не лише локальна динаміка вузла, а й інформація, що надходить від його сусідів у графі [7].

Одним із базових механізмів у графових підходах є neighborhood aggregation, тобто агрегація інформації від сусідніх вузлів [7]. У задачі прогнозування реалізованих коваріацій та волатильностей такий підхід дозволяє доповнити власні лаги активу інформацією про пов'язані з ним активи. Це є принциповою відмінністю від HAR-RV, де майбутня волатильність цільового активу переважно пояснюється його власними добовими, тижневими та місячними компонентами [8]. Графовий підхід, навпаки, дозволяє включити структурну інформацію про взаємозалежність активів без явного моделювання кожної пари як окремої змінної [7].

У дослідженнях реалізованих коваріацій запропоновано розглядати окремі графи для волатильностей і кореляцій [7]. Зокрема, граф волатильності описує залежності між реалізованими волатильностями активів, тоді як line graph може використовуватися для моделювання залежностей між кореляційними парами, що мають спільний актив [7]. Така структура дозволяє окремо враховувати два різні типи ринкової динаміки: власну мінливість активів і взаємну зміну кореляцій між ними [7].

Побудова графа може здійснюватися різними способами. Найпростішим є повний граф, де кожен актив пов'язаний з усіма іншими, однак такий підхід може призводити до надлишкової кількості зв'язків і погіршення інтерпретованості [7]. Іншим варіантом є секторний граф, наприклад на основі GICS-класифікації, де зв'язки задаються належністю активів до одного сектору [7]. Такий підхід краще відображає економічну структуру ринку, але може ігнорувати важливі міжсекторні залежності. Більш гнучким варіантом є data-driven граф,

побудований за допомогою Graphical LASSO, де ребра визначаються через ненульові елементи матриці точності, тобто через умовні залежності між активами [7].

Для узагальнення основних способів побудови графів у фінансовому прогнозуванні доцільно подати їх у табл. 1.5.

Таблиця 1.5 — Основні способи побудови графів у фінансовому прогнозуванні

Тип графа	Принцип побудови	Перевага	Обмеження
Повний граф	Усі активи пов'язані між собою	Враховує глобальну ринкову інформацію	Надлишкова кількість зв'язків [7]
Секторний граф	Ребра задаються належністю до одного сектору	Має економічну інтерпретацію	Може ігнорувати міжсекторні зв'язки [7]
GLASSO-граф	Ребра визначаються через умовні залежності	Дає розріджену data-driven структуру	Залежить від параметра регуляризації [7]
Динамічний граф	Структура ребер змінюється у часі	Враховує зміну ринкових режимів	Потребує складнішого оцінювання [25]

Емпіричні результати graph-based підходів показують, що включення графової інформації може покращувати прогнозування реалізованих коваріацій порівняно з традиційними HAR-бенчмарками [7, 8]. Зокрема, моделі типу GHAR і GHARQ розширюють HAR-логіку за рахунок графових компонентів, що агрегують інформацію від пов'язаних вузлів [7]. У таких моделях граф не замінює часову структуру, а доповнює її, дозволяючи врахувати як власну історію активу, так і інформацію про його структурне оточення [7].

Особливо важливим є те, що графові методи частково розв'язують проблему високої розмірності, характерну для класичних багатовимірних моделей

волатильності. У VAR, multivariate GARCH або повному pairwise-моделюванні кількість параметрів швидко зростає зі збільшенням кількості активів [7, 20]. Натомість графова агрегація дозволяє зберегти розмірність ознак на контрольованому рівні, оскільки модель використовує структуровану інформацію від сусідів, а не окремий параметр для кожної можливої пари активів [7].

Графові методи також створюють природну основу для застосування графових нейронних мереж (Graph Neural Networks, GNN). Якщо класичні graph-based економетричні моделі використовують граф як додаткове джерело агрегованих ознак [7], то GNN здатні навчатися представлень вузлів з урахуванням топології графа та ознак сусідніх елементів [16, 24]. У фінансовому контексті це означає, що модель може одночасно враховувати часову динаміку окремого сектору та його положення у системі міжсекторних залежностей [24].

Один із релевантних напрямів розвитку — поєднання LSTM і GNN. У такій архітектурі LSTM або інший рекурентний/темпоральний блок відповідає за моделювання часової послідовності, тоді як GNN обробляє просторову або структурну залежність між активами [24]. Це відповідає загальній логіці гібридного прогнозування: часовий компонент моделі виявляє внутрішню динаміку ряду, а графовий компонент враховує взаємодію між фінансовими об'єктами [17, 24]. Для задачі секторної волатильності така комбінація є особливо доцільною, оскільки сектори можуть мати як власні цикли ризику, так і залежності від інших секторів.

Ще одним важливим напрямом є динамічні графові нейронні мережі, у яких структура зв'язків може змінюватися в часі [25]. Це має принципове значення для фінансових ринків, оскільки кореляції та спілловери не є сталими: у кризові періоди зв'язки між активами часто посилюються, а у стабільні періоди можуть слабшати або змінювати напрям [6, 22]. Динамічні GNN дозволяють моделі не фіксувати одну незмінну структуру ринку, а адаптуватися до зміни режимів і структурних зламів [25].

Водночас графові методи мають власні обмеження. По-перше, якість моделі суттєво залежить від способу побудови графа: повний, секторний, кореляційний або GLASSO-граф можуть давати різні результати [7]. По-друге, статичний граф може не відповідати реальній динаміці ринку, якщо структура залежностей змінюється у часі [25]. По-третє, GNN-моделі, як і інші глибокі архітектури, мають проблему інтерпретованості та можуть поводитися нестабільно за зміни вибірки або ринкового режиму [16, 18].

Таким чином, графові методи є логічним продовженням аналізу спілловерів і connectedness, оскільки дозволяють перейти від кількісного вимірювання передачі шоків до структурного моделювання фінансової системи [7, 20]. Graph representation дає змогу описати активи або сектори як вузли, dependency modeling формалізує зв'язки між ними, а GNN-архітектури забезпечують механізм навчання на такій структурі [7, 24]. Для цієї роботи графові методи є важливим методологічним підґрунтям, оскільки вони дозволяють моделювати міжсекторні залежності, враховувати поширення ринкових шоків і перейти від ізольованого прогнозування волатильності до системного представлення фінансового ринку.

1.8. Ризикові метрики та оцінка

Оцінювання моделей прогнозування волатильності не може обмежуватися лише стандартними статистичними метриками точності, оскільки у фінансових задачах важливо не тільки наблизити прогноз до фактичного значення, а й правильно оцінити ризик екстремальних втрат. Для задачі прогнозування секторної волатильності це особливо суттєво, оскільки помилка моделі в період низької мінливості має зовсім інші наслідки, ніж помилка під час кризового режиму або різкого зовнішнього шоку [6, 13].

Базові метрики, такі як MAE та RMSE, залишаються корисними для первинного порівняння моделей, оскільки дозволяють оцінити середній рівень

похибки прогнозу. MAE відображає середнє абсолютне відхилення прогнозованих значень від фактичних, тоді як RMSE сильніше штрафує великі помилки через квадратичну природу функції втрат. Проте для прогнозування волатильності ці метрики є недостатніми, оскільки вони не враховують специфіку латентної природи волатильності та можливу похибку її realized-проксі [11].

Для оцінювання прогнозів волатильності важливе значення має QLIKE loss. На відміну від звичайних квадратичних метрик, QLIKE краще пристосована до ситуацій, коли істинна умовна дисперсія є неспостережуваною, а замість неї використовується недосконалий проху, наприклад realized volatility [11]. Patton показує, що вибір функції втрат може змінювати ranking прогнозних моделей, якщо проху волатильності містить шум, тому robust loss functions є важливими для коректного порівняння моделей [11]. Саме тому QLIKE доцільно використовувати поряд із RMSE та MAE, а не як випадкову “ще одну метрику”, яку додають, щоб таблиця виглядала розумнішою [11].

Окремий блок оцінювання пов’язаний із ризиковими метриками Value-at-Risk (VaR) та Expected Shortfall (ES). VaR визначає максимально очікувану втрату портфеля або активу на заданому рівні довіри протягом певного горизонту, тоді як ES оцінює середню втрату за умови перевищення VaR-порогу [26]. На відміну від VaR, ES краще відображає tail risk, оскільки враховує не тільки факт порушення порогу, а й середню тяжкість екстремальних втрат [26, 27].

У контексті прогнозування волатильності VaR та ES виконують роль практичного містка між статистичним прогнозом і фінансовим рішенням. Якщо модель точно прогнозує середню волатильність, але систематично недооцінює хвостові ризики, вона може бути непридатною для управління портфелем, risk limits або capital allocation [26]. Саме тому сучасні роботи з volatility forecasting дедалі частіше оцінюють не лише точність прогнозу σ або RV, а й якість risk calibration для VaR, ES або CVaR [30].

Основні групи метрик, які доцільно застосовувати для оцінювання моделей прогнозування волатильності, наведено у табл. 1.6.

Таблиця 1.6 — Основні групи метрик оцінювання моделей прогнозування волатильності

Група метрик	Приклади	Основне призначення
Статистична точність	MAE, RMSE	Оцінювання середнього рівня похибки прогнозу
Robust loss для волатильності	QLIKE	Порівняння прогнозів за умов недосконалого проху волатильності [11]
Хвостові ризики	VaR, ES / CVaR	Оцінювання потенційних екстремальних втрат [26, 27]
Бектестинг ризику	Kupiec, Christoffersen, ES backtesting	Перевірка коректності частоти та залежності порушень VaR/ES [27]
Економічна значущість	P&L, drawdown, utility, turnover	Перевірка практичної користі прогнозу для стратегії [13, 30]

Для перевірки якості VaR-прогнозів використовуються процедури backtesting. Їхня логіка полягає у порівнянні прогнозованого ризикового порогу з фактичними втратами та підрахунку кількості порушень. Якщо модель побудована коректно, частота перевищень VaR має відповідати заданому рівню довіри [27]. Тест Kupiec перевіряє unconditional coverage, тобто чи відповідає фактична частота порушень очікуваній, тоді як тест Christoffersen додатково враховує independence of violations, тобто чи не групуються порушення в часі [27].

Для ES backtesting задача складніша, оскільки Expected Shortfall оцінює середню величину втрат за межами VaR-порогу, а не лише кількість порушень. Тому перевірка ES має враховувати не тільки частоту екстремальних подій, а й те, наскільки точно модель описує їхню інтенсивність [26, 27]. Це особливо

важливо для кризових періодів, де модель може формально проходити VaR coverage, але водночас суттєво недооцінювати реальний розмір втрат у хвості розподілу [27].

Основні backtesting-підходи до ризикових метрик узагальнено у табл. 1.7.

Таблиця 1.7 — Backtesting-підходи для ризикових метрик

Підхід	Що перевіряє	Значення для моделі
Kupiec test	Чи відповідає частота VaR-порушень заданому рівню довіри	Перевіряє базову коректність VaR-прогнозу [27]
Christoffersen test	Чи є порушення незалежними в часі	Виявляє кластеризацію помилок ризику [27]
ES backtesting	Чи коректно оцінюється середня втрата за VaR-порогом	Дає оцінку tail-risk calibration [26, 27]
Joint VaR/ES evaluation	Узгодженість VaR та ES як ризикових прогнозів	Важлива для регуляторного та портфельного застосування [30]

Окрім окремих метрик точності та ризику, важливо перевіряти статистичну значущість різниці між моделями. Для цього використовується тест Diebold–Mariano, який дозволяє визначити, чи є різниця у прогнозній якості двох моделей статистично значущою, а не випадковим результатом конкретної вибірки [28]. У задачах прогнозування волатильності DM-тест доцільно застосовувати разом із loss-функціями, придатними для роботи з volatility proxy, зокрема QLIKE [11, 28].

Якщо порівнюється не дві, а багато моделей, доцільним є використання Model Confidence Set (MCS). Цей підхід дозволяє сформувати множину моделей, які статистично не поступаються найкращій за заданою функцією втрат [29]. Для дослідження з великою кількістю альтернатив — наприклад, GARCH, HAR-RV, SVR, Random Forest, XGBoost, LSTM, GRU, Transformer або GNN — MCS є

корисним інструментом, оскільки він не змушує вибирати “переможця” лише за мінімальним RMSE, що, як не дивно, іноді є пасткою, а не наукою [29].

Окремо слід враховувати економічну значущість прогнозів. Модель може мати кращі статистичні метрики, але не давати практичної переваги у реальному застосуванні, якщо її прогнози не покращують управління ризиком, ребалансування портфеля або торговельну стратегію. Наприклад, у deep learning-based trading strategy для ETF прогнозні моделі оцінюються не тільки через accuracy, а й через показники прибутковості, ризику та VaR, тобто через перехід від прогнозу до практичного рішення [13].

У межах цієї роботи економічна значущість має розглядатися як окремий рівень оцінювання, що доповнює статистичну точність. Для секторного прогнозування важливо не лише передбачити рівень волатильності, а й визначити, чи допомагає прогноз краще ранжувати сектори за ризиком, уникати періодів надмірної турбулентності та коректніше оцінювати tail exposure. У цьому контексті доцільними є directional accuracy, rank IC, portfolio turnover, drawdown, hit ratio для ризикових порогів та порівняння risk-adjusted performance [13, 30].

Сучасні гібридні моделі дедалі частіше намагаються поєднати точність прогнозування волатильності з узгодженим калібруванням хвостових ризиків. Зокрема, EGARCH-Informer підхід із consistent risk calibration орієнтований не лише на прогноз σ , а й на оцінювання VaR/CVaR, що дозволяє поєднати deep learning із класичною логікою risk management [30]. Така постановка є близькою до задачі цієї роботи, оскільки кінцевий результат моделі має бути придатним не лише для опису ринку, а й для оцінки ризику в умовах зовнішніх шоків і режимних змін [6, 30].

Таким чином, оцінювання моделей прогнозування волатильності має бути багаторівневим. На першому рівні використовуються MAE, RMSE та QLIKE для перевірки статистичної точності й robust forecast comparison [11]. На другому рівні застосовуються VaR, ES та backtesting-процедури для оцінювання хвостових ризиків і калібрування ризикових прогнозів [26, 27]. На третьому рівні

використовуються DM-тест, MCS та показники економічної значущості, які дозволяють перевірити, чи є перевага моделі статистично й практично важливою [13, 28, 29]. Саме таке поєднання метрик є необхідним для моделі, що прогнозує секторну волатильність в умовах нелінійної ринкової динаміки, зовнішніх шоків і міжсекторної зв'язаності.

1.9. Зовнішні фактори

Попередні підрозділи показують, що волатильність фінансових ринків формується не лише внутрішньою динамікою активів, лагами дохідностей, realized-показниками або міжсекторними зв'язками. Суттєву роль відіграє зовнішнє інформаційне середовище, яке включає макроекономічні умови, монетарну політику, індикатори невизначеності, товарні ринки, валютні курси та соціально-інституційні фактори [15]. Інакше кажучи, ринок не живе у стерильній лабораторній банці, хоча класичні моделі іноді роблять вигляд, що саме так усе й працює.

Макроекономічні фактори відображають загальний стан економіки та формують фундаментальне середовище, у якому функціонують фінансові ринки. До таких змінних належать темпи зростання ВВП, інфляція, процентні ставки, показники монетарної політики, безробіття та інші агреговані індикатори економічної активності [15]. Їхній вплив на волатильність пояснюється тим, що зміни макроекономічних умов змінюють очікування інвесторів щодо майбутніх прибутків компаній, вартості капіталу, ліквідності та ризику [15].

Особливе значення мають процентні ставки та показники монетарної політики. Зміна ставок впливає на дисконтовану вартість майбутніх грошових потоків, переоцінку ризикових активів і поведінку інвесторів щодо перерозподілу капіталу між акціями, облігаціями, валютами та товарними активами [15]. У сучасних дослідженнях для опису монетарного середовища також використовуються shadow short rates, які дозволяють враховувати стан

політики центрального банку навіть у періоди, коли номінальні ставки перебувають поблизу нульової межі [15, 31].

Окрему групу зовнішніх чинників становлять індикатори невизначеності. Economic Policy Uncertainty (EPU) відображає рівень невизначеності, пов'язаної з економічною політикою, регулюванням, бюджетними рішеннями та загальною непередбачуваністю економічного середовища [32]. Зростання EPU може посилювати волатильність, оскільки інвестори переглядають очікування щодо майбутніх доходів, ризикових премій та ймовірності негативних сценаріїв [32].

Geopolitical Risk (GPR) відображає ризики, пов'язані з міжнародними конфліктами, військовими загрозами, терористичними подіями та політичною нестабільністю [33]. На відміну від звичайних макроекономічних змінних, GPR часто має шоківий характер: його вплив може проявлятися різко, нерівномірно та по-різному для окремих секторів [33]. Наприклад, енергетичний сектор може сильніше реагувати на геополітичні загрози, пов'язані з поставками нафти й газу, тоді як технологічний сектор може бути більш чутливим до санкцій, торговельних обмежень або змін у глобальних ланцюгах постачання [15, 33].

Financial Stress Index (FSI) використовується для оцінки напруженості фінансової системи та може включати показники кредитних спредів, ліквідності, волатильності, ринкової турбулентності й системного ризику [15, 34]. У дослідженні Latif та ін. показано, що серед зовнішніх предикторів для S&P 500 важливими факторами є VIX, FSI та EPU, що підтверджує значущість індикаторів невизначеності та фінансового стресу для прогнозування ринкової динаміки [15]. Це особливо важливо для задачі прогнозування волатильності, оскільки фінансовий стрес не лише супроводжує кризові періоди, а й може виступати раннім сигналом майбутнього зростання ризику [34].

Товарні ринки також є важливим джерелом зовнішньої інформації. Ціни на нафту впливають на виробничі витрати, інфляційні очікування, прибутковість енергетичних компаній та загальну оцінку макроекономічних ризиків [15]. Золото, навпаки, часто розглядається як захисний актив, реакція якого може відображати зростання невизначеності або перехід інвесторів до менш

ризикових інструментів [15, 35]. Тому одночасне врахування нафти й золота дозволяє моделі захоплювати різні канали зовнішнього впливу: виробничо-інфляційний та захисно-ризиковий [15, 35].

Валютні курси є ще одним важливим зовнішнім фактором, оскільки вони відображають відносну вартість національних валют, міжнародну конкурентоспроможність, очікування щодо монетарної політики та глобальні потоки капіталу [36]. Для компаній, залежних від експорту, імпорту або міжнародного фінансування, зміна валютного курсу може безпосередньо впливати на прибутковість і ризик [36]. На секторному рівні це означає, що FX-фактори можуть мати неоднорідний вплив: експортоорієнтовані, енергетичні, технологічні та споживчі сектори можуть реагувати на валютні шоки по-різному [15, 36].

Окрему роль у цій роботі відіграють соціальні та інституційні фактори. На відміну від високочастотних фінансових даних, такі показники мають нижчу частоту оновлення, але можуть відображати глибинні характеристики економічного й суспільного середовища. До них належать індикатори якості державного управління, політичної стабільності, довіри, соціальних цінностей, ставлення до ризику, інституційної надійності та культурних установок [37, 38]. Їхнє використання особливо релевантне для довгострокового аналізу, де важливо врахувати не лише миттєві ринкові сигнали, а й стабільні характеристики середовища, у якому формується поведінка інвесторів.

У межах цієї роботи соціально-інституційний блок узгоджується з логікою використання Worldwide Governance Indicators (WGI) та World Values Survey (WVS). WGI дає змогу описати інституційний контекст через показники якості управління, політичної стабільності, ефективності уряду, верховенства права та контролю корупції [37]. WVS, своєю чергою, дозволяє включити соціально-культурні характеристики, пов'язані з довірою, ціннісними орієнтаціями, ставленням до інституцій та соціальною поведінкою [38]. Для фінансового прогнозування такі фактори не замінюють ринкові дані, але доповнюють їх

контекстом, який може пояснювати різну чутливість країн, секторів або інвесторських груп до однакових економічних шоків [37, 38].

Основні групи зовнішніх факторів, релевантних для прогнозування волатильності, узагальнено у табл. 1.8.

Таблиця 1.8 — Основні групи зовнішніх факторів у прогнозуванні волатильності

Група факторів	Приклади змінних	Роль у моделі
Макроекономічні фактори	GDP, інфляція, ставки, shadow short rate	Відображають загальний стан економіки та монетарного середовища [15, 31]
Індикатори невизначеності	EPU, GPR, FSI, VIX	Фіксують політичну, геополітичну та фінансову напруженість [15, 32–34]
Товарні ринки	Oil, gold	Відображають інфляційні, енергетичні та safe-haven канали [15, 35]
Валютні фактори	FX rates, currency volatility	Передають зовнішньоторговельні та монетарні шоки [36]
Соціально-інституційні фактори	WGI, WVS	Описують інституційне середовище, довіру та соціальні цінності [37, 38]

Методологічно інтеграція зовнішніх факторів у модель прогнозування потребує вирішення кількох проблем. По-перше, ці фактори мають різну частоту оновлення: фінансові змінні можуть бути щоденними, макроекономічні — місячними або кварталними, а соціально-інституційні — річними або хвильовими [15, 37, 38]. По-друге, частина показників публікується із затримкою, тому під час формування датасету необхідно враховувати лаги публікації, щоб уникнути витоку інформації [15]. По-третє, зовнішні фактори

можуть мати різну силу впливу залежно від сектору, ринкового режиму та поточного рівня фінансового стресу [6, 15].

Саме тому просте механічне додавання макроекономічних або соціальних змінних до фінансового датасету не є достатнім. Для коректної інтеграції необхідні нормалізація, узгодження часових шкал, побудова лагових ознак, контроль data leakage та відбір релевантних факторів [15]. У сучасних deep learning підходах цю задачу можна розв'язувати через механізми уваги або cross-attention, які дозволяють моделі адаптивно визначати, які саме зовнішні фактори є важливими для конкретного сектору й моменту часу [19].

Для задачі цієї роботи така логіка є принципово важливою. Оскільки прогнозування виконується на секторному рівні, один і той самий зовнішній фактор може мати різний ефект для різних секторів. Наприклад, зростання цін на нафту може бути позитивним сигналом для енергетичного сектору, але негативним для секторів із високою залежністю від транспортних або виробничих витрат [15]. Аналогічно, зростання GPR або FSI може загалом посилювати ринкову волатильність, але конкретна реакція секторів залежатиме від їхньої експозиції до відповідного типу ризику [33, 34].

Зовнішні фактори також пов'язані з режимною логікою, розглянутою у підрозділі 1.3. У періоди стабільного зростання макроекономічні та соціальні сигнали можуть мати помірний вплив, тоді як у кризові періоди індикатори невизначеності, фінансового стресу та геополітичного ризику можуть ставати домінантними предикторами волатильності [6, 15, 33]. Це означає, що модель має враховувати не тільки самі зовнішні фактори, а й контекст, у якому вони діють.

Таким чином, зовнішні фактори є необхідним компонентом сучасної моделі прогнозування волатильності. Макроекономічні показники відображають фундаментальний стан економіки, EPU, GPR і FSI фіксують канали невизначеності та фінансового стресу, commodities і FX передають глобальні цінові та валютні шоки, а WGI/WVS дозволяють врахувати інституційний і соціально-культурний контекст [15, 31–38]. Для цієї роботи інтеграція таких

факторів створює основу для переходу від суто ринкового прогнозування до моделі, яка враховує ширше зовнішнє середовище, неоднорідну секторну чутливість і зміну впливу факторів у різних ринкових режимах.

Висновки до розділу 1

У першому розділі було розглянуто основні теоретичні та методологічні підходи до прогнозування волатильності фондових ринків. Аналіз показав, що класичні економетричні моделі, зокрема ARCH, GARCH та їх асиметричні розширення, створюють базову основу для формалізації умовної гетероскедастичності, кластеризації волатильності та реакції ринку на інформаційні шоки. Водночас ці підходи мають обмеження, пов'язані з припущенням відносної стабільності параметрів, слабкою адаптацією до структурних зламів і недостатнім урахуванням складних міждринкових залежностей.

Розгляд реалізованої волатильності та еталонних моделей показав, що RV, HAR-RV і Realized GARCH є важливими інструментами сучасного прогнозування, оскільки дозволяють точніше описувати фактичну мінливість ринку та враховувати ефекти довгої пам'яті. При цьому realized-підходи також не усувають усіх проблем моделювання, оскільки залишають відкритими питання мікроструктурного шуму, якості volatility proxy, вибору функцій втрат і врахування взаємозалежностей між активами та секторами.

Окрему увагу було приділено режимним моделям і структурним зламам. Було встановлено, що Markov switching та НММ-підходи дозволяють описувати зміну ринкових станів, зокрема перехід між фазами стабільності, спаду та кризової турбулентності. Це є важливим для прогнозування волатильності, оскільки поведінка фінансових рядів суттєво змінюється залежно від поточного режиму ринку. Разом з тим режимні моделі потребують коректного вибору

кількості станів і можуть бути нестабільними за зміни вибірки або зовнішнього середовища.

Аналіз класичних методів машинного навчання показав, що регресійні моделі, SVR, Random Forest і XGBoost можуть ефективно працювати з нелінійними залежностями та різнорідними ознаками. Їхня перевага полягає у гнучкості та можливості використання ширшого набору предикторів порівняно з класичними економетричними моделями. Проте ці методи переважно розглядають дані як табличну матрицю ознак, тому часова структура фінансових рядів у них не моделюється безпосередньо, а має бути попередньо закодована через лаги, ковзні статистики або інші інженерні ознаки.

Було встановлено, що глибоке навчання розширює можливості прогнозування волатильності завдяки здатності моделювати складні нелінійні залежності та часові послідовності. RNN, LSTM і GRU дозволяють працювати з послідовною природою фінансових даних, CNN можуть використовуватися для вилучення локальних патернів, а attention-механізми та Transformer-архітектури забезпечують більш гнучке врахування довгострокових і факторних залежностей. Водночас deep learning моделі мають суттєві обмеження, зокрема black-box природу, чутливість до гіперпараметрів, ризик перенавчання та нестабільність у періоди структурних змін.

Розгляд спілловів та зв'язаності показав, що сучасні фінансові ринки не можуть бути адекватно описані як сукупність ізольованих часових рядів. Diebold–Yilmaz framework, VAR, FEVD та пов'язані з ними connectedness-підходи дозволяють оцінювати напрями й силу передачі шоків між ринками або секторами. Це є особливо важливим для задачі секторного прогнозування волатильності, оскільки джерело ризику може перебувати не в самому секторі, а в іншому елементі фінансової системи.

Графові методи було визначено як логічне продовження аналізу міжринкової зв'язаності. Представлення фінансового ринку у вигляді графа дозволяє описувати активи або сектори як вузли, а залежності між ними — як ребра, що відображають кореляції, коваріації, спілловери або умовні зв'язки.

Такий підхід створює методологічне підґрунтя для використання графових нейронних мереж, які можуть одночасно враховувати власну часову динаміку секторів і структурну інформацію про їхнє положення у фінансовій системі.

Оцінювання моделей прогнозування волатильності має бути багаторівневим. Стандартні метрики точності, такі як MAE та RMSE, є корисними для базового порівняння, однак недостатні для повноцінної оцінки фінансового ризику. Тому доцільним є використання QLIKE для робастного порівняння прогнозів волатильності, а також VaR, Expected Shortfall і backtesting-процедур для оцінювання хвостових ризиків. Додатково важливо перевіряти статистичну та економічну значущість прогнозів, оскільки модель має бути не лише точнішою формально, а й корисною для практичного управління ризиком.

Також було встановлено, що зовнішні фактори є необхідним компонентом сучасних моделей прогнозування волатильності. Макроекономічні показники, процентні ставки, індикатори невизначеності, фінансового стресу, геополітичного ризику, товарні ринки, валютні курси, а також соціально-інституційні змінні дозволяють розширити модель за межі суто ринкової динаміки. Водночас їх інтеграція потребує узгодження частот, нормалізації, побудови лагових ознак і контролю витоку інформації.

Отже, проведений аналіз показав, що для задачі прогнозування волатильності фондових ринків на основі макроекономічних показників та зовнішніх шоків факторів доцільно використовувати багатокomпонентний підхід. Такий підхід має поєднувати класичні економетричні бенчмарки, realized volatility, режимну логіку, методи машинного та глибокого навчання, графове представлення міжсекторних залежностей, зовнішні фактори та багаторівневу систему оцінювання ризику. Саме ці висновки формують методологічну основу для побудови архітектури моделі, що розглядається у другому розділі роботи.

РОЗДІЛ 2. РОЗРОБКА ТА РЕАЛІЗАЦІЯ МОДЕЛІ ПРОГНОЗУВАННЯ

2.1. Загальна архітектура системи

2.1.1. Концептуальна схема моделі

Концептуальна схема запропонованої моделі базується на багаторівневому підході до прогнозування фінансових часових рядів, де основною одиницею аналізу виступають секторні портфелі ринку. У якості базового представлення використовується набір із 49 індустрій, сформованих відповідно до методології Fama–French, що дозволяє відобразити агреговану поведінку ринку на галузевому рівні [39] [рис. 2.1].

Ключовою ідеєю моделі є інтеграція декількох джерел даних різної природи, що включають як внутрішньоринкові фінансові сигнали, так і зовнішні фактори. До внутрішніх даних належать часові ряди дохідностей секторів, які відображають динаміку ринку. Зовнішні фактори представлені макроекономічними, політичними та соціально-культурними індикаторами, що формують додатковий контекст для моделювання ринкової поведінки [15, 31–38]. Такий підхід дозволяє враховувати не лише ендегенну структуру ринку, але й екзогенні впливи, що можуть визначати зміни у волатильності та доходностях [15, 19].

Модель орієнтована на ймовірнісне прогнозування, що реалізується через оцінювання квантильних характеристик розподілу майбутніх значень. Замість точкового прогнозу формується набір квантилів, зокрема q_{10} , q_{50} , q_{90} , що дозволяє оцінити невизначеність та ризики, пов'язані з прогнозованими значеннями [19, 40]. Такий підхід є більш інформативним у задачах фінансового аналізу, оскільки забезпечує можливість подальшого використання результатів для оцінювання ризикових метрик, таких як Value-at-Risk та Expected Shortfall [26, 27, 30].




Рисунок 2.1 - Структура системи реалізації

Загальна логіка функціонування системи реалізується у вигляді послідовного багатокрокового пайплайну обробки даних. На першому етапі здійснюється завантаження та попередня обробка даних (Data), що включає нормалізацію, синхронізацію частот та формування єдиного представлення. Така підготовка є необхідною для інтеграції фінансових часових рядів із зовнішніми макроекономічними, інституційними та соціальними факторами, які мають різну періодичність і структуру [15, 37–39].

Далі виконується побудова структурних залежностей між секторами ринку (Graph discovery), де визначаються взаємозв'язки типу lead-lag та формується графова структура ринку. Використання графового представлення дозволяє описати фінансовий ринок як систему взаємопов'язаних секторів, у якій зв'язки можуть відображати кореляції, коваріації, спілловери або інші форми залежностей між ринковими об'єктами [7, 20, 24, 25]. Наступним етапом є аналіз зовнішніх факторів (Factor discovery), у межах якого оцінюється вплив макроекономічних та соціальних змінних на поведінку секторів [15, 31–38].

Отримані на попередніх етапах артефакти використовуються у фінальній моделі прогнозування (Forecast model), яка поєднує графові, часові та екзогенні компоненти в єдиній нейромережевій архітектурі. Така логіка узгоджується із сучасними підходами, де графові моделі застосовуються для врахування структурних залежностей між фінансовими об'єктами, а deep learning та Transformer-based архітектури — для моделювання складної часової динаміки та роботи з екзогенними змінними [16, 17, 19, 24, 25]. Завершальним етапом є інференс (Inference), під час якого модель генерує прогнози для нових даних та забезпечує можливість їх подальшого аналізу та інтерпретації.

Загалом, запропонована концептуальна схема відображає перехід від класичних однофакторних моделей до комплексних мультиджерельних систем, що поєднують структурний аналіз ринку, зовнішні впливи та сучасні методи машинного навчання, забезпечуючи більш точне та інформативне прогнозування фінансових показників [7, 15–17, 19, 24, 25] [рис. 2.2].




Рисунок 2.2 - Концептуальна схема моделі

2.1.2. Повна архітектурна схема моделі

Повна архітектурна схема моделі відображає інтегровану неймережеву систему прогнозування, яка поєднує просторові, часові та екзогенні залежності в єдиній обчислювальній структурі. Архітектура розроблена з урахуванням необхідності моделювання складних взаємозв'язків між секторами фінансового ринку, а також впливу зовнішніх факторів різної природи на динаміку доходностей [7, 15, 19, 24, 25].

Вхідними даними для моделі є тензор секторних ознак, сформований на основі часових рядів доходностей 49 індустрій, а також відповідні матриці графових зв'язків та набір зовнішніх факторів [39]. Додатково використовується інформація про ринкові режими, що дозволяє адаптувати поведінку моделі до різних фаз ринку [6, 12, 13].

Першим ключовим компонентом архітектури є модуль Dual Graph Encoder, який відповідає за обробку структурних залежностей між секторами. Даний модуль використовує дві паралельні гілки: динамічну, що враховує часову змінність зв'язків, та статичну, що відображає стабільні довгострокові залежності. У результаті формується узагальнене векторне представлення секторів, яке інкапсулює інформацію про міжсекторні взаємодії [7, 24, 25].

Отримані просторові представлення передаються до блоку Temporal Transformer, який моделює часову динаміку фінансових рядів. Використання механізму самоуваги дозволяє ефективно враховувати довгострокові залежності у часових вікнах та виділяти найбільш значущі періоди для прогнозування [17, 19].

Інтеграція зовнішніх факторів здійснюється за допомогою механізму Cross-Attention, де секторні часові ознаки виступають у ролі запитів, а зовнішні змінні — ключів та значень. Такий підхід забезпечує адаптивне врахування екзогенних сигналів у кожен момент часу, зберігаючи часову узгодженість даних [15, 19].

Для врахування неоднорідності ринкової поведінки використовується блок Regime embeddings, який формує векторні представлення режимів ринку на основі характеристик волатильності. Ці представлення інтегруються у модель та впливають на подальші обчислення, дозволяючи враховувати зміну ринкових умов [6, 12, 13].

Наступним компонентом є Mixture of Experts, що реалізує адаптивний механізм вибору спеціалізованих підмоделей. Кожен експерт відповідає за певний тип ринкової поведінки, тоді як керуюча мережа (gating network) визначає ваги їхнього внеску залежно від поточного стану системи. Це дозволяє підвищити гнучкість моделі та її здатність до узагальнення [41].

Фінальним етапом є Quantile Output Layer, яка формує ймовірнісний прогноз у вигляді набору квантилів. Замість одного значення модель генерує інтервал прогнозу, що включає нижню, медіанну та верхню оцінки, забезпечуючи можливість аналізу невизначеності та ризиків прогнозу [19, 40].

Таким чином, повна архітектурна схема моделі представляє собою багатокомпонентну систему, що поєднує графові нейронні мережі, трансформери, механізми уваги та ансамблеві підходи. Це дозволяє ефективно моделювати складну природу фінансових ринків та забезпечувати високоякісне ймовірнісне прогнозування [7, 17, 19, 24, 25, 40, 41] [рис. 2.3].




Рисунок 2.3 - Повна архітектурна схема моделі

2.1.3. Формалізація задачі

У межах даної роботи розглядається задача прогнозування прибутковостей секторів фондового ринку з використанням багатовимірних часових рядів та екзогенних факторів. Основною метою є побудова моделі, здатної здійснювати прогноз на один часовий крок вперед для кожного сектору з урахуванням як внутрішньоринкових, так і зовнішніх впливів [15, 17, 19, 39].

Нехай S — кількість секторів, у даному випадку $S = 49$, а F — кількість ознак, що характеризують кожен сектор у момент часу t . Тоді вхідні дані моделі можуть бути представлені у вигляді матриці:

$$X_t \in \mathbb{R}^{S \times F},$$

де кожен рядок відповідає окремому сектору, а кожен стовпчик — певній характеристиці, зокрема дохідності, технічним індикаторам або похідним ознакам, сформованим у процесі попередньої обробки даних [15, 39].

Задача моделі полягає у прогнозуванні майбутніх значень доходностей секторів на наступний момент часу $t + 1$. На відміну від класичних підходів, що

формують точковий прогноз, у даній роботі використовується ймовірнісний підхід, який передбачає оцінювання квантильних характеристик розподілу прогнозованих значень [19, 40]. Таким чином, вихід моделі визначається як:

$$\hat{Y}_{t+1} = \{q_{10}, q_{50}, q_{90}\},$$

де q_{10} , q_{50} , q_{90} відповідають 10-му, 50-му (медіанному) та 90-му квантилям розподілу прогнозованої доходності для кожного сектору [40].

У загальному випадку вихід моделі має тензорну структуру та охоплює всі сектори одночасно, що дозволяє розглядати задачу як багатовимірне прогнозування (multi-output forecasting). Формально це означає, що для кожного моменту часу модель генерує прогноз для всіх S секторів:

$$\hat{Y}_{t+1} \in \mathbb{R}^{S \times Q},$$

де $Q = 3$ — кількість оцінюваних квантилів.

Таким чином, задача формулюється як задача ймовірнісного прогнозування багатовимірного часового ряду, в якій необхідно оцінити умовний розподіл майбутніх значень доходностей секторів за наявними історичними даними та екзогенними факторами [17, 19, 40]. Така постановка дозволяє не лише отримати очікувані значення, але й оцінити рівень невизначеності прогнозу, що є критично важливим у фінансових застосуваннях, зокрема при оцінюванні ризиків та прийнятті інвестиційних рішень [26, 27, 30, 40].

2.2. Архітектура моделі

2.2.1. Графова модель ринку (Round 1)

Перший етап побудови моделі присвячений виявленню структурних залежностей між секторами фінансового ринку та формуванню графового представлення цих взаємозв'язків. Даний етап реалізується у вигляді окремого аналітичного блоку (Round 1), який не передбачає навчання фінальної прогнозної

моделі, а спрямований на побудову інформативних артефактів, що використовуються на наступних стадіях [7, 24, 25].

Основою для побудови графової моделі є аналіз залежностей типу lead-lag між часовими рядами секторних доходностей. Такий підхід дозволяє визначити, чи зміни в одному секторі передують змінам в іншому, що є важливим для розуміння механізмів поширення інформації та ризиків на ринку [20, 42]. Формально це реалізується шляхом оцінювання регресійних моделей, у яких поточне значення доходності цільового сектору залежить від лагованих значень як власних показників, так і показників інших секторів [21, 42].

На основі отриманих оцінок формується матриця впливів (influence matrix), яка відображає силу та напрямок взаємодії між секторами. Додатково розраховуються допоміжні характеристики, такі як стабільність знаку впливу, частота відбору зв'язку у різних підвибірках та частковий коефіцієнт детермінації. Це дозволяє відфільтрувати випадкові або нестійкі залежності та виділити лише статистично значущі взаємозв'язки [7, 20, 21].

Подальшим кроком є групування секторів на основі виявлених залежностей. Сектори, що мають подібні патерни впливу або взаємодіють між собою більш інтенсивно, об'єднуються у групи. Це дозволяє перейти від аналізу окремих зв'язків до більш узагальненої структури ринку, де розглядаються взаємодії між групами секторів [7, 39].

Результатом даного етапу є побудова двох типів графів. Перший — статичний граф (static graph), який відображає усереднену структуру зв'язків між секторами за весь період спостереження або за його значну частину. Другий — динамічний граф (dynamic graph), що враховує зміну взаємозв'язків у часі та дозволяє адаптувати модель до еволюції ринкової структури [25]. Динамічні графи формуються для окремих часових інтервалів, наприклад за роками, та відображають актуальні на той момент залежності [25].

Отримані графові структури використовуються як вхідні дані для нейромережевої моделі на наступних етапах, зокрема у модулі Dual Graph

Encoder, де вони визначають спосіб агрегування інформації між секторами [24, 25].

Таким чином, графова модель ринку дозволяє перейти від незалежного розгляду секторів до урахування їхньої взаємопов'язаності, що є критично важливим для підвищення якості прогнозування в умовах складної та взаємозалежної фінансової системи [7, 20, 24, 25] [рис. 2.4].




Рисунок 2.4 - Графова модель ринку

2.2.2. Аналіз зовнішніх факторів (Round 2)

Другий етап побудови моделі присвячений аналізу впливу зовнішніх факторів на поведінку секторів фінансового ринку. На відміну від першого етапу, який фокусується на внутрішньоринкових залежностях, даний блок спрямований на виявлення екзогенних впливів, що формуються поза межами ринку, але суттєво впливають на його динаміку [15, 31–38].

У якості джерел зовнішніх даних використовуються два основних набори показників. Першим є Worldwide Governance Indicators (WGI), який містить інституційні характеристики країн, зокрема показники ефективності уряду, політичної стабільності, контролю корупції та якості регуляторного середовища [37]. Другим джерелом є World Values Survey (WVS), що відображає соціально-культурні аспекти, включаючи рівень довіри, цінності суспільства та інші поведінкові фактори [38]. Поєднання цих джерел дозволяє сформувати комплексне уявлення про зовнішній контекст функціонування ринку [37, 38].

Методологічно аналіз зовнішніх факторів реалізується з використанням регуляризованих лінійних моделей, зокрема ridge regression. Такий підхід дозволяє оцінити вплив великої кількості потенційно корельованих факторів, зменшуючи ризик перенавчання та забезпечуючи стабільність оцінок [43]. Для кожного фактору визначається його внесок у пояснення варіації цільових змінних, що вимірюється за допомогою інкрементального коефіцієнта детермінації R^2 .

Важливою складовою аналізу є оцінювання стабільності отриманих залежностей. Для цього використовується підхід, що включає перевірку знаку коефіцієнтів у різних підвибірках, аналіз чутливості моделей до виключення окремих факторів, а також статистичну значущість отриманих результатів. Це дозволяє відокремити стійкі залежності від випадкових кореляцій та підвищити надійність побудованих висновків [43].

Аналіз зовнішніх факторів проводиться на двох рівнях. Перший рівень передбачає дослідження впливу окремих факторів безпосередньо на секторні доходності (factor $\rightarrow$ sector). Це дозволяє виявити, які саме зовнішні змінні є найбільш релевантними для кожного сектору. Другий рівень полягає у дослідженні впливу факторів на агреговані групи секторів (factor $\rightarrow$ group), сформовані на попередньому етапі. Такий підхід дозволяє виявити узагальнені закономірності та зменшити рівень шуму у даних за рахунок агрегування [15, 37, 38].

Додатково аналіз реалізується у декілька етапів, що включають як однофакторні, так і багатофакторні моделі. Це дозволяє оцінити як індивідуальний внесок кожного фактору, так і їхню спільну дію. У результаті формується набір артефактів, що містить інформацію про значущі фактори, їхню силу впливу та стабільність, які надалі використовуються у фінальній моделі прогнозування [15, 43].

Таким чином, другий етап забезпечує інтеграцію зовнішнього інформаційного середовища у процес моделювання, що дозволяє підвищити

точність прогнозів за рахунок врахування макроекономічних, інституційних та соціальних чинників [15, 37, 38] [рис. 2.5].




Рисунок 2.5 - Аналіз зовнішніх факторів

2.2.3. Dual Graph Encoder

Одним із ключових компонентів запропонованої моделі є модуль Dual Graph Encoder, який забезпечує обробку структурних залежностей між секторами фінансового ринку. Його основною задачею є трансформація вхідних секторних ознак з урахуванням топології графа взаємозв'язків, сформованого на попередньому етапі аналізу [7, 24, 25].

Вхідними даними для даного модуля є тензор секторних ознак, що містить часові ряди характеристик кожного сектору, а також матриці суміжності (adjacency matrices), які описують зв'язки між секторами [7]. Ці матриці можуть бути як статичними, так і динамічними, що дозволяє враховувати як стабільні, так і змінні у часі залежності [25].

Архітектурно модуль складається з двох паралельних гілок обробки. Перша гілка відповідає за роботу з динамічним графом (dynamic graph), який відображає зміну взаємозв'язків між секторами у часі. Для кожного часового інтервалу використовується відповідна матриця суміжності, що дозволяє моделі адаптуватися до еволюції ринкової структури [25].

Друга гілка працює зі статичним графом (static graph), який відображає усереднену або довгострокову структуру взаємодій між секторами. Такий граф дозволяє зберігати інформацію про стійкі залежності, що не змінюються швидко у часі [7, 24].

У кожній із гілок застосовуються графові нейронні мережі, зокрема GCN або GAT, які здійснюють агрегацію інформації від сусідніх вузлів відповідно до структури графа [44, 45]. Це дозволяє кожному сектору отримувати контекстну інформацію від інших секторів, з якими він пов'язаний, що підвищує інформативність його представлення [7, 24].

Після незалежної обробки у двох гілках результати об'єднуються та проєктуються у спільний простір ознак. Таким чином формується узагальнене векторне представлення (embeddings) кожного сектору, яке інкапсулює як короткострокові, так і довгострокові структурні залежності [24, 25].

Отримані embeddings секторів передаються до наступних компонентів моделі, зокрема до блоку часової обробки, де вони використовуються для моделювання динаміки у часі. Таким чином, Dual Graph Encoder забезпечує інтеграцію графової структури ринку у загальний процес прогнозування, що є критично важливим для врахування взаємозалежності секторів у фінансовій системі [7, 24, 25].

2.2.4. Temporal Transformer

Після врахування структурних залежностей між секторами наступним етапом є моделювання часової динаміки фінансових рядів. Для цього у запропонованій архітектурі використовується модуль Temporal Transformer, який дозволяє ефективно обробляти послідовності даних та враховувати як короткострокові, так і довгострокові часові залежності [17, 19, 46].

Вхідними даними для даного модуля є векторні представлення секторів, отримані після обробки у графовому енкодері. Ці представлення організовані у

вигляді часових вікон (sliding windows), що формуються на основі послідовних спостережень за фіксовану кількість попередніх днів. Такий підхід дозволяє моделі аналізувати локальні часові контексти та використовувати історичну інформацію для прогнозування майбутніх значень [17, 19].

Оснoву модуля становить механізм самоуваги (self-attention), який застосовується по часовій осі. На відміну від традиційних рекурентних підходів, де інформація передається послідовно, self-attention дозволяє кожному часовому кроку безпосередньо взаємодіяти з усіма іншими кроками у межах вікна [46]. Це забезпечує більш гнучке та ефективне виявлення залежностей, зокрема тих, що розташовані на значній часовій відстані [17, 19, 46].

Перед застосуванням механізму уваги вхідні дані проєктуються у простір фіксованої розмірності та доповнюються позиційними кодуваннями, які зберігають інформацію про порядок елементів у часовій послідовності [46]. Далі послідовність обробляється за допомогою декількох шарів трансформера, кожен з яких включає багатоголову самоувагу, нормалізацію та повнозв'язні перетворення [46].

У результаті формується узагальнене часове представлення секторів, яке відображає як локальні, так і глобальні закономірності у динаміці ринку. Це представлення використовується на наступних етапах моделі, зокрема для інтеграції із зовнішніми факторами та формування фінального прогнозу [17, 19].

Таким чином, Temporal Transformer забезпечує ефективне моделювання часової структури даних, дозволяючи враховувати складні та нелінійні залежності у фінансових часових рядах, що є критично важливим для підвищення точності прогнозування [17, 19, 46].

2.2.5. Cross-Attention (інтеграція зовнішніх факторів)

Інтеграція зовнішніх факторів у модель прогнозування здійснюється за допомогою механізму міжмодальної уваги (Cross-Attention), який дозволяє

поєднати внутрішньоринкові часові представлення секторів із екзогенними змінними. Даний підхід забезпечує адаптивне врахування впливу макроекономічних, інституційних та соціально-культурних факторів на динаміку фінансових показників [15, 19, 46].

У якості джерел зовнішніх факторів використовуються показники з наборів Worldwide Governance Indicators (WGI) та World Values Survey (WVS), які попередньо проходять обробку, нормалізацію та узгодження з часовою шкалою фінансових даних [37, 38]. Оскільки ці фактори мають нижчу частоту, зокрема річну або хвильову, вони трансформуються у щоденний формат шляхом вирівнювання за календарем торговельних днів та врахування лагів публікації, що дозволяє уникнути витоку інформації (data leakage) [15, 37, 38].

Механізм Cross-Attention реалізується таким чином, що векторні представлення секторів, отримані після обробки часовим трансформером, виступають у ролі запитів (query). Зовнішні фактори, представлені у вигляді відповідних векторів ознак, використовуються як ключі (key) та значення (value). Це означає, що для кожного сектору і кожного моменту часу модель визначає, які саме зовнішні фактори є найбільш релевантними, та з якою інтенсивністю вони повинні впливати на прогноз [19, 46].

Завдяки цьому механізму кожен сектор отримує зважену комбінацію зовнішніх сигналів, яка залежить від його поточного стану та історичної динаміки. Такий підхід дозволяє враховувати різну чутливість секторів до зовнішніх впливів, що є важливим для фінансових ринків, де окремі галузі можуть по-різному реагувати на одні й ті самі макроекономічні або соціальні зміни [15, 31–38].

Отриманий результат інтеграції додається до внутрішніх представлень секторів та передається до наступних компонентів моделі. Додатково застосовуються механізми нормалізації та масштабування, які забезпечують стабільність навчання та узгодженість різномірних джерел даних [17, 19].

Таким чином, використання Cross-Attention дозволяє ефективно поєднати внутрішню структуру ринку із зовнішнім інформаційним середовищем,

забезпечуючи більш гнучке та інформативне представлення даних для подальшого прогнозування [15, 19, 37, 38, 46].

2.2.6. Regime Detection

Важливим компонентом запропонованої моделі є врахування різних станів фінансового ринку, що реалізується через механізм визначення режимів (Regime Detection). Фінансові часові ряди характеризуються наявністю періодів із різною волатильністю та поведінковими характеристиками, що потребує адаптивного підходу до моделювання [6, 12, 13].

Основою для визначення режимів є аналіз волатильності секторних доходностей. На базі ковзного вікна розраховуються статистичні характеристики, які дозволяють класифікувати кожен момент часу за рівнем ринкової активності. Зокрема, використовуються розподільчі підходи, при яких межі режимів визначаються за відповідними перцентилями значень волатильності. Як правило, виділяються декілька основних режимів, наприклад, періоди низької, середньої та високої волатильності, що відповідають різним фазам ринку, таким як стабільність або турбулентність [6, 13].

Для подальшого використання у моделі кожному режиму відповідає векторне представлення (embedding), яке формується у вигляді компактного числового опису відповідного стану ринку. Ці embeddings мають фіксовану розмірність та генеруються для кожного моменту часу, що дозволяє інтегрувати інформацію про режим безпосередньо у процес обробки часових даних [12, 13].

Інтеграція режимних представлень дозволяє моделі адаптувати свої параметри до поточних ринкових умов. Зокрема, вони використовуються у механізмах прийняття рішень, таких як Mixture of Experts, де вибір відповідного експерта визначається як функцією вхідних даних, так і поточного режиму ринку [41]. Це забезпечує більш гнучке моделювання та підвищує здатність системи до узагальнення в умовах змінного середовища [6, 13, 41].

Таким чином, використання механізму Regime Detection дозволяє враховувати структурні зміни у поведінці ринку та підвищує точність прогнозування за рахунок адаптації моделі до різних фаз фінансової динаміки [6, 12, 13] [рис. 2.6].




Рисунок 2.6 - Результати роботи моделі та їх збереження

2.2.7. Mixture of Experts

Для підвищення адаптивності моделі до різних станів фінансового ринку у її архітектурі використовується підхід Mixture of Experts, який передбачає наявність декількох спеціалізованих підмоделей (експертів). Кожен експерт орієнтований на обробку даних, що відповідають певному типу ринкової поведінки, зокрема різним режимам волатильності або структурним умовам ринку [41, 47].

Кожен із експертів реалізований у вигляді окремої нейронної мережі, яка обробляє вхідні ознаки та формує власне представлення даних. Таким чином, модель має можливість паралельно враховувати декілька альтернативних сценаріїв розвитку ринку, що підвищує її гнучкість та здатність до узагальнення [41].

Вибір або зважування експертів здійснюється за допомогою спеціального механізму — gating network. Ця мережа отримує на вході агреговані

представлення даних, зокрема результати попередніх шарів та embeddings режимів ринку, і формує ваги для кожного експерта. Отримані ваги нормалізуються та використовуються для побудови зваженої комбінації виходів експертів [41, 47].

Такий підхід дозволяє моделі динамічно адаптуватися до змін ринкового середовища. Наприклад, у періоди високої волатильності можуть активуватися експерти, які краще моделюють турбулентні стани, тоді як у стабільних умовах більшу вагу отримують експерти, орієнтовані на спокійні ринкові фази [6, 13, 41].

Додатково у процесі навчання використовується механізм балансування навантаження між експертами, що запобігає ситуації, коли модель надмірно покладається лише на одного з них. Це сприяє більш рівномірному використанню експертів та покращує якість узагальнення моделі [47].

Таким чином, використання підходу Mixture of Experts дозволяє моделі ефективно враховувати різноманітність ринкових режимів та забезпечує гнучке поєднання спеціалізованих стратегій прогнозування, що є важливим для задач аналізу фінансових часових рядів [6, 13, 41, 47].

2.2.8. Quantile Regression Output

Фінальним компонентом запропонованої моделі є блок формування вихідних прогнозів, реалізований у вигляді квантильної регресії (Quantile Regression Output). На відміну від класичних підходів, що генерують точкову оцінку, дана модель формує ймовірнісний прогноз, який відображає розподіл можливих значень майбутньої доходності секторів [19, 40]. Тут модель уже не грає в “одне число врятує світ”, бо фінансові ринки, на жаль, не такі ввічливі.

Вихід моделі представлений у вигляді набору квантилів, зокрема q_{10} , q_{50} та q_{90} , які відповідають нижній, медіанній та верхній оцінкам прогнозованого значення. Така структура дозволяє оцінити не лише очікуваний рівень

доходності, але й діапазон її можливих коливань, що є критично важливим для аналізу ризиків у фінансових задачах [26, 27, 30, 40].

Кожен квантиль моделюється окремою підмережею, що дозволяє гнучко враховувати різні аспекти розподілу. При цьому для забезпечення коректності прогнозу необхідно дотримуватися умови впорядкованості квантилів, тобто:

$$q_{10} \leq q_{50} \leq q_{90}.$$

Проблема перетину квантилів є типовою для моделей квантильної регресії, оскільки незалежне оцінювання різних квантилів може призводити до ситуації, коли нижній квантиль виявляється більшим за верхній [48]. Для реалізації цієї вимоги використовуються монотонні обмеження (monotonic constraints), які гарантують збереження правильного порядку квантилів незалежно від значень, що генеруються моделлю [48]. У практичній реалізації це досягається шляхом параметризації різниць між квантилями через невід’ємні функції, що забезпечує їх зростання.

Застосування квантильної регресії дозволяє перейти від детермінованого прогнозування до оцінювання умовного розподілу, що значно підвищує інформативність результатів [40]. Це, у свою чергу, створює основу для подальшого використання прогнозів у задачах управління ризиками, зокрема для розрахунку показників Value-at-Risk та Expected Shortfall [26, 27, 30].

Таким чином, блок Quantile Regression Output завершує обробку даних у моделі, забезпечуючи формування узгодженого та інтерпретованого ймовірнісного прогнозу для кожного сектору фінансового ринку [19, 40, 48].

2.3. Датасети

2.3.1. Секторні фінансові дані

Основним джерелом вхідної інформації для побудови моделі є секторні фінансові часові ряди, отримані з відкритої бази даних Kenneth R. French Data Library. Зокрема, використовується набір 49 галузевих портфелів (49 Industry

Portfolios), який є одним із стандартних бенчмарків у фінансових дослідженнях та широко застосовується для аналізу структури ринку [39].

Даний набір даних містить щоденні значення доходностей для кожної з 49 індустрій, сформованих на основі класифікації компаній за галузевою належністю [39]. Кожен стовпчик у датасеті відповідає окремому сектору, тоді як кожен рядок представляє один торговий день. Значення у таблиці відображають середню доходність відповідного сектору за день у відсотках [39]. Загальний період спостереження охоплює декілька десятиліть, що забезпечує достатню глибину історичних даних для навчання моделей фінансових часових рядів [17, 39].

У процесі підготовки даних часові ряди проходять попередню обробку, яка включає сортування за датою, фільтрацію за заданим часовим інтервалом, обробку пропущених значень та приведення до уніфікованого формату. Додатково може здійснюватися формування похідних ознак, таких як показники моментуму, волатильності та інші статистичні характеристики, що підвищують інформативність вхідних даних [15, 17].

Секторні фінансові дані виконують роль основного сигналу моделі, оскільки саме вони безпосередньо відображають динаміку ринку та використовуються як цільова змінна для прогнозування. Усі інші джерела інформації, зокрема зовнішні фактори, розглядаються як допоміжні та інтегруються з метою уточнення та покращення якості прогнозу [15, 19].

Таким чином, використання 49 галузевих портфелів як базового джерела даних забезпечує репрезентативне відображення структури ринку та створює надійну основу для побудови моделі прогнозування прибутковості секторів [39].

2.3.2. Інституційні фактори

У якості одного з джерел зовнішніх змінних у моделі використовуються інституційні фактори, представлені набором Worldwide Governance Indicators

(WGI), що розробляється Світовим банком. Даний набір даних містить узагальнені показники якості державного управління та інституційного середовища, які охоплюють широкий спектр характеристик функціонування державних систем [37, 49].

До складу WGI входять індикатори, що відображають такі аспекти, як право голосу та підзвітність, політична стабільність, ефективність уряду, якість регулювання, верховенство права та контроль корупції [37, 49]. Ці показники формуються на основі великої кількості джерел, включаючи експертні оцінки, опитування та статистичні дані, і надаються у вигляді агрегованих індексів для різних країн [37].

У контексті даної роботи інституційні фактори виконують роль змінних, що характеризують зовнішнє середовище функціонування фінансового ринку. Зокрема, показники політичної стабільності відображають рівень ризиків, пов'язаних із політичними подіями та змінами у державному управлінні, тоді як індикатори governance характеризують ефективність функціонування інституцій та регуляторного середовища [37].

Перед використанням у моделі дані WGI проходять попередню обробку, що включає очищення, трансформацію у зручний формат та узгодження з часовою шкалою фінансових даних. Оскільки вихідна частота цих показників є річною, здійснюється їх приведення до щоденного формату з урахуванням лагу публікації, що дозволяє уникнути використання інформації, яка фактично не була доступна на момент прогнозування [15, 37, 49].

Таким чином, інституційні фактори з набору WGI дозволяють врахувати вплив політичної стабільності та якості державного управління на поведінку фінансового ринку, доповнюючи внутрішньоринкові дані та підвищуючи інформативність моделі прогнозування [15, 37, 49].

2.3.3. Соціально-культурні фактори

Окрім інституційних характеристик, у моделі враховуються соціально-культурні фактори, представлені даними World Values Survey (WVS), що розробляється міжнародною дослідницькою організацією World Values Survey Association. Даний набір даних містить інформацію про цінності, переконання та поведінкові установки населення, що формуються у довгостроковій перспективі та відображають соціальний контекст функціонування економіки [38].

WVS включає широкий спектр показників, зокрема рівень міжособистісної довіри, ставлення до інституцій, соціальні норми, економічні очікування та інші поведінкові характеристики [38]. На відміну від традиційних макроекономічних індикаторів, ці змінні відображають глибинні процеси у суспільстві, які можуть опосередковано впливати на фінансові ринки через зміну інвестиційної поведінки, рівня ризик-апетиту та очікувань учасників ринку [15, 38].

У рамках даної роботи соціально-культурні фактори виконують роль поведінкового сигналу (behavioral signal), який доповнює кількісні фінансові та інституційні дані. Їх використання дозволяє врахувати нематеріальні аспекти, що формують ринкову динаміку, зокрема довіру до економічної системи, схильність до ризику та загальні соціальні настрої [15, 38].

Оскільки дані WVS мають низьку частоту оновлення та охоплюють тривалі часові періоди, вони використовуються для моделювання довгострокових трендів [38]. У процесі підготовки ці дані проходять очищення, трансформацію та узгодження з фінансовими часовими рядами. Аналогічно до інших зовнішніх факторів, здійснюється їх приведення до щоденного формату з урахуванням лагу публікації, що забезпечує коректність використання інформації у прогностичній моделі [15, 38].

Таким чином, включення соціально-культурних факторів дозволяє розширити інформаційну базу моделі за рахунок врахування поведінкових аспектів, що формують довгострокові тенденції на фінансових ринках, та

підвищує здатність системи до виявлення прихованих закономірностей у даних [15, 38].

2.4. Нормалізація та підготовка даних

2.4.1. Фінансові дані

Підготовка фінансових даних є ключовим етапом побудови моделі, оскільки саме ці дані формують основний сигнал для навчання та прогнозування. У якості вихідного джерела використовується набір секторних доходностей із Kenneth R. French Data Library, який містить часові ряди для 49 галузевих портфелів [39].

На першому етапі виконується сортування даних за часовою ознакою. Це забезпечує коректний порядок спостережень та є необхідною умовою для подальшої побудови часових вікон і застосування моделей, що враховують часову залежність [17, 19]. Всі записи впорядковуються за полем дати, що дозволяє сформувати послідовну часову шкалу.

Далі здійснюється фільтрація даних за обраним періодом. Відповідно до конфігурації моделі, визначається часовий інтервал, який використовується для навчання та тестування. Це дозволяє виключити надто ранні або нерелевантні спостереження, а також забезпечити узгодженість із зовнішніми джерелами даних, що використовуються у моделі [15, 37–39].

Наступним кроком є обробка пропущених значень. У фінансових часових рядах можливі як короткі, так і довгі пропуски, що можуть виникати внаслідок відсутності торгів або неповноти даних. Для коротких пропусків застосовується інтерполяція або заповнення на основі найближчих значень, тоді як записи з довгими розривами можуть бути виключені для забезпечення якості даних. Такий підхід дозволяє зберегти максимальний обсяг інформації без внесення значних спотворень [15, 17].

Після очищення та фільтрації дані приводяться до уніфікованого формату та використовуються для формування тензорного представлення. У фінальному

вигляді структура датасету містить такі поля: date, return_weighting, Agric, Food, Soda, Beer, Smoke, Toys, Fun, Books, Hshld, Clths, Hlth, MedEq, Drugs, Chems, Rubbr, Txtls, BldMt, Cnstr, Steel, FabPr, Mach, ElcEq, Autos, Aero, Ships, Guns, Gold, Mines, Coal, Oil, Util, Telcm, PerSv, BusSv, Hardw, Softw, Chips, LabEq, Paper, Boxes, Trans, Whlsl, Rtail, Meals, Banks, Insur, REst, Fin, Other [39].

Поле return_weighting використовується для розрізнення типу вагування портфелів, зокрема value-weighted або equal-weighted, при цьому основним сигналом для моделі виступають значення value-weighted доходностей [39]. Інші поля відповідають окремим галузевим секторам та містять відповідні часові ряди доходностей [39].

У результаті формується тензор даних розмірності (T, S, F) , де T — кількість часових спостережень, $S = 49$ — кількість секторів, а F — кількість ознак для кожного сектору. Даний тензор використовується як основний вхід у модель та забезпечує її здатність до навчання на багатовимірних часових залежностях [17, 19, 39].

Таким чином, процедура підготовки фінансових даних забезпечує їхню цілісність, узгодженість та придатність для подальшого використання у складній нейромережевій архітектурі прогнозування [17, 19, 39].

2.4.2. WGI

Обробка інституційних факторів, представлених набором Worldwide Governance Indicators (WGI), є важливим етапом підготовки зовнішніх даних для моделі. Оскільки вихідні дані WGI мають складну структуру та представлені у різних форматах, необхідно виконати низку трансформацій для приведення їх до уніфікованого вигляду, придатного для подальшого використання [37, 49].

На першому етапі здійснюється перетворення формату даних із довгого (long) у широкий (wide). У вихідному вигляді дані можуть бути представлені у вигляді записів, де кожен рядок відповідає окремому індикатору для певної

країни та року. Для подальшої роботи з моделлю необхідно об'єднати ці записи таким чином, щоб кожен рядок відповідав конкретній країні та року, а окремі індикатори були представлені у вигляді окремих стовпців [37, 49].

Наступним кроком є агрегація даних за роками. Оскільки WGI має річну частоту оновлення, всі показники узгоджуються на рівні календарного року [37, 49]. У випадках, коли доступні декілька значень для одного року, застосовується відповідна агрегація або вибір репрезентативного значення. Це дозволяє сформувати стабільний часовий ряд інституційних характеристик.

Після цього виконується відбір ознак (feature selection), спрямований на збереження найбільш інформативних показників. У фінальному датасеті залишаються такі стовпці: country, year, Control of Corruption: Estimate, Control of Corruption: Number of Sources, Control of Corruption: Percentile Rank, Control of Corruption: Percentile Rank, Lower Bound of 90% Confidence Interval, Control of Corruption: Percentile Rank, Upper Bound of 90% Confidence Interval, Control of Corruption: Standard Error, Government Effectiveness: Estimate, Government Effectiveness: Number of Sources, Government Effectiveness: Percentile Rank, Government Effectiveness: Percentile Rank, Lower Bound of 90% Confidence Interval, Government Effectiveness: Percentile Rank, Upper Bound of 90% Confidence Interval, Government Effectiveness: Standard Error, Political Stability and Absence of Violence/Terrorism: Estimate, Political Stability and Absence of Violence/Terrorism: Number of Sources, Political Stability and Absence of Violence/Terrorism: Percentile Rank, Political Stability and Absence of Violence/Terrorism: Percentile Rank, Lower Bound of 90% Confidence Interval, Political Stability and Absence of Violence/Terrorism: Percentile Rank, Upper Bound of 90% Confidence Interval, Political Stability and Absence of Violence/Terrorism: Standard Error, Regulatory Quality: Estimate, Regulatory Quality: Number of Sources, Regulatory Quality: Percentile Rank, Regulatory Quality: Percentile Rank, Lower Bound of 90% Confidence Interval, Regulatory Quality: Percentile Rank, Upper Bound of 90% Confidence Interval, Regulatory Quality: Standard Error, Rule of Law: Estimate, Rule of Law: Number of Sources, Rule of Law: Percentile Rank, Rule of

Law: Percentile Rank, Lower Bound of 90% Confidence Interval, Rule of Law: Percentile Rank, Upper Bound of 90% Confidence Interval, Rule of Law: Standard Error, Voice and Accountability: Estimate, Voice and Accountability: Number of Sources, Voice and Accountability: Percentile Rank, Voice and Accountability: Percentile Rank, Lower Bound of 90% Confidence Interval, Voice and Accountability: Percentile Rank, Upper Bound of 90% Confidence Interval, Voice and Accountability: Standard Error [37, 49].

Зазначені показники охоплюють ключові аспекти інституційного середовища, включаючи контроль корупції, ефективність уряду, політичну стабільність, якість регулювання, верховенство права та рівень громадянської участі [37, 49]. Додатково враховуються показники невизначеності, такі як стандартні похибки та інтервали довіри, що дозволяє моделі враховувати ступінь надійності оцінок [37, 49].

Після завершення обробки дані WGI інтегруються з фінансовими часовими рядами шляхом приведення до спільної часової шкали. Зокрема, річні значення трансформуються у щоденні шляхом розповсюдження останнього доступного значення на відповідний період із врахуванням лагу публікації. Це забезпечує коректність використання інформації та запобігає витоку даних у процесі навчання моделі [15, 37, 49].

Таким чином, підготовка даних WGI дозволяє сформувати структурований набір інституційних факторів, що відображають якість державного управління та політичну стабільність, і забезпечує їх ефективну інтеграцію у модель прогнозування [15, 37, 49].

2.4.3. WVS

Обробка соціально-культурних факторів, представлених даними World Values Survey (WVS), є важливим етапом формування зовнішнього інформаційного блоку моделі. Дані WVS характеризуються високою

розмірністю, неоднорідністю структури та наявністю значної кількості пропущених значень, що потребує комплексної процедури підготовки перед використанням у моделі [38].

На першому етапі виконується очищення даних. Воно включає видалення технічних та допоміжних змінних, обробку пропущених значень, приведення форматів змінних до уніфікованого вигляду, а також узгодження ідентифікаторів країн та часових міток. Особливу увагу приділено забезпеченню консистентності даних у межах різних хвиль опитувань, що дозволяє сформувати узгоджений часовий ряд соціально-культурних показників [38].

Наступним кроком є редукція факторів, спрямована на зменшення розмірності простору ознак та виділення найбільш інформативних змінних. Зважаючи на велику кількість початкових індикаторів, формується набір агрегованих індексів, які відображають ключові аспекти соціальної поведінки та цінностей. Зокрема, об'єднуються показники довіри, ставлення до інституцій, економічних очікувань та соціальних норм, що дозволяє знизити рівень шуму та підвищити стабільність моделі [38].

У результаті редукції формується фінальний набір ознак, який включає такі стовпці: country, year, generalized_social_trust_index, institutional_confidence_index, cultural_values_index, economic_perception_index, composite_social_index, economic_institutional_crisis_proxy, family_trust_index, neighborhood_trust_index, personal_acquaintance_trust_index, stranger_trust_index, other_religion_trust_index, other_nationality_trust_index, close_circle_trust_index, bridging_social_trust_index, confidence_in_press_index, confidence_in_police_index, confidence_in_parliament_index, confidence_in_civil_service_index, confidence_in_government_index, confidence_in_political_parties_index, confidence_in_major_companies_index, confidence_in_justice_system_index, confidence_in_united_nations_index, institutional_skepticism_index [38].

Даний набір охоплює як загальні індекси довіри та соціальної інтеграції, так і специфічні показники, що характеризують ставлення до різних інституцій та

соціальних груп. Це дозволяє сформувати багатовимірне представлення поведінкових факторів, які впливають на економічну активність та фінансові ринки [15, 38].

На завершальному етапі виконується інтеграція даних WVS з іншими джерелами. Оскільки вихідна частота даних є нерегулярною та значно нижчою за фінансові часові ряди, здійснюється їх приведення до річного формату з подальшим узгодженням із щоденними даними. Значення показників розповсюджуються на відповідні часові інтервали з урахуванням лагу доступності інформації, що дозволяє уникнути витоку даних у процесі навчання моделі [15, 38].

Таким чином, обробка даних WVS забезпечує формування узагальненого набору соціально-культурних індикаторів, які відображають поведінкові аспекти економічної системи та доповнюють фінансові й інституційні дані, підвищуючи інформативність моделі прогнозування [15, 38].

2.4.4. Узгодження частот

Оскільки у моделі використовуються джерела даних із різною частотою оновлення, важливим етапом є узгодження часових масштабів. Зокрема, фінансові дані мають щоденну частоту, тоді як зовнішні фактори, зокрема WGI та WVS, представлені переважно у річному або хвильовому форматі [37–39, 49]. Для їх коректної інтеграції необхідно привести всі змінні до єдиного часового представлення [15, 17, 19].

Першим кроком є трансформація річних значень зовнішніх факторів у щоденний формат (yearly → daily). Для цього використовується календар фінансових даних як базова шкала часу. Кожному торговому дню ставиться у відповідність актуальне значення зовнішнього фактору, яке було доступне на цей момент часу [15, 37–39, 49].

Далі застосовується метод заповнення вперед (forward-fill), при якому останнє відоме значення показника переноситься на всі наступні дні до моменту появи нового значення. Такий підхід дозволяє зберегти сталість зовнішніх факторів у межах відповідного періоду та забезпечити їх безперервне використання у моделі [15, 37, 38].

Критично важливим елементом узгодження є врахування лагу публікації даних (lag). У реальних умовах значення річних показників стають доступними лише через певний час після завершення відповідного періоду. Тому для кожного року використовується не фактична дата початку року, а дата з урахуванням затримки публікації. Це дозволяє уникнути витоку інформації (data leakage), коли модель отримує доступ до даних, які фактично не були відомі на момент прогнозування [15, 17, 19]. Так, навіть календар може підставити модель, бо, очевидно, одного хаосу в даних було замало.

Додатково у процесі узгодження формуються допоміжні ознаки, такі як індикатор оновлення зовнішніх даних, кількість днів від останнього оновлення та ступінь проходження року. Це дозволяє моделі враховувати динаміку появи нової інформації та її потенційний вплив на прогноз [15, 19] [рис. 2.7].




Рисунок 2.7 - Деталі інференсу

Таким чином, узгодження частот забезпечує коректну інтеграцію різнорідних джерел даних у єдину часову структуру, зберігаючи реалістичність інформаційного потоку та запобігаючи виникненню витоку даних у процесі навчання моделі [15, 17, 19, 37–39, 49].

2.5. Навчання моделі

2.5.1. Триетапний pipeline

Процес навчання та побудови моделі організований у вигляді триетапного пайплайну, який забезпечує послідовне формування структурних, факторних та прогнозних компонентів системи. Такий підхід дозволяє розділити складну задачу моделювання на окремі логічні етапи, кожен з яких вирішує специфічну підзадачу та формує необхідні артефакти для наступного кроку [7, 15, 17, 19, 24, 25] [рис. 2.8].

Перший етап (Round 1) присвячений побудові графової структури ринку. На цьому кроці виконується аналіз взаємозв'язків між секторами на основі їхніх часових рядів доходностей. Використовуються методи виявлення залежностей типу lead-lag, що дозволяє визначити напрямок та силу впливу між секторами [20, 42]. У результаті формується матриця впливів, а також здійснюється групування секторів на основі подібності їхніх взаємодій. Підсумком етапу є побудова статичних та динамічних графів, які використовуються у подальшій обробці [7, 24, 25].

Другий етап (Round 2) спрямований на аналіз зовнішніх факторів та їхнього впливу на ринок. Використовуються дані з наборів WGI та WVS, які проходять попередню обробку та узгодження [37, 38, 49]. На цьому етапі застосовуються регуляризовані моделі для оцінювання зв'язків між зовнішніми змінними та секторними доходностями або їх агрегованими групами [43]. Результатом є набір

факторних залежностей, що характеризують значущість та стабільність впливу кожного фактору [15, 37, 38, 43].




Рисунок 2.8 – Архітектура етапу Round 3: формування прогнозів

Третій етап (Round 3) є фінальним і включає побудову та навчання прогнозної моделі. На цьому кроці використовуються артефакти, отримані на попередніх етапах, зокрема графові структури та факторні залежності. Дані об'єднуються у єдине представлення, після чого формується навчальна вибірка з використанням ковзних часових вікон [17, 19]. Модель навчається у режимі багатовимірного ймовірнісного прогнозування, генеруючи квантильні оцінки майбутніх значень доходностей для кожного сектору [19, 40, 48] [рис. 2.9].




Рисунок 2.9 - Pipeline навчання

Такий триетапний підхід дозволяє послідовно врахувати внутрішню структуру ринку, вплив зовнішніх факторів та часову динаміку даних. Це забезпечує більш глибоке розуміння процесів, що відбуваються на ринку, та підвищує ефективність фінальної моделі прогнозування.

2.5.2. Walk-forward валідація

Для оцінювання якості моделі та забезпечення коректності її узагальнюючої здатності використовується підхід walk-forward валідації, який є стандартним підходом у задачах прогнозування часових рядів. Даний метод дозволяє врахувати часову структуру даних та уникнути порушення причинно-наслідкових зв'язків між навчальними та тестовими вибірками [17, 50].

Основною ідеєю підходу є послідовне розширення навчальної вибірки (expanding window). На кожній ітерації модель навчається на початковому відрізку даних, після чого перевіряється на наступних періодах. Після цього навчальна вибірка розширюється, включаючи нові спостереження, і процес повторюється. Такий підхід дозволяє моделювати реальні умови використання моделі, коли нові дані стають доступними поступово [50].

Кожен крок walk-forward валідації включає три основні підвибірки: навчальну (train), валідаційну (validation) та тестову (test). Навчальна вибірка використовується для підгонки параметрів моделі, валідаційна — для налаштування гіперпараметрів та контролю перенавчання, тоді як тестова вибірка застосовується для фінальної оцінки якості прогнозу. При цьому всі підвибірки формуються у хронологічному порядку, що забезпечує відсутність витоку інформації з майбутнього у минуле [17, 50].

Важливою особливістю даного підходу є те, що нормалізація даних та оцінювання допоміжних параметрів, наприклад меж режимів волатильності, виконуються лише на основі навчальної частини кожного кроку. Це дозволяє

уникнути використання інформації з тестового періоду під час навчання та забезпечує коректність оцінки моделі [17, 19, 50].

У результаті виконання walk-forward валідації формується набір прогнозів для кожного тестового періоду, які об'єднуються у загальний результат. Це дозволяє отримати більш надійну оцінку якості моделі, ніж у випадку одноразового розбиття даних, та врахувати змінність ринкових умов у часі [50].

Таким чином, використання walk-forward валідації з розширюваним вікном забезпечує реалістичну оцінку ефективності моделі у динамічному середовищі фінансового ринку та є необхідною умовою для побудови надійної системи прогнозування [17, 19, 50].

2.5.3. Loss-функції

Для навчання моделі використовується комбінована функція втрат, яка враховує різні аспекти якості прогнозу та дозволяє адаптувати модель до специфіки фінансових часових рядів. Зокрема, застосовується поєднання квантильної, напрямкової та рангової складових, що забезпечує як точність прогнозу, так і його економічну інтерпретованість [13, 26, 27, 40, 51, 52].

Основною складовою є квантильна функція втрат (quantile loss), яка використовується для навчання моделі ймовірнісному прогнозуванню. Вона базується на pinball loss та дозволяє оцінювати помилки прогнозу для різних квантилів розподілу [40]. Для кожного квантиля функція втрат асиметрично штрафує переоцінку та недооцінку, що забезпечує коректне відображення умовного розподілу цільової змінної [40]. Це є критично важливим для задач, пов'язаних із оцінкою ризиків, оскільки дозволяє моделі адекватно відтворювати хвости розподілу [26, 27, 30, 40].

Додатково використовується напрямкова функція втрат (directional loss), яка оцінює здатність моделі правильно визначати знак зміни доходності. У фінансових задачах правильне передбачення напрямку руху ринку часто є не

менш важливим, ніж точність самого значення [51]. Ця складова реалізується у вигляді бінарної класифікаційної втрати, що стимулює модель до коректного визначення зростання або падіння секторних доходностей [51].

Третьою складовою є рангова функція втрат (ranking loss), яка враховує відносне розташування секторів за прогнозованими значеннями. Вона спрямована на забезпечення коректного порядку секторів за рівнем доходності, що є важливим для задач портфельного відбору та побудови інвестиційних стратегій [13, 52]. Завдяки цьому модель навчається не лише відтворювати абсолютні значення, але й правильно оцінювати відносну привабливість різних секторів [52].

Загальна функція втрат формується як зважена сума зазначених компонентів, що дозволяє збалансувати їхній вплив залежно від цілей моделювання. Такий підхід забезпечує комплексну оптимізацію моделі, орієнтовану як на статистичну точність, так і на практичну корисність результатів [13, 40, 51, 52].

Таким чином, використання комбінованої функції втрат дозволяє ефективно враховувати різні аспекти прогнозування фінансових часових рядів та підвищує якість отриманих результатів [13, 26, 27, 40, 51, 52].

2.5.4. Метрики

Оцінювання якості побудованої моделі здійснюється з використанням набору метрик, які відображають різні аспекти точності прогнозування та його практичної цінності у фінансовому контексті. Враховуючи специфіку задачі, використовуються як класичні статистичні показники, так і спеціалізовані метрики, орієнтовані на оцінку напрямку руху, ранжування секторів та ризиків [13, 26, 27, 30, 50–52].

До базових метрик належать середня абсолютна похибка (MAE) та корінь із середньоквадратичної похибки (RMSE). MAE відображає середнє абсолютне

відхилення прогнозованих значень від фактичних і є більш стійкою до окремих великих помилок, тоді як RMSE сильніше штрафує великі помилки за рахунок квадратичного характеру функції [50]. Використання обох показників дозволяє комплексно оцінити точність моделі з урахуванням різних типів помилок [50].

Важливою характеристикою у фінансових задачах є здатність моделі правильно визначати напрямок зміни доходності. Для цього використовується метрика *directional accuracy*, яка показує частку випадків, у яких модель коректно передбачила знак зміни показника [51]. Цей показник є критично важливим для практичного застосування результатів, зокрема при прийнятті інвестиційних рішень [13, 51].

Для оцінювання якості ранжування секторів використовується коефіцієнт рангової кореляції (*rank IC*). Дана метрика вимірює відповідність між порядком секторів за прогнозованими значеннями та фактичними результатами. Високе значення *rank IC* свідчить про здатність моделі коректно визначати відносну привабливість секторів, що є важливим для задач побудови портфелів [13, 52].

Оскільки модель формує ймовірнісний прогноз, додатково застосовуються ризикові метрики, зокрема *Value-at-Risk (VaR)* та *Expected Shortfall (ES)*. *VaR* дозволяє оцінити максимальні потенційні втрати із заданою ймовірністю, тоді як *ES* характеризує середнє значення втрат у випадках перевищення *VaR* [26, 27]. Використання цих метрик дозволяє оцінити здатність моделі коректно відтворювати хвости розподілу та забезпечує її придатність для задач управління ризиками [26, 27, 30].

Таким чином, використання комплексного набору метрик дозволяє оцінити модель як з точки зору статистичної точності, так і з позиції її практичного застосування у фінансовому аналізі, забезпечуючи всебічну характеристику якості прогнозування [13, 26, 27, 30, 50–52].

2.6. Інференс та застосування

2.6.1. Генерація прогнозів

Після завершення етапу навчання модель використовується для генерації прогнозів, що здійснюється у межах окремого інференс-модуля. Даний модуль забезпечує підготовку даних, завантаження навченої моделі та формування вихідних прогнозів у відповідному форматі.

Одним із основних режимів роботи є генерація прогнозів для останнього доступного часового вікна (latest window). У цьому випадку модель використовує найновіші доступні дані для формування прогнозу на наступний часовий крок. Такий підхід відповідає реальному сценарію застосування, коли необхідно отримати актуальну оцінку майбутньої динаміки секторів на основі останніх спостережень [17, 19, 50].

Формування прогнозу включає підготовку вхідного тензора, який містить значення секторних ознак, графові структури, зовнішні фактори та режимні представлення за останні T днів. Після цього дані передаються у модель, яка генерує набір квантильних оцінок для кожного сектору, що відображають можливий діапазон майбутніх значень [19, 40, 48].

Окрім роботи з одним часовим вікном, підтримується режим пакетної обробки (batch inference). У цьому випадку модель застосовується до множини вхідних вікон одночасно, що дозволяє ефективно обробляти великі обсяги даних та отримувати прогнози для цілих підвибірок, наприклад, тестових або валідаційних наборів. Це є особливо важливим при проведенні бектестування та оцінюванні якості моделі на історичних даних [27, 50].

Результати прогнозування можуть зберігатися у різних форматах, зокрема у вигляді таблиць із зазначенням дати, сектору та відповідних квантильних значень. Це забезпечує зручність подальшого аналізу, візуалізації та використання результатів у прикладних задачах [19, 40].

Таким чином, модуль генерації прогнозів забезпечує гнучке та ефективне використання навченої моделі як для отримання актуальних оцінок, так і для масштабного аналізу історичних даних [17, 19, 40, 50].

2.6.2. API

Для забезпечення доступу до функціональності моделі у прикладному середовищі реалізовано програмний інтерфейс прикладного рівня (API), побудований із використанням фреймворку FastAPI. Даний підхід дозволяє організувати взаємодію з моделлю у вигляді веб-сервісу, що забезпечує гнучке використання системи у різних сценаріях, зокрема для інтеграції з іншими програмними компонентами [53].

API забезпечує централізований доступ до функцій генерації прогнозів, аналізу даних та моніторингу стану системи. При запуску сервера здійснюється ініціалізація інференс-модуля, завантаження навченої моделі та підготовка необхідних конфігурацій. Після цього система готова до обробки запитів у режимі реального часу [53].

Основна взаємодія з API здійснюється через набір кінцевих точок (endpoints), кожна з яких відповідає за виконання певної функції. Зокрема, передбачено endpoint для перевірки працездатності сервісу (health check), який повертає інформацію про статус системи. Також реалізовано endpoint для отримання прогнозів на основі останніх доступних даних, що дозволяє швидко отримати актуальні оцінки без необхідності ручної підготовки вхідних даних [53].

Окрім цього, передбачено можливість передачі довільних вхідних даних через окремий endpoint, що дозволяє виконувати прогнозування для заданих часових вікон. Це забезпечує гнучкість використання моделі та можливість інтеграції у різні прикладні сценарії, включаючи тестування та експерименти [53].

Додатково реалізовано endpoint для аналізу важливості ознак, який дозволяє оцінити вплив окремих факторів на результати прогнозування. Це сприяє підвищенню інтерпретованості моделі та забезпечує можливість більш глибокого аналізу її поведінки [54].

Таким чином, використання FastAPI для реалізації програмного інтерфейсу забезпечує ефективний доступ до функціональності моделі, дозволяє інтегрувати її у зовнішні системи та підтримує роботу у режимі реального часу з мінімальними затримками [53].

2.7. Інтерпретація моделі

Інтерпретація моделі є важливим етапом аналізу результатів, оскільки дозволяє зрозуміти внутрішні механізми прийняття рішень та оцінити внесок окремих компонентів у формування прогнозу. У контексті складних нейромережових архітектур, що поєднують графові, часові та екзогенні елементи, питання інтерпретованості набуває особливої актуальності [17, 19, 24, 25, 54].

Одним із основних інструментів інтерпретації є аналіз механізмів уваги (attention). Зокрема, у межах Temporal Transformer визначаються часові кроки, які мали найбільший вплив на прогноз, що дозволяє виділити ключові періоди у динаміці ринку [19, 46, 54]. У свою чергу, механізм Cross-Attention дозволяє оцінити важливість зовнішніх факторів, зокрема WGI та WVS, для кожного сектору у конкретний момент часу, що забезпечує розуміння ролі екзогенних змінних у формуванні результату [15, 19, 37, 38, 46, 54].

Додатково інтерпретація моделі здійснюється через аналіз ваг у модулі Mixture of Experts. Розподіл ваг між експертами дозволяє визначити, які саме підмоделі активуються за різних ринкових умов, що, у свою чергу, пов'язано з визначеними режимами волатильності [41, 47]. Це дає змогу оцінити, як модель

адаптується до змін середовища та які стратегії прогнозування використовуються у різних ситуаціях [6, 13, 41, 47].

Важливим аспектом є також оцінювання впливу окремих ознак на прогноз. Це може реалізовуватися шляхом варіювання вхідних даних та аналізу змін у вихідних значеннях, що дозволяє визначити чутливість моделі до різних факторів [54]. Такий підхід забезпечує більш глибоке розуміння причинно-наслідкових зв'язків у даних [42, 54].

Результати інтерпретації можуть бути представлені у вигляді графічних матеріалів, зокрема теплових карт ваг уваги, графіків важливості факторів та діаграм розподілу експертів. Це забезпечує наочність аналізу та полегшує сприйняття складних залежностей [54].

Таким чином, інтерпретація моделі дозволяє не лише оцінити її якість, але й зрозуміти логіку формування прогнозів, що є критично важливим для використання результатів у практичних задачах фінансового аналізу та управління ризиками [26, 27, 54].

Висновки до розділу 2

У другому розділі було розроблено концептуальну та архітектурну основу моделі прогнозування волатильності фондових ринків з урахуванням внутрішньоринкових зв'язків і зовнішніх шоків факторів. Запропонована система базується на багаторівневому підході, у межах якого фінансовий ринок розглядається не як набір ізольованих часових рядів, а як взаємопов'язана структура секторів, що реагують на власну динаміку, міжсекторні залежності та екзогенні впливи.

У межах загальної архітектури було визначено основні компоненти моделі: графове представлення ринку, блок аналізу зовнішніх факторів, Dual Graph Encoder, Temporal Transformer, Cross-Attention, Regime Detection, Mixture of Experts та Quantile Regression Output. Така структура дозволяє поєднати кілька

рівнів інформації: просторові залежності між секторами, часову динаміку волатильності, макроекономічні й соціально-інституційні фактори, а також режимну зміну ринкового середовища.

Графова модель ринку забезпечує формалізацію міжсекторних зв'язків і створює основу для врахування залежностей між галузевими портфелями. Dual Graph Encoder використовується для перетворення цієї структури у векторні представлення секторів, які можуть бути передані до подальших прогнозних блоків. Це дозволяє моделі враховувати не лише власну історію сектору, а й інформацію про його положення у загальній структурі ринку.

Temporal Transformer відповідає за моделювання часової динаміки фінансових рядів. Його використання є доцільним у задачі прогнозування волатильності, оскільки така архітектура дозволяє працювати з довгими часовими залежностями та складними послідовними патернами. У поєднанні з графовим представленням це створює основу для одночасного врахування часової й структурної інформації.

Блок Cross-Attention забезпечує інтеграцію зовнішніх факторів у процес прогнозування. До таких факторів належать макроекономічні показники, індикатори невизначеності, фінансового стресу, геополітичного ризику, товарні ринки, валютні курси, а також інституційні й соціально-культурні змінні. Використання механізму уваги дозволяє моделі адаптивно визначати, які зовнішні сигнали є найбільш релевантними для конкретного сектору та конкретного ринкового періоду.

Окрему роль у запропонованій архітектурі відіграє Regime Detection. Цей блок дозволяє враховувати, що фінансові ринки можуть перебувати у різних станах, зокрема у режимах стабільності, підвищеної невизначеності або кризової турбулентності. У поєднанні з Mixture of Experts це дає змогу моделі не використовувати один універсальний шаблон прогнозування для всіх ринкових ситуацій, а адаптувати прогноз залежно від поточного режиму.

Quantile Regression Output забезпечує ймовірнісний характер прогнозування. Такий підхід є важливим для задачі волатильності, оскільки

дозволяє оцінювати не лише одне очікуване значення майбутньої мінливості, а й діапазон можливих сценаріїв. Це створює основу для подальшого аналізу ризику, зокрема через оцінювання хвостових подій, інтервалів невизначеності та ризикових метрик.

У розділі також було визначено склад і роль основних датасетів, необхідних для побудови моделі. Секторні фінансові дані формують базовий часовий ряд для аналізу ринкової динаміки. Інституційні фактори дозволяють врахувати якість державного управління, політичну стабільність і регуляторне середовище. Соціально-культурні фактори доповнюють модель інформацією про довіру, ціннісні орієнтації та ширший соціальний контекст, який може впливати на реакцію ринків на зовнішні шоки.

Було розглянуто процес нормалізації та підготовки даних, зокрема обробку фінансових рядів, підготовку WGI та WVS, а також узгодження частот між різними типами джерел. Це є необхідним етапом, оскільки фінансові дані, макроекономічні індикатори та соціально-інституційні показники мають різну періодичність, різну структуру та різний рівень повноти. Коректне узгодження таких даних дозволяє уникнути інформаційних втрат, помилок синхронізації та витоку майбутньої інформації у процес навчання.

Для навчання моделі було визначено триетапний pipeline, який охоплює підготовку даних, побудову ознак і навчання прогнозної архітектури. Окремо було обґрунтовано використання walk-forward валідації, оскільки вона краще відповідає природі фінансових часових рядів, ніж випадковий поділ вибірки. Такий підхід дозволяє оцінювати модель у послідовному часовому режимі та наближати перевірку якості до реального сценарію прогнозування.

У межах розділу було визначено loss-функції та метрики, які мають використовуватися для оцінювання моделі. Вони повинні відображати не лише середню точність прогнозу, а й якість оцінювання ризику та стабільність моделі в різних ринкових умовах. Такий підхід узгоджується з метою роботи, оскільки прогнозування волатильності має практичну цінність лише тоді, коли воно дозволяє точніше оцінювати майбутню невизначеність і потенційні ризики.

Також було описано логіку інференсу та практичного застосування моделі. Генерація прогнозів, API-рівень і візуалізація результатів формують прикладний контур системи, який дозволяє використовувати модель не лише як дослідницьку конструкцію, а й як основу для програмної реалізації. Це забезпечує зв'язок між математичною постановкою задачі, архітектурою моделі та її подальшим використанням у прикладному середовищі.

Окремо було розглянуто питання інтерпретації моделі. Для складних нейромережевих архітектур це є важливим елементом, оскільки прогноз має бути не лише чисельно точним, а й аналітично зрозумілим. Інтерпретація графових зв'язків, уваги до зовнішніх факторів, режимних станів і внеску окремих компонентів моделі дозволяє краще пояснити, чому модель формує певний прогноз волатильності.

Отже, у другому розділі було сформовано повну методологічну основу запропонованої системи прогнозування. Розроблена архітектура поєднує графове моделювання міжсекторних залежностей, часове моделювання фінансових рядів, інтеграцію зовнішніх факторів, режимну адаптацію та ймовірнісний прогнозний вихід. Це створює підґрунтя для подальшої програмної реалізації, навчання, тестування та порівняльного оцінювання моделі у третьому розділі роботи.

РОЗДІЛ 3. ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ТА АНАЛІЗ РЕЗУЛЬТАТІВ МОДЕЛІ

3.1. Загальна постановка експерименту

Експериментальна частина роботи спрямована на перевірку працездатності запропонованої триетапної системи прогнозування секторних фінансових часових рядів. На відміну від теоретичного опису архітектури, поданого у другому розділі, у даному розділі здійснюється аналіз фактичних результатів роботи моделі на основі сформованих фінансових, інституційних та соціально-культурних даних. Основна мета експерименту полягає у перевірці того, наскільки поєднання графового аналізу, зовнішніх факторів та нейромережевого прогнозування дозволяє підвищити інформативність прогнозу порівняно з ізольованим аналізом секторних рядів [7, 15, 19, 24, 25].

У якості базового фінансового джерела використовується набір 49 галузових портфелів Kenneth R. French Data Library, який містить щоденні ряди секторних доходностей та дозволяє розглядати ринок не як сукупність окремих активів, а як систему взаємопов'язаних індустріальних секторів [39]. Такий рівень агрегації є доцільним для дослідження міжсекторних залежностей, оскільки він зменшує шум окремих інструментів і водночас зберігає структурну різноманітність ринку.

Зовнішній інформаційний блок формується на основі двох джерел: Worldwide Governance Indicators та World Values Survey. Показники WGI використовуються для врахування інституційного середовища, зокрема політичної стабільності, ефективності державного управління, якості регулювання, верховенства права та контролю корупції [37, 49]. Дані WVS доповнюють модель соціально-культурними та поведінковими характеристиками, зокрема показниками довіри, ставлення до інституцій, соціальних норм та суспільних цінностей [38]. Використання цих джерел

дозволяє оцінювати не лише внутрішньоринкові залежності, а й вплив ширшого макроекономічного та соціального контексту на секторну динаміку [15, 37, 38].

Експериментальний pipeline складається з трьох послідовних етапів. Перший етап, Round 1, спрямований на виявлення міжсекторної структури ринку. На цьому етапі аналізуються кореляційні та напрямлені залежності між секторами, після чого формуються групи секторів, матриці впливів та графові представлення ринку [7, 20, 24, 25, 42]. Другий етап, Round 2, присвячений аналізу зовнішніх факторів. У його межах оцінюються зв'язки між WGI/WVS-показниками та секторними доходностями або агрегованими секторними групами із використанням регуляризованих моделей [15, 37, 38, 43, 49]. Третій етап, Round 3, є фінальним прогностичним блоком, у якому результати попередніх етапів інтегруються у модель багатовимірного ймовірнісного прогнозування [19, 40, 48].

Оцінювання якості моделі здійснюється із застосуванням walk-forward валідації, що дозволяє зберегти хронологічний порядок спостережень і наблизити експеримент до реальних умов використання моделі [50]. У межах такого підходу навчання, валідація та тестування виконуються послідовно за часовими відрізками, без використання майбутньої інформації під час побудови прогнозу. Це є принципово важливим для фінансових часових рядів, де порушення часової структури призводить до некоректної оцінки якості моделі [17, 19, 50].

Для оцінювання результатів використовується набір статистичних, напрямкових, рангових та ризикових метрик. До нього входять MAE, RMSE, directional accuracy, balanced accuracy, кореляція прогнозованих і фактичних значень, RankIC, ZeroSkill, PICP та інші показники, що дозволяють оцінити модель не лише з точки зору числової похибки, але й з позиції практичної придатності для фінансового аналізу [13, 26, 27, 30, 50–52]. Узагальнену структуру експериментального pipeline подано в таблиці 3.1.

Таблиця 3.1 — Структура експериментального pipeline

Етап	Основні вхідні дані	Основний результат	Роль у фінальній моделі
1	Секторні доходності 49 галузевих портфелів	Кореляційні матриці, напрямлені впливи, секторні групи, статичні та динамічні графи	Формування графової структури ринку для подальшого використання у графовому енкодері
2	WGI, WVS, секторні доходності та секторні групи	Зв'язки між зовнішніми факторами, секторами та групами секторів	Визначення релевантних і інституційних і соціально-культурних факторів для інтеграції у прогнозну модель
3	Секторні часові ряди, графові артефакти, зовнішні фактори, режимні ознаки	Квантильні прогнози, метрики якості, секторні та режимні результати	Фінальне багатовимірне ймовірнісне прогнозування секторних доходностей

Таким чином, експериментальна постановка дозволяє послідовно перевірити всі ключові складові запропонованої системи: наявність міжсекторної структури, релевантність зовнішніх факторів та якість фінального прогнозування. Це забезпечує цілісну оцінку моделі не лише як нейромережевої архітектури, а як повного pipeline для аналізу та прогнозування секторної динаміки фінансового ринку.

3.2. Аналіз міжсекторної кореляційної структури ринку

Першим етапом експериментального дослідження є аналіз міжсекторної кореляційної структури ринку, виконаний у межах Round 1. Метою цього етапу є

виявлення стійких зв'язків між секторними доходностями та перевірка того, чи має ринок виражену структурну організацію, яку доцільно враховувати у подальшій графовій моделі. Для цього було побудовано market-neutral матрицю міжсекторних кореляцій, що відображає ступінь співруху між 49 галузевими портфелями після нейтралізації загального ринкового компонента [7, 20, 24, 25, 39].

На рисунку 3.1 подано теплову карту міжсекторних кореляцій, де червоні відтінки відповідають додатним кореляційним зв'язкам, сині — від'ємним, а значення поблизу білого кольору свідчать про слабку або майже нульову залежність між секторами. Діагональні елементи матриці дорівнюють одиниці, оскільки відображають кореляцію кожного сектору із самим собою. Основне аналітичне значення мають позадіагональні блоки, які демонструють силу зв'язків між різними секторами та групами секторів.




Рисунок 3.1 — Матриця міжсекторних market-neutral кореляцій Round 1

Результати показують, що міжсекторна структура не є випадковою: у матриці чітко простежуються локальні блоки секторної близькості. Найбільш виражені додатні кореляції спостерігаються всередині груп секторів, які мають подібну економічну природу або належать до суміжних напрямів ринкової активності. Зокрема, помітні блоки високої внутрішньогрупової близькості у технологічно-виробничих, фінансових, сировинних та споживчих сегментах. Це підтверджує, що секторні доходності не є незалежними часовими рядами, а формують структуровану систему взаємопов'язаних елементів [7, 24, 25].

У межах подальшого аналізу сектори були агреговані у шість груп: G1 PerSv/Trans, G2 Smoke/Insur, G3 Autos/Fun, G4 Guns/Ships, G5 Meals/Other та G6 Rubbr/Util. Таке групування використовується для переходу від аналізу окремих секторів до аналізу більш узагальненої ринкової структури. Наявність візуально виражених блоків у кореляційній матриці підтверджує доцільність такого підходу, оскільки сектори всередині окремих груп демонструють вищий рівень взаємної близькості порівняно з секторами з інших груп.

Разом із тим між різними групами секторів спостерігаються слабші, а в окремих випадках і від'ємні кореляційні зв'язки. Це означає, що різні частини ринку можуть реагувати на однакові умови неоднаково або навіть у протилежних напрямках. Зокрема, наявність синіх зон у матриці свідчить про потенційні диверсифікаційні ефекти та неоднорідність секторної реакції на ринкові зміни. Така неоднорідність є важливою для подальшого прогнозування, оскільки модель повинна враховувати не лише загальний ринковий рух, але й специфіку поведінки окремих секторних груп [13, 20, 24].

Отримана кореляційна матриця не є фінальним прогнозним результатом. Її роль полягає у структурній діагностиці ринку та формуванні підґрунтя для наступних етапів моделювання. Вона дозволяє виявити, які сектори мають подібну динаміку, які групи формують стійкі блоки взаємозалежності, а також де спостерігаються слабкі або протилежні зв'язки. Саме ці результати

обґрунтовують використання графового представлення ринку, у якому сектори розглядаються як вузли, а виявлені залежності — як зв'язки між ними [7, 24, 25].

Таким чином, аналіз міжсекторної market-neutral кореляційної структури підтверджує наявність внутрішньої організації фондового ринку на рівні галузевих портфелів. Виявлені блоки секторної близькості та неоднорідність міжгрупових залежностей свідчать про доцільність переходу від незалежного моделювання окремих секторів до графового підходу, який дозволяє враховувати структурні взаєм

3.3. Аналіз групових напрямлених впливів між секторами

Після аналізу міжсекторних кореляцій було виконано оцінювання напрямлених впливів між сформованими секторними групами. На відміну від кореляційної матриці, яка відображає лише синхронний співрух секторів, матриця напрямленого впливу дозволяє оцінити потенційні канали передавання сигналу між частинами ринку. Це є важливим для подальшого графового моделювання, оскільки у фінансових часових рядах значення має не лише сила зв'язку, а й те, яка група виступає джерелом зміни, а яка — її потенційним приймачем [20, 42].

У межах Round 1 напрямлені впливи оцінювалися на рівні шести секторних груп: G1 PerSv/Trans, G2 Smoke/Insur, G3 Autos/Fun, G4 Guns/Ships, G5 Meals/Other та G6 Rubbr/Util. Отримана матриця дозволяє перейти від аналізу окремих секторних кореляцій до більш узагальненої структури ринку, де кожна група розглядається як агрегований вузол системи. Результати такого аналізу подано на рисунку 3.2.

На рисунку 3.2 видно, що напрямлені зв'язки між групами мають виражену асиметричну структуру. Найбільш помітним джерелом додатного впливу є група G2 Smoke/Insur, для якої спостерігаються інтенсивні додатні значення щодо більшості інших груп. Це свідчить про те, що дана група може виконувати роль

одного з центральних каналів передавання сигналу у сформованій міжсекторній структурі. Особливо вираженими є додатні впливи з боку G2 на групи G1 PerSv/Trans, G3 Autos/Fun, G4 Guns/Ships, G5 Meals/Other та G6 Rubbr/Util.




Рисунок 3.2 — Матриця напрямленого міжгрупового впливу Round 1

Протилежна картина спостерігається для групи G6 Rubbr/Util, яка у матриці має переважно від’ємний напрямлений вплив на інші групи. Найсильніші від’ємні значення простежуються щодо G2 Smoke/Insur та G3 Autos/Fun, а також частково щодо G5 Meals/Other. Це означає, що сигнали, пов’язані з групою G6, можуть мати протилежну динаміку відносно інших секторних блоків або виконувати роль компенсуючого компонента у міжгруповій структурі.

Групи G1 PerSv/Trans, G3 Autos/Fun, G4 Guns/Ships та G5 Meals/Other демонструють більш локальні та менш однорідні зв'язки. Зокрема, для G1 помітний слабший позитивний вплив на G4 та слабший від'ємний вплив на G5. Для G3 і G4 більшість значень перебуває поблизу нуля, що свідчить про обмежену роль цих груп як самостійних джерел широкого міжгрупового впливу. Водночас їхня реакція на інші групи залишається важливою для загальної структури, оскільки вони виступають не лише джерелами, а й приймачами сигналів.

Для деталізації міжгрупових результатів було також побудовано матрицю впливу груп-джерел на окремі цільові сектори. Такий рівень аналізу дозволяє встановити, які саме сектори найбільш чутливі до сигналів, що надходять від певних груп. Результати подано на рисунку 3.3.

Рисунок 3.3 підтверджує висновки, отримані на рівні міжгрупової матриці. Група G2 Smoke/Insur демонструє найбільш виражений додатний вплив на широкий набір секторів. Особливо помітні додатні значення для секторів Autos, Chips, LabEq, Mach, Steel, Meals, Aero, MedEq, Drugs, Rubbr, Food та Whlsl. Це свідчить про те, що G2 є не лише впливовою на агрегованому рівні, а й має широкий секторний канал поширення сигналу.

Група G6 Rubbr/Util, навпаки, демонструє переважно від'ємний вплив на значну кількість секторів. Найбільш помітні від'ємні значення спостерігаються для Insur, BldMt, Banks, Fin, BusSv, Softw, LabEq, Mach, Txtls, RIEst, Cnstr, Other, Hlth, Hshld, Food та Beer. Це узгоджується з результатами міжгрупової матриці та вказує на те, що G6 може формувати протилежний або стримувальний сигнал щодо значної частини ринкової структури.

Окремі групи мають більш специфічний характер впливу. Наприклад, G1 PerSv/Trans демонструє локально виражені додатні зв'язки з Mines і Coal та від'ємний зв'язок із Soda. Групи G3 Autos/Fun, G4 Guns/Ships і G5 Meals/Other мають переважно слабші та більш фрагментарні впливи, що вказує на їхню меншу роль як широких джерел сигналу, але не виключає їхньої значущості для окремих секторів.




Рисунок 3.3 — Вплив груп-джерел на окремі цільові сектори Round 1

Узагальнення основних типів міжгрупових впливів подано в таблиці 3.2.

Таблиця 3.2 — Основні типи міжгрупових впливів у Round 1

Група-джерело	Група або сектор-ціль	Характер впливу	Інтерпретація
G2 Smoke/Insur	Більшість секторних груп	Переважаючий додатний	Група виступає одним із головних джерел позитивного міжсекторного сигналу
G6 Rubbr/Util	G2 Smoke/Insur, G3 Autos/Fun, G5 Meals/Other та низка окремих секторів	Переважаючий від’ємний	Група формує протилежний або компенсуючий сигнал щодо значної частини ринку
G1 PerSv/Trans	G4 Guns/Ships, Mines, Coal	Локально додатний	Вплив має вибірковий характер і проявляється для окремих груп або секторів
G3 Autos/Fun	Окремі секторні групи та сектори	Слабкий або близький до нуля	Група має обмежений вплив як джерело широкого сигналу
G4 Guns/Ships	Окремі секторні групи та сектори	Переважаючий слабкий	Вплив має фрагментарний характер і не формує домінантного ринкового каналу
G5 Meals/Other	Окремі секторні групи та сектори	Слабкий або помірний	Група виконує допоміжну роль у структурі напрямлених впливів

Отримані результати показують, що міжсекторна структура ринку має не лише кореляційний, а й напрямлений характер. Це означає, що окремі групи можуть виконувати роль джерел сигналу, тоді як інші групи або сектори переважно реагують на ці зміни. Така асиметрія є важливою для побудови графової моделі, оскільки вона дозволяє враховувати не просто факт наявності зв'язку, а його напрямок і потенційну роль у передаванні інформації між секторами [7, 20, 24, 25, 42].

Таким чином, аналіз напрямлених впливів у Round 1 підтверджує доцільність використання графового представлення ринку у фінальній прогнозній моделі. Найбільш значущими результатами цього етапу є виявлення G2 Smoke/Insur як основного джерела додатного міжсекторного сигналу, G6 Rubbr/Util як джерела переважно від'ємного впливу та наявність локальних каналів взаємодії між окремими групами й секторами.

3.4. Аналіз впливу інституційних факторів WGI

Другий етап експериментального дослідження передбачає аналіз зв'язків між інституційними факторами та секторною динамікою фінансового ринку. У межах Round 2 для цього використано набір Worldwide Governance Indicators, який характеризує якість інституційного середовища через показники контролю корупції, ефективності державного управління, політичної стабільності, якості регулювання, верховенства права, а також голосу та підзвітності [37, 49]. Метою цього етапу є визначення того, які інституційні фактори мають найбільш виражений зв'язок з окремими секторами та сформованими секторними групами.

Аналіз WGI-факторів виконано на чотирьох рівнях. Перший рівень відображає зв'язки окремих факторів з окремими секторами, другий — зв'язки окремих факторів із секторними групами, третій — вплив агрегованих груп WGI-факторів на окремі сектори, а четвертий — зв'язки між групами WGI-факторів та секторними групами. Така багаторівнева структура дозволяє оцінити не лише

точковий вплив окремих індикаторів, а й більш узагальнені закономірності між інституційним середовищем та ринковою структурою [15, 37, 43, 49].




Рисунок 3.4 — Вплив WGI-факторів на окремі сектори: Stage 1 factor → sector

На рисунку 3.4 подано зв'язки між окремими WGI-факторами та секторними доходностями. Результати демонструють, що вплив інституційних змінних є неоднорідним: різні сектори мають різну чутливість до одних і тих самих показників. Найбільш виражені додатні та від'ємні зони спостерігаються для фінансових, технологічних, сировинних, промислових та споживчих секторів. Це свідчить про те, що інституційні фактори не діють на ринок рівномірно, а формують секторно-специфічні патерни впливу.

На рівні окремих секторів помітно, що частина WGI-індикаторів пов'язана з позитивною реакцією одних секторів і водночас з негативною реакцією інших. Такий результат є очікуваним для багатосекторної ринкової системи, оскільки покращення або погіршення інституційних умов може по-різному впливати на галузі залежно від їхньої регуляторної чутливості, залежності від державної політики, експортної орієнтації або ролі у внутрішньому попиті [15, 37, 49].




Рисунок 3.5 — Вплив WGI-факторів на секторні групи: Stage 2 factor → group

На рисунку 3.5 показано зв'язки між окремими WGI-факторами та секторними групами. На відміну від Stage 1, цей рівень дозволяє зменшити шум окремих секторів і виявити більш стійкі групові закономірності. Найбільш виражені відмінності простежуються між групами G1 PerSv/Trans, G2 Smoke/Insur, G3 Autos/Fun, G4 Guns/Ships, G5 Meals/Other та G6 Rubbr/Util. Це

свідчить про те, що інституційні фактори впливають не лише на окремі галузі, а й на ширші секторні блоки.

Зокрема, для окремих груп спостерігаються стійкі додатні зв'язки з частиною WGI-показників, тоді як інші групи демонструють переважно від'ємні реакції. Така структура підтверджує доцільність використання групового рівня аналізу, оскільки він дозволяє виявити системні закономірності, які можуть бути менш помітними при розгляді лише окремих секторів.




Рисунок 3.6 — Вплив груп WGI-факторів на сектори: Stage 3 factor groups → sector

Для подальшого узагальнення окремі WGI-змінні були об'єднані у факторні групи: G1 RQ/GE, G2 CC/RQ, G3 PV/RQ, G4 VA/RQ та G5 GE/CC. Таке групування дозволяє оцінювати не окремі індикатори, а комплексні інституційні блоки, пов'язані з якістю регулювання, ефективністю управління, контролем корупції, політичною стабільністю та підзвітністю [37, 49].

На рисунку 3.6 показано вплив груп WGI-факторів на окремі сектори. Результати демонструють, що агреговані інституційні блоки мають різну силу та напрям зв'язку з секторами. Зокрема, окремі секторні групи демонструють виражену чутливість до факторних груп, пов'язаних із якістю регулювання та ефективністю управління, тоді як інші сильніше реагують на блоки, пов'язані з політичною стабільністю або контролем корупції. Це підтверджує, що інституційне середовище не може бути представлене одним узагальненим показником без втрати важливої інформації.




Рисунок 3.7 — Вплив груп WGI-факторів на секторні групи: Stage 4 factor groups → group

На рисунку 3.7 наведено найузагальненіший рівень аналізу — зв'язки між групами WGI-факторів та секторними групами. Цей фрагмент дозволяє оцінити, які інституційні блоки є найбільш релевантними для окремих секторних груп. Результати показують, що секторні групи мають різний профіль інституційної чутливості. Наприклад, одна група може демонструвати додатний зв'язок із

блоками, пов'язаними з ефективністю управління та контролем корупції, тоді як інша — від'ємний зв'язок із політичною стабільністю або регуляторною якістю.

Такий результат є важливим для фінальної прогнозної моделі, оскільки він підтверджує необхідність врахування інституційних факторів не як однорідного зовнішнього фону, а як структурованого набору ознак із різною секторною релевантністю. Саме тому результати Round 2 використовуються як додатковий факторний контекст для прогнозування, а не як самостійний фінальний результат [15, 37, 43, 49].

Таким чином, аналіз WGI-факторів показав, що інституційне середовище має виражений, але неоднорідний зв'язок із секторною динамікою. Окремі фактори та їх агреговані групи по-різному пов'язані з секторами та секторними групами, що підтверджує доцільність інтеграції WGI-блоку у загальну модель прогнозування. Отримані результати дозволяють розширити опис ринку за межі внутрішніх фінансових сигналів і врахувати інституційний контекст як один із компонентів екзогенного впливу.

3.5. Аналіз впливу соціально-культурних факторів WVS

Окрім інституційних показників WGI, у межах Round 2 було проведено аналіз впливу соціально-культурних факторів, сформованих на основі даних World Values Survey. На відміну від WGI, які характеризують якість державного управління та інституційного середовища, WVS-фактори відображають поведінковий і соціальний контекст: рівень соціальної довіри, довіру до інституцій, ставлення до поліції, преси та міжнародних організацій, ціннісні орієнтації, crisis proxy, а також різні форми close-circle trust і stranger trust [38]. Таким чином, WVS-блок не дублює інституційні змінні, а формує окремий шар зовнішніх факторів, пов'язаний із соціальною поведінкою та довгостроковими суспільними установками [15, 38].

Аналіз WVS-факторів, як і у випадку WGI, виконано на чотирьох рівнях: вплив окремих факторів на окремі сектори, вплив окремих факторів на секторні групи, вплив агрегованих груп WVS-факторів на сектори та вплив груп WVS-факторів на секторні групи. Така структура дозволяє оцінити як детальні секторні реакції, так і узагальнені закономірності взаємодії між соціально-культурним середовищем та ринковою динамікою [15, 38, 43].




Рисунок 3.8 — Вплив WVS-факторів на окремі сектори: Stage 1 factor → sector

На рисунку 3.8 подано зв'язки між окремими WVS-факторами та секторними доходностями. Отримані результати демонструють виражену неоднорідність секторної реакції на соціально-культурні змінні. Частина секторів має додатні зв'язки з показниками довіри, соціальних цінностей або

інституційної впевненості, тоді як інші сектори демонструють від’ємні зв’язки з тими самими факторами. Це свідчить про те, що соціально-культурний контекст впливає на ринок не як однорідний фоновий показник, а через диференційовані канали, пов’язані зі специфікою окремих галузей.

Особливо помітними є відмінності між секторами, чутливими до споживчої поведінки, фінансової довіри, регуляторних очікувань та загального суспільного настрою. Показники close-circle trust, institutional trust, confidence in police, confidence in press, confidence in UN, stranger trust та crisis proxy формують різні патерни зв’язків із секторами. Це підтверджує доцільність використання WVS як окремого джерела зовнішніх ознак, оскільки такі показники не можуть бути повністю замінені макроекономічними або інституційними індикаторами [15, 38].




Рисунок 3.9 — Вплив WVS-факторів на секторні групи: Stage 2 factor → group

На рисунку 3.9 показано вплив окремих WVS-факторів на сформовані секторні групи. Перехід до групового рівня дозволяє зменшити шум окремих секторів і виявити більш стійкі закономірності. У результатах видно, що групи G1 PerSv/Trans, G2 Smoke/Insur, G3 Autos/Fun, G4 Guns/Ships, G5 Meals/Other та G6 Rubbr/Util мають різні профілі чутливості до соціально-культурних факторів.

Зокрема, окремі групи демонструють виражені додатні зв'язки з показниками соціальної або інституційної довіри, тоді як інші мають від'ємні зв'язки з тими самими змінними. Це означає, що соціально-культурні фактори можуть по-різному відображатися у секторах, пов'язаних зі споживанням, фінансовими послугами, промисловістю, оборонними або утилітарними напрямками. Така неоднорідність є важливою для фінальної моделі, оскільки вона вказує на необхідність секторно-специфічної інтеграції зовнішніх факторів [15, 38, 43].




Рисунок 3.10 — Вплив груп WVS-факторів на сектори: Stage 3 factor groups
→ sector

Для узагальнення окремі WVS-змінні було об'єднано у факторні групи: G1 Values/Crisis, G2 Police/CloseTrust, G3 UN/Press, G4 InstTrust та G5 Trust. Таке групування дозволяє аналізувати не лише окремі соціальні показники, а ширші поведінкові блоки, що характеризують суспільні цінності, кризове сприйняття, довіру до поліції та близького кола, ставлення до міжнародних і медійних інституцій, загальну інституційну довіру та базовий рівень соціальної довіри [38].

На рисунку 3.10 подано вплив груп WVS-факторів на окремі сектори. Результати показують, що агреговані соціально-культурні блоки мають різну силу та напрям зв'язку з окремими галузями. Наприклад, групи, пов'язані з довірою та інституційним сприйняттям, можуть мати додатний зв'язок з одними секторами й від'ємний з іншими. Це свідчить про те, що поведінковий контекст не є універсальним фактором ринкової реакції, а має вибірккову секторну дію.

Окреме значення мають фактори, пов'язані з crisis проху та загальними ціннісними орієнтаціями, оскільки вони можуть відображати довгострокову зміну суспільних очікувань і рівня невизначеності. Такі фактори є релевантними для прогнозування фінансової динаміки, оскільки зміна соціальної довіри або кризового сприйняття може впливати на ризик-апетит, інвестиційні очікування та поведінку економічних агентів [15, 38].

На рисунку 3.11 наведено узагальнений рівень взаємодії між групами WVS-факторів та секторними групами. Цей фрагмент дозволяє оцінити, які саме соціально-культурні блоки є найбільш релевантними для різних частин ринку. Результати демонструють, що секторні групи мають різні профілі чутливості до груп WVS-факторів. Зокрема, окремі секторні групи сильніше пов'язані з блоком Values/Crisis, тоді як інші демонструють помітніші зв'язки з Trust, InstTrust або Police/CloseTrust.

Наявність таких відмінностей підтверджує, що соціально-культурні змінні мають окрему аналітичну цінність для моделювання секторної динаміки. Якщо WGI описує формальну якість інституційного середовища, то WVS дозволяє

врахувати неформальний поведінковий контекст, зокрема рівень довіри, суспільні очікування та ставлення до інституцій [37, 38, 49]. Саме тому використання WVS-факторів розширює інформаційну базу моделі та доповнює інституційний блок, не замінюючи його.




Рисунок 3.11 — Вплив груп WVS-факторів на секторні групи: Stage 4 factor groups → group

Таким чином, аналіз WVS-факторів показав, що соціально-культурні змінні мають неоднорідний і секторно-специфічний зв'язок із фінансовою динамікою. Окремі фактори та їх агреговані групи по-різному пов'язані з секторами та секторними групами, що підтверджує доцільність включення WVS-блоку у модель прогнозування. Отримані результати свідчать, що поведінковий і соціальний контекст є окремим джерелом інформації, яке доповнює внутрішньоринкові та інституційні фактори у задачі прогнозування секторних доходностей.

3.6. Оцінювання якості фінальної прогнозової моделі Round 3

Фінальний етап експерименту, Round 3, присвячений оцінюванню якості прогнозової моделі, яка інтегрує результати попередніх етапів: секторні часові ряди, графові структури, зовнішні фактори WGI/WVS та режимні ознаки. На цьому етапі модель формує ймовірнісні прогнози для секторних доходностей у вигляді квантильних оцінок, а якість результатів оцінюється за набором статистичних, напрямкових, рангових та інтервальних метрик [19, 40, 48, 50–52].

На відміну від класичної оцінки точкового прогнозу, у даній роботі аналіз якості не обмежується лише абсолютною або квадратичною похибкою. Для фінансового прогнозування важливими є також здатність моделі правильно визначати напрям руху, ранжувати сектори за відносною привабливістю, формувати інтервали прогнозової невизначеності та демонструвати перевагу над базовим орієнтиром [13, 26, 27, 30, 51, 52]. Узагальнені результати Round 3 подано на рисунку 3.12.

MAE 0.3215	RMSE 0.7642	DirAcc 0.5812
ZeroSkill 0.0907	PICP 0.8456	AmpRatio 0.5972
BalAcc 0.650273	Corr 0.1647	RankIC 0.2341
UpShare 0.5428	ActUp 0.5310	SpreadSharpe 1.0305

Рисунок 3.12 — Узагальнені метрики якості прогнозування Round 3

Значення MAE становить 0.3215, що характеризує середній рівень абсолютної похибки прогнозу. RMSE дорівнює 0.7642 і, на відміну від MAE, сильніше реагує на великі помилки прогнозування. Спільне використання цих двох метрик дозволяє оцінити не лише середню точність моделі, а й наявність окремих значних відхилень у прогнозах [50].

Напрямова якість прогнозування оцінюється за допомогою DirAcc та BalAcc. Значення DirAcc дорівнює 0.5812, що означає, що модель частіше правильно визначає напрям зміни секторної доходності, ніж помиляється. Balanced accuracy становить 0.650273, що є важливим доповненням до звичайної напрямкової точності, оскільки враховує можливу незбалансованість між випадками зростання та падіння доходностей [51]. Це свідчить про те, що модель має не лише числову, а й напрямкову прогнозну здатність.

Кореляція між прогнозованими та фактичними значеннями становить 0.1647. Це значення не є високим, однак для задачі короткострокового прогнозування фінансових часових рядів воно вказує на наявність помірного узгодження між прогнозом і фактичною динамікою. Додатково RankIC дорівнює 0.2341, що свідчить про здатність моделі частково відтворювати правильне ранжування секторів за майбутньою доходністю. Для задач секторного аналізу цей результат є важливим, оскільки ранжування часто має практичне значення для порівняння секторів між собою [13, 52].

Показник ZeroSkill становить 0.0907, що відображає перевагу моделі відносно базового орієнтира. Додатне значення цього показника означає, що модель демонструє покращення порівняно з нульовою або наївною прогнозною стратегією. PISR дорівнює 0.8456, що характеризує частку фактичних значень, які потрапляють у прогнозний інтервал. Це свідчить про достатній рівень покриття прогнозованої невизначеності, що є важливим для використання моделі у задачах ризик-аналізу [26, 27, 40].

Показник AmpRatio становить 0.5972 і відображає співвідношення амплітуди прогнозованих значень до фактичної динаміки. Значення менше одиниці свідчить про те, що модель частково згладжує амплітуду ринкових коливань. UpShare дорівнює 0.5428, а ActUp — 0.5310, що показує відносну збалансованість між прогнозованою та фактичною часткою висхідних рухів. SpreadSharpe становить 1.0305, що вказує на наявність позитивного співвідношення між прогнозним спредом та ризиком у межах секторного ранжування.

Узагальнення основних метрик якості фінальної моделі подано в таблиці 3.3.

Таблиця 3.3 — Основні метрики якості фінальної моделі

Метрика	Значення	Зміст метрики	Інтерпретація для задачі прогнозування
MAE	0.3215	Середня абсолютна похибка	Характеризує середній масштаб відхилення прогнозу від фактичного значення
RMSE	0.7642	Корінь із середньоквадратичної похибки	Відображає чутливість моделі до великих помилок
DirAcc	0.5812	Частка правильно передбачених напрямків зміни	Показує здатність моделі визначати знак майбутньої доходності
BalAcc	0.650273	Збалансована напрямкова точність	Уточнює напрямкову якість з урахуванням дисбалансу класів
Corr	0.1647	Кореляція прогнозованих і фактичних значень	Відображає ступінь узгодженості прогнозу з реальною динамікою
RankIC	0.2341	Рангова кореляція між прогнозним і фактичним порядком секторів	Оцінює якість відносного ранжування секторів
ZeroSkill	0.0907	Перевага над базовим прогнозом	Показує покращення моделі порівняно з наївним орієнтиром
PICP	0.8456	Частка фактичних значень у прогнозованому інтервалі	Характеризує якість покриття прогнозованої невизначеності

AmpRatio	0.5972	Співвідношення амплітуди прогнозу до фактичної амплітуди	Показує ступінь відтворення масштабу коливань
UpShare	0.5428	Частка прогнозованих висхідних рухів	Відображає схильність моделі прогнозувати зростання
ActUp	0.5310	Фактична частка висхідних рухів	Дає базу для порівняння з UpShare
SpreadSharpe	1.0305	Співвідношення прогнозного секторного спреда до ризику	Характеризує практичну корисність ранжування секторів

Окрім агрегованих метрик, було проведено секторний аналіз якості прогнозування. Його результати подано на рисунку 3.13 у вигляді scorecard-матриці, де рядки відповідають секторам, а стовпці — основним метрикам оцінювання. Такий формат дозволяє виявити, для яких секторів модель демонструє кращу або слабшу якість, а також визначити неоднорідність результатів у межах ринкової структури.

Секторна scorecard-матриця показує, що якість прогнозування істотно відрізняється між галузями. Для частини секторів модель демонструє кращі результати за показниками похибки, напрямкової точності, рангової якості та покриття інтервалів, тоді як для інших секторів спостерігаються слабші значення окремих метрик. Це свідчить про те, що фінальна модель не працює однаково для всіх секторів, а її ефективність залежить від характеру секторної динаміки, рівня шуму, чутливості до зовнішніх факторів та позиції сектору в графовій структурі ринку [7, 13, 19, 24, 25].

Зокрема, у зведеному описі результатів найкращим сектором за zero-skill MAE визначено Gold, тоді як найслабшим сектором за цим критерієм є Hshld. Це вказує на те, що для окремих секторів модель має суттєвішу перевагу над базовим прогнозом, тоді як для інших секторів така перевага є менш вираженою. Така

неоднорідність є важливою для практичного використання моделі, оскільки вона показує, що результати доцільно аналізувати не лише в агрегованому вигляді, а й на рівні окремих секторів.




Рисунок 3.13 — Секторна scorecard-матриця Round 3

Таким чином, результати Round 3 підтверджують, що фінальна модель забезпечує багатовимірну оцінку майбутньої секторної динаміки. Вона демонструє прийнятний рівень абсолютної та квадратичної похибки, здатність до напрямкового прогнозування, часткове відтворення секторного ранжування, достатнє покриття прогнозного інтервалу та додатну перевагу над базовим орієнтиром. Сукупність цих результатів свідчить про практичну придатність моделі для аналізу секторних фінансових часових рядів, особливо у задачах порівняння секторів, оцінювання невизначеності та підтримки ризик-орієнтованого фінансового аналізу.

3.7. Аналіз стійкості результатів у часі

Окрім агрегованої оцінки якості фінальної моделі, важливим етапом експериментального аналізу є перевірка стійкості результатів у часі. Для цього було використано результати walk-forward валідації, у межах якої модель послідовно перевіряється на різних часових відрізках без порушення хронологічного порядку даних [50]. Такий підхід дозволяє оцінити не лише загальну якість прогнозування, а й те, наскільки стабільно модель працює в умовах зміни ринкового середовища.

На відміну від одноразового розбиття вибірки, walk-forward перевірка дає змогу простежити динаміку метрик за окремими фолдами. Це є особливо важливим для фінансових часових рядів, оскільки їхні властивості можуть змінюватися у часі під впливом кризових періодів, змін волатильності, структурних зламів та зовнішніх факторів [6, 17, 50]. У даній роботі для аналізу часової стійкості використано блок Fold Evolution, який відображає зміну основних метрик якості за роками.

На рисунку 3.14 подано зміну чотирьох ключових показників за walk-forward фолдами: ZeroSkill, BalAcc, RankIC та PICP. Ці метрики дозволяють оцінити різні аспекти стійкості моделі: перевагу над базовим прогнозом, напрямкову якість, здатність до ранжування секторів та покриття прогнозного інтервалу. Використання кількох метрик одночасно є необхідним, оскільки покращення за одним критерієм не завжди означає загальне покращення якості прогнозу [13, 26, 27, 50–52].

Результати показують, що якість моделі не є повністю однорідною в часі. Для окремих фолдів спостерігаються сильніші значення ZeroSkill та BalAcc, що свідчить про кращу здатність моделі перевершувати базовий орієнтир і правильніше визначати напрям руху секторних доходностей. Водночас в інших періодах ці показники знижуються, що вказує на складність підтримання однакової якості прогнозування в умовах змінної ринкової структури.

Метрика RankIC також демонструє часову мінливість. Це означає, що здатність моделі правильно ранжувати сектори за майбутньою доходністю залежить від конкретного ринкового періоду. У стабільніших фолдах модель краще відтворює відносний порядок секторів, тоді як у складніших періодах ранговий сигнал послаблюється. Такий результат є характерним для фінансового прогнозування, оскільки відносна привабливість секторів може швидко змінюватися під впливом нових ринкових або зовнішніх умов [13, 52].




Рисунок 3.14 — Динаміка якості моделі за walk-forward фолдами

Окремо слід відзначити показник PISР, який характеризує частку фактичних значень, що потрапляють у прогнозний інтервал. Його динаміка за фолдами дає змогу оцінити, наскільки стабільно модель відтворює прогнозну невизначеність. Наявність змін у PISР свідчить про те, що рівень покриття інтервалів також залежить від ринкового періоду. Це є важливим для ризик-орієнтованого застосування моделі, оскільки в різних фазах ринку однакова архітектура може по-різному оцінювати межі майбутніх коливань [26, 27, 40].

Загальна картина Fold Evolution свідчить про наявність часової неоднорідності результатів. Модель демонструє працездатність на різних фолдах, однак її ефективність змінюється залежно від періоду. Це узгоджується з властивостями фінансових часових рядів, для яких характерні нестабільність параметрів, зміна режимів волатильності та структурні злами [6, 17]. Саме тому оцінювання моделі лише за усередненими метриками є недостатнім: часовий аналіз дозволяє виявити періоди посилення або послаблення прогнозної здатності.

Таким чином, аналіз стійкості результатів у часі показав, що фінальна модель має змінну, але збережену прогнозну здатність у межах walk-forward перевірки. Найбільш інформативним є спільний розгляд ZeroSkill, BalAcc, RankIC та PISР, оскільки він дозволяє оцінити не лише точність, а й напрямкову, рангову та інтервальну якість прогнозування. Отримані результати підтверджують необхідність використання часово коректної валідації та подальшого аналізу моделі в розрізі ринкових режимів.

3.8. Аналіз результатів за ринковими режимами

Окремим етапом оцінювання фінальної моделі є аналіз її результатів у розрізі ринкових режимів. Такий підхід є необхідним, оскільки фінансові часові ряди мають неоднорідну структуру: у різні періоди ринок може перебувати у

стані відносної стабільності, підвищеної турбулентності або кризової динаміки. У другому розділі було передбачено механізм Regime Detection, який дозволяє враховувати різні фази ринкової поведінки через режимні ознаки та відповідні embeddings [6, 12, 13]. У цьому пункті аналізується, як така режимна неоднорідність відображається у фактичних результатах прогнозування.

У межах експерименту результати було згруповано за трьома основними режимами: calm, turbulent та crisis. Режим calm відповідає періодам відносно низької волатильності та стабільнішої ринкової поведінки. Режим turbulent характеризує періоди підвищеної мінливості, коли ринок демонструє сильніші коливання та менш стабільні залежності. Режим crisis відповідає найбільш напруженим періодам, у яких спостерігаються суттєві відхилення від звичайної динаміки та підвищений рівень ризику [6, 13].




Рисунок 3.15 — Порівняння якості прогнозування за ринковими режимами

На рисунку 3.15 подано порівняння основних метрик прогнозування за трьома ринковими режимами. Аналіз включає такі показники, як MAE, RMSE, DirAcc, BalAcc, Corr, RankIC, ZeroSkill, PICP, AmpRatio, UpShare, ActUp та SpreadSharpe. Такий набір метрик дозволяє оцінити не лише середню похибку

прогнозу, а й напрямкову якість, рангову здатність, покриття прогнозного інтервалу та практичну корисність секторного ранжування [13, 26, 27, 30, 50–52].

У режимі *calm* модель демонструє найбільш стабільну поведінку. Для цього режиму характерні нижчі значення похибок порівняно з більш нестабільними періодами, а також відносно краща узгодженість між прогнозованими та фактичними значеннями. Це пояснюється тим, що в умовах низької волатильності структура залежностей між секторами є більш сталою, а короткострокові коливання менш різкі. У таких умовах модель ефективніше використовує історичні часові патерни, графові зв'язки та зовнішні фактори.

У режимі *turbulent* якість прогнозування стає менш однорідною. Зростання ринкової мінливості ускладнює точне відтворення амплітуди рухів, що може проявлятися у підвищенні MAE та RMSE або зниженні кореляції між прогнозом і фактичними значеннями. Водночас напрямкові та рангові метрики можуть зберігати інформативність, оскільки навіть за умов підвищеної волатильності модель здатна частково визначати загальний напрям руху або відносну позицію секторів. Це свідчить про те, що в турбулентному режимі модель може бути корисною не стільки для точного числового прогнозу, скільки для оцінювання відносних секторних змін.

У режимі *crisis* прогнозування є найбільш складним. Кризові періоди характеризуються різкими змінами волатильності, нестабільністю параметрів та послабленням раніше сформованих залежностей [6, 13]. У таких умовах може знижуватися точність точкового прогнозу та погіршуватися здатність моделі відтворювати масштаб фактичних коливань. Водночас саме для кризового режиму особливо важливими є інтервальні та ризикові характеристики, зокрема PISR, оскільки вони показують, наскільки модель здатна охоплювати невизначеність прогнозу та відображати потенційні крайні значення [26, 27, 40].

Порівняння режимів показує, що модель не має однакової ефективності в усіх ринкових станах. Найбільш передбачуваними є стабільні періоди, тоді як турбулентні та кризові режими супроводжуються погіршенням окремих метрик і підвищенням ролі інтервального прогнозування. Це підтверджує доцільність

включення Regime Detection до архітектури моделі, оскільки ринковий режим є важливим контекстом для інтерпретації результатів прогнозування [6, 12, 13].

Важливим результатом є те, що режимний аналіз дозволяє оцінити модель не лише за середньою якістю, а й за її поведінкою в різних умовах ринку. Усереднені метрики можуть приховувати те, що модель працює краще у спокійних періодах і слабше у кризових, або навпаки зберігає корисні напрямкові та рангові властивості навіть при зростанні волатильності. Тому аналіз за режимами доповнює результати walk-forward перевірки та дає більш повну характеристику стійкості моделі.

Таким чином, результати за ринковими режимами показують, що якість прогнозування залежить від стану ринку. У calm-режимі модель демонструє стабільнішу точність, у turbulent-режимі зростає значення напрямкових і рангових метрик, а в crisis-режимі ключову роль відіграють інтервальні та ризикові характеристики прогнозу. Це підтверджує практичну необхідність режимного компонента в архітектурі та обґрунтовує використання Regime Detection як одного з елементів фінальної системи прогнозування.

3.9. Інтерпретація отриманих результатів та практичне значення моделі

Проведене експериментальне дослідження дозволило оцінити запропоновану систему на трьох рівнях: структурному, факторному та прогнозному. Така логіка відповідає загальній архітектурі моделі, у якій фінальний прогноз формується не лише на основі історичних секторних доходностей, а й з урахуванням міжсекторних зв'язків, зовнішніх інституційних і соціально-культурних факторів, а також режимної структури ринку [7, 15, 19, 24, 25].

Результати Round 1 показали, що секторний ринок має виражену внутрішню структуру. Аналіз market-neutral кореляційної матриці виявив наявність блоків секторної близькості, а оцінювання напрямлених впливів дало змогу визначити

потенційні канали передавання сигналу між секторними групами. Це підтверджує, що незалежне моделювання окремих секторів є обмеженим підходом, оскільки воно не враховує структурні залежності між частинами ринку [7, 20, 24, 25, 42]. Відповідно, результати першого етапу обґрунтовують використання графового представлення ринку у фінальній моделі.

Результати Round 2 засвідчили, що зовнішні фактори мають неоднорідний зв'язок із секторною динамікою. Інституційні показники WGI відображають вплив якості державного управління, політичної стабільності, регуляторного середовища, верховенства права та контролю корупції на окремі сектори й секторні групи [37, 49]. Соціально-культурні фактори WVS, у свою чергу, доповнюють інституційний блок поведінковим контекстом, зокрема показниками довіри, ставлення до інституцій, соціальних норм, ціннісних орієнтацій і кризового сприйняття [38]. Отримані результати показали, що WGI та WVS не дублюють один одного, а описують різні рівні зовнішнього середовища, які можуть бути релевантними для прогнозування секторних доходностей [15, 37, 38].

Результати Round 3 дали змогу оцінити фактичну якість фінальної прогнозової моделі. Агреговані метрики показали, що модель має здатність до ймовірнісного прогнозування, напрямкового передбачення, часткового ранжування секторів і формування прогнозних інтервалів [19, 40, 48, 50–52]. Зокрема, використання квантильного виходу дозволяє аналізувати не лише очікуване значення майбутньої доходності, а й діапазон можливої невизначеності, що є важливим для задач фінансового ризику [26, 27, 40].

Практичне значення запропонованої моделі полягає у можливості її використання для комплексного аналізу секторної динаміки фінансового ринку. По-перше, модель дозволяє оцінювати ризики через інтервальні та квантильні прогнози, що створює основу для подальшого розрахунку ризикових характеристик, зокрема Value-at-Risk та Expected Shortfall [26, 27]. По-друге, результати можуть бути використані для секторного ранжування, оскільки модель формує відносні оцінки майбутньої привабливості секторів [13, 52]. По-

третє, режимний аналіз дозволяє виявляти періоди, у яких якість прогнозування змінюється, що є важливим для оцінювання стабільності моделі в умовах різної ринкової волатильності [6, 13].

Окрему цінність має можливість інтерпретації результатів через структурні та факторні компоненти. Графові артефакти Round 1 дають змогу пояснювати міжсекторні залежності, результати Round 2 — оцінювати роль зовнішніх факторів, а метрики Round 3 — визначати фактичну якість прогнозування. Завдяки цьому модель може використовуватися не лише як інструмент числового прогнозу, а й як аналітична система для дослідження того, які внутрішні та зовнішні чинники впливають на секторну поведінку фінансового ринку.

Узагальнення результатів експериментальних етапів подано в таблиці 3.4.

Таблиця 3.4 — Узагальнення результатів експериментальних етапів

Етап	Отриманий результат	Значення для моделі
Round 1	Виявлено міжсекторні кореляційні блоки, направлені впливи та секторні групи	Підтверджено доцільність графового представлення ринку та використання міжсекторних залежностей у прогнозуванні
Round 2 WGI	Встановлено неоднорідні зв'язки між інституційними факторами, секторами та секторними групами	Обґрунтовано включення інституційного контексту як зовнішнього блоку ознак
Round 2 WVS	Виявлено зв'язки між соціально-культурними факторами, секторами та секторними групами	Показано, що поведінкові та соціальні змінні доповнюють фінансові й інституційні дані
Round 3	Отримано фінальні квантильні прогнози та оцінено якість моделі за статистичними, напрямковими,	Підтверджено практичну придатність моделі для

	ранговими й інтервальними метриками	прогнозування, оцінювання ризику та секторного аналізу
Walk-forward та regime analysis	Виявлено часову та режимну неоднорідність якості прогнозування	Показано необхідність оцінювання моделі в різних ринкових умовах, а не лише за усередненими метриками

Таким чином, результати експериментального дослідження підтверджують, що запропонована модель має практичне значення для прогнозування секторних фінансових часових рядів, оцінювання ризиків, аналізу факторного впливу, секторного ранжування та виявлення нестабільних періодів ринку. Отримані результати узгоджуються з метою роботи, оскільки демонструють можливість побудови комплексної системи, яка поєднує внутрішньоринкові залежності, зовнішні фактори та сучасні методи машинного навчання для аналізу фінансової динаміки.

Висновки до розділу 3

У третьому розділі було проведено експериментальне дослідження запропонованої моделі прогнозування секторних фінансових часових рядів. Аналіз охоплював три основні етапи: виявлення міжсекторної структури ринку, оцінювання впливу зовнішніх факторів та перевірку якості фінальної прогнозованої моделі. Такий підхід дозволив оцінити не лише кінцеві прогнозовані метрики, а й проміжні структурні та факторні компоненти, які використовуються для побудови фінального прогнозу.

На першому етапі було підтверджено, що секторний ринок має виражену внутрішню структуру. Побудована market-neutral кореляційна матриця показала наявність блоків секторної близькості, а аналіз напрямлених міжгрупових впливів дозволив виявити потенційні канали передавання сигналу між

секторними групами. Це підтвердило доцільність використання графового представлення ринку, оскільки секторні доходності не є незалежними рядами, а формують систему взаємопов'язаних елементів.

На другому етапі було встановлено, що зовнішні фактори мають неоднорідний вплив на сектори та секторні групи. Інституційні показники WGI дозволили врахувати формальний контекст якості державного управління, політичної стабільності та регуляторного середовища, тоді як соціально-культурні фактори WVS відобразили поведінковий і суспільний контекст. Отримані результати показали, що ці групи факторів не дублюють одна одну, а доповнюють фінансові дані різними типами зовнішньої інформації.

Фінальна модель Round 3 забезпечила формування ймовірнісного прогнозу у вигляді квантильних оцінок для секторних доходностей. Оцінювання за набором метрик показало, що модель демонструє не лише числову точність, але й напрямкову здатність, часткову якість секторного ранжування, покриття прогнозного інтервалу та перевагу відносно базового орієнтира. Це підтверджує практичну доцільність використання моделі в задачах фінансового аналізу, де важливими є не лише точкові значення, а й оцінка невизначеності.

Окремий аналіз показав, що якість моделі відрізняється залежно від секторів, часових фолдів та ринкових режимів. У стабільніших періодах модель демонструє більш передбачувану поведінку, тоді як у турбулентних і кризових режимах зростає значення інтервальних, напрямкових та рангових характеристик. Це підтверджує необхідність оцінювання фінансових моделей не лише за усередненими показниками, а й у розрізі ринкових умов.

Таким чином, результати третього розділу підтвердили працездатність запропонованої системи та її придатність для подальшого використання у прогнозуванні секторних доходностей, аналізі ризиків, секторному ранжуванні та дослідженні впливу зовнішніх факторів на фінансовий ринок. Модель може бути використана як основа для побудови більш складних систем підтримки інвестиційних рішень та ризик-орієнтованого фінансового аналізу.

ВИСНОВКИ

У кваліфікаційній роботі було розглянуто задачу прогнозування волатильності та секторної динаміки фондового ринку з використанням методів машинного навчання, графового моделювання та зовнішніх макроінституційних і соціально-культурних факторів. У межах дослідження було обґрунтовано доцільність переходу від класичних однофакторних моделей волатильності до комплексної багатокомпонентної системи, здатної враховувати часові, міжсекторні, екзогенні та режимні залежності. Так, замість ізольованого прогнозування окремих фінансових рядів запропоновано підхід, у якому ринок розглядається як взаємопов'язана система секторів.

У першому розділі було проаналізовано теоретичні основи прогнозування фінансової волатильності. Розглянуто класичні ARCH/GARCH-підходи, моделі реалізованої волатильності, HAR та Realized GARCH, режимні моделі, методи машинного та глибокого навчання, графові підходи, спілловери, ризикові метрики та роль зовнішніх факторів. Проведений аналіз показав, що традиційні моделі є важливою теоретичною основою, однак мають обмеження при роботі зі складними нелінійними, міжринковими та екзогенними залежностями. Це сформувало підґрунтя для розроблення гібридної моделі, яка поєднує різні типи даних і механізми їх обробки.

У другому розділі було розроблено концепцію та архітектуру моделі прогнозування. Запропонована система побудована як триетапний pipeline, що включає виявлення міжсекторної структури ринку, аналіз зовнішніх факторів та фінальне прогнозування секторних доходностей. У моделі передбачено використання Dual Graph Encoder для врахування статичних і динамічних графових залежностей, Temporal Transformer для моделювання часової структури, Cross-Attention для інтеграції зовнішніх факторів, Regime Detection для врахування ринкових станів, Mixture of Experts для адаптивного вибору

підмоделей та Quantile Regression Output для формування ймовірнісного прогнозу. Ну так, архітектура вийшла не “одна LSTM і молимося”, а нормальна система, як і просив здоровий глузд.

У третьому розділі було проведено експериментальне дослідження працездатності запропонованого підходу. На першому етапі встановлено наявність структурованих міжсекторних залежностей, що підтвердило доцільність графового представлення ринку. На другому етапі показано, що інституційні фактори WGI та соціально-культурні фактори WVS мають неоднорідний вплив на сектори та секторні групи, тобто зовнішній контекст справді додає окремий інформаційний шар до фінансових даних. На третьому етапі оцінено якість фінальної прогнозної моделі за статистичними, напрямковими, ранговими та інтервальними метриками.

Отримані результати показали, що модель здатна формувати ймовірнісний прогноз секторних доходностей, оцінювати прогнозну невизначеність, частково відтворювати напрям руху та ранжування секторів, а також демонструвати перевагу над базовим орієнтиром. Окремий аналіз за walk-forward фолдами та ринковими режимами показав, що якість прогнозування змінюється залежно від часових періодів і стану ринку. Це підтвердило необхідність не лише агрегованої оцінки моделі, а й аналізу її поведінки у стабільних, турбулентних і кризових режимах.

Практичне значення отриманих результатів полягає у можливості використання запропонованої системи для прогнозування секторної динаміки, аналізу ризиків, оцінювання впливу зовнішніх факторів, виявлення нестабільних періодів та підтримки інвестиційних рішень. Розроблений підхід може бути використаний як основа для подальшого вдосконалення моделей фінансового прогнозування, зокрема шляхом розширення набору зовнішніх факторів, поглиблення режимного аналізу, оптимізації графової структури та порівняння з додатковими базовими моделями.

Таким чином, поставлену мету кваліфікаційної роботи досягнуто: було розроблено та експериментально перевірено модель прогнозування секторної фінансової динаміки, яка поєднує внутрішньоринкові часові ряди, міжсекторні графові залежності, зовнішні інституційні й соціально-культурні фактори та ймовірнісний підхід до формування прогнозу. Отримані результати підтверджують доцільність використання комплексних багатоджерельних моделей для аналізу волатильності та ризиків фондового ринку.

СПИСОК ДЖЕРЕЛ ТА ЛІТЕРАТУРИ

1. Andersen T. G., Bollerslev T., Diebold F. X., Labys P. Modeling and forecasting realized volatility // *Econometrica*. 2003. Vol. 71, No. 2. P. 579–625.
2. Engle R. F. Autoregressive conditional heteroskedasticity with estimates of the variance of United Kingdom inflation // *Econometrica*. 1982. Vol. 50, No. 4. P. 987–1007.
3. Bollerslev T. Generalized autoregressive conditional heteroskedasticity // *Journal of Econometrics*. 1986. Vol. 31, No. 3. P. 307–327.
4. Nelson D. B. Conditional heteroskedasticity in asset returns: a new approach // *Econometrica*. 1991. Vol. 59, No. 2. P. 347–370.
5. Glosten L. R., Jagannathan R., Runkle D. E. On the relation between the expected value and the volatility of the nominal excess return on stocks // *The Journal of Finance*. 1993. Vol. 48, No. 5. P. 1779–1801.
6. Hamilton J. D. A new approach to the economic analysis of nonstationary time series and the business cycle // *Econometrica*. 1989. Vol. 57, No. 2. P. 357–384.
7. Zhang C., Pu X., Cucuringu M., Dong X. Graph-based methods for forecasting realized covariances // *Journal of Financial Econometrics*. 2025. Vol. 23, No. 2. P. 1977–2016.
8. Corsi F. A simple approximate long-memory model of realized volatility // *Journal of Financial Econometrics*. 2009. Vol. 7, No. 2. P. 174–196.
9. Hansen P. R., Huang Z., Shek H. H. Realized GARCH: a joint model for returns and realized measures of volatility // *Journal of Applied Econometrics*. 2012. Vol. 27, No. 6. P. 877–906.
10. Barndorff-Nielsen O. E., Shephard N. Power and bipower variation with stochastic volatility and jumps // *Journal of Financial Econometrics*. 2004. Vol. 2, No. 1. P. 1–37.
11. Patton A. J. Volatility forecast comparison using imperfect volatility proxies // *Journal of Econometrics*. 2011. Vol. 160, No. 1. P. 246–256.

12. Rabiner L. R. A tutorial on hidden Markov models and selected applications in speech recognition // *Proceedings of the IEEE*. 1989. Vol. 77, No. 2. P. 257–286.
13. Ranoto T., Ranjbar F., Byers J. W. Deep learning-based trading strategy for index ETFs using LSTM and GARCH under market uncertainty. SSRN, 2025. DOI: 10.2139/ssrn.5615174.
14. Zhang Y., Zhang T., Hu J. Forecasting stock market volatility using CNN-BiLSTM-Attention model with mixed-frequency data // *Mathematics*. 2025. Vol. 13, No. 11. Article 1889.
15. Latif S., Aslam F., Ferreira P., Iqbal S. Integrating macroeconomic and technical indicators into forecasting the stock market: a data-driven approach // *Economies*. 2025. Vol. 13, No. 1. Article 6.
16. LeCun Y., Bengio Y., Hinton G. Deep learning // *Nature*. 2015. Vol. 521. P. 436–444.
17. Lim B., Zohren S. Time-series forecasting with deep learning: a survey // *Philosophical Transactions of the Royal Society A*. 2021. Vol. 379. Article 20200209.
18. Liu F., Liang C., Jia Z. Application of the deep learning integrated framework CEEMDAN-GRU-Informer in financial time series prediction // *Computational Economics*. 2025.
19. Caetano R., Oliveira J. M., Ramos P. Transformer-based models for probabilistic time series forecasting with explanatory variables // *Mathematics*. 2025. Vol. 13, No. 5. Article 814.
20. Diebold F. X., Yilmaz K. Better to give than to receive: predictive directional measurement of volatility spillovers // *International Journal of Forecasting*. 2012. Vol. 28, No. 1. P. 57–66.
21. Koop G., Pesaran M. H., Potter S. M. Impulse response analysis in nonlinear multivariate models // *Journal of Econometrics*. 1996. Vol. 74, No. 1. P. 119–147.

22. Ari Y., Kurt H., Uçak H. Volatility spillovers among EAGLE economies: insights from frequency-based TVP-VAR connectedness // *Mathematics*. 2025. Vol. 13, No. 8. Article 1256.
23. Del Nero L., Giudici P. Machine learning models to predict stock market spillovers // *Finance Research Letters*. 2025. Vol. 86. Article 108508.
24. Sonani M. S., Badii A., Moin A. Stock price prediction using a hybrid LSTM-GNN model: integrating time-series and graph-based analysis. *arXiv*, 2025. *arXiv:2502.15813*.
25. Kumar P. N., Umeorah N., Alochukwu A. Dynamic graph neural networks for enhanced volatility prediction in financial markets. *arXiv*, 2024. *arXiv:2410.16858*.
26. Naimoli A. The information content of sentiment indices in forecasting Value at Risk and Expected Shortfall: a Complete Realized Exponential GARCH-X approach // *International Economics*. 2023. Vol. 176. Article 100459.
27. Lecq M. van der, Vuuren G. van. Estimating Value at Risk and Expected Shortfall: a Kalman Filter Approach // *International Journal of Economics and Financial Issues*. 2024. Vol. 14, No. 1. P. 1–14.
28. Diebold F. X., Mariano R. S. Comparing predictive accuracy // *Journal of Business & Economic Statistics*. 1995. Vol. 13, No. 3. P. 253–263.
29. Hansen P. R., Lunde A., Nason J. M. The model confidence set // *Econometrica*. 2011. Vol. 79, No. 2. P. 453–497.
30. Lee M. C. A hybrid EGARCH–Informer model with consistent risk calibration for volatility and CVaR forecasting // *Mathematics*. 2025. Vol. 13, No. 19. Article 3108.
31. Krippner L. Measuring the stance of monetary policy in zero lower bound environments // *Economics Letters*. 2013. Vol. 118, No. 1. P. 135–138.
32. Baker S. R., Bloom N., Davis S. J. Measuring economic policy uncertainty // *The Quarterly Journal of Economics*. 2016. Vol. 131, No. 4. P. 1593–1636.
33. Caldara D., Iacoviello M. Measuring geopolitical risk // *American Economic Review*. 2022. Vol. 112, No. 4. P. 1194–1225.

34. Liang C., Luo Q., Li Y., Huynh L. D. T. Global financial stress index and long-term volatility forecast for international stock markets // *Journal of International Financial Markets, Institutions and Money*. 2023. Vol. 88. Article 101825.
35. Baur D. G., Lucey B. M. Is gold a hedge or a safe haven? An analysis of stocks, bonds and gold // *The Financial Review*. 2010. Vol. 45, No. 2. P. 217–229.
36. Dornbusch R., Fischer S. Exchange rates and the current account // *The American Economic Review*. 1980. Vol. 70, No. 5. P. 960–971.
37. Kaufmann D., Kraay A., Mastruzzi M. The Worldwide Governance Indicators: methodology and analytical issues // *Hague Journal on the Rule of Law*. 2011. Vol. 3. P. 220–246.
38. Inglehart R., Haerpfer C., Moreno A., Welzel C., Kizilova K., Diez-Medrano J., Lagos M., Norris P., Ponarin E., Puranen B. World Values Survey: all rounds — country-pooled datafile. Madrid; Vienna : JD Systems Institute; WVSA Secretariat, 2022.
39. French K. R. 49 Industry Portfolios // Kenneth R. French Data Library. Dartmouth College, Tuck School of Business. Электронный ресурс. Режим доступа: https://mba.tuck.dartmouth.edu/pages/faculty/ken.french/data_library.html. Дата обращения: 05.05.2026.
40. Koenker R., Bassett G. Regression quantiles // *Econometrica*. 1978. Vol. 46, No. 1. P. 33–50.
41. Jacobs R. A., Jordan M. I., Nowlan S. J., Hinton G. E. Adaptive mixtures of local experts // *Neural Computation*. 1991. Vol. 3, No. 1. P. 79–87.
42. Granger C. W. J. Investigating causal relations by econometric models and cross-spectral methods // *Econometrica*. 1969. Vol. 37, No. 3. P. 424–438.
43. Hoerl A. E., Kennard R. W. Ridge regression: biased estimation for nonorthogonal problems // *Technometrics*. 1970. Vol. 12, No. 1. P. 55–67.
44. Kipf T. N., Welling M. Semi-supervised classification with graph convolutional networks. arXiv, 2016. arXiv:1609.02907.
45. Veličković P., Cucurull G., Casanova A., Romero A., Liò P., Bengio Y. Graph attention networks. arXiv, 2017. arXiv:1710.10903.

46. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser Ł., Polosukhin I. Attention is all you need // Advances in Neural Information Processing Systems. 2017. Vol. 30.
47. Shazeer N., Mirhoseini A., Maziarz K., Davis A., Le Q., Hinton G., Dean J. Outrageously large neural networks: the sparsely-gated mixture-of-experts layer. arXiv, 2017. arXiv:1701.06538.
48. Bondell H. D., Reich B. J., Wang H. Noncrossing quantile regression curve estimation // Biometrika. 2010. Vol. 97, No. 4. P. 825–838.
49. World Bank. Worldwide Governance Indicators. Washington : World Bank. Электронный ресурс. Режим доступа: <https://www.worldbank.org/en/publication/worldwide-governance-indicators>. Дата звернення: 05.05.2026.
50. Hyndman R. J., Athanasopoulos G. Forecasting: principles and practice. 3rd ed. Melbourne : OTexts, 2021. Электронный ресурс. Режим доступа: <https://otexts.com/fpp3/>. Дата звернення: 05.05.2026.
51. Pesaran M. H., Timmermann A. A simple nonparametric test of predictive performance // Journal of Business & Economic Statistics. 1992. Vol. 10, No. 4. P. 461–465.
52. Burges C. J. C., Shaked T., Renshaw E., Lazier A., Deeds M., Hamilton N., Hullender G. Learning to rank using gradient descent // Proceedings of the 22nd International Conference on Machine Learning. New York : Association for Computing Machinery, 2005. P. 89–96.
53. FastAPI. FastAPI framework, high performance, easy to learn, fast to code, ready for production. Электронный ресурс. Режим доступа: <https://fastapi.tiangolo.com/>. Дата звернення: 05.05.2026.
54. Molnar C. Interpretable Machine Learning: a guide for making black box models explainable. 2nd ed. Электронный ресурс. 2022. Режим доступа: <https://christophm.github.io/interpretable-ml-book/>. Дата звернення: 05.05.2026.