

М. М. КОРАБЛЬОВ

доктор технічних наук, професор,
професор кафедри комп'ютерних інтелектуальних технологій та систем
Харківський національний університет радіоелектроніки
ORCID: 0009-0005-2540-7741

І. В. КОБЗЕВ

кандидат технічних наук, доцент,
доцент кафедри мультимедійних систем і технологій
Харківський національний економічний університет
імені Симона Кузнеця
ORCID: 0000-0002-7182-5814

Д. О. АНТОНОВ

аспірант кафедри комп'ютерних інтелектуальних технологій та систем
Харківський національний університет радіоелектроніки
ORCID: 0009-0000-2079-3413

ВИКОРИСТАННЯ ЕВОЛЮЦІОНУЮЧОЇ ГРАФОВОЇ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ПРОГНОЗУВАННЯ ЦІН НА ФОНДОВОМУ РИНКУ

Прогнозування цін на акції має важливе значення для ухвалення обґрунтованих інвестиційних рішень на фінансовому ринку. Аналіз рухів фінансового ринку та поведінки цін на акції надзвичайно складний через динамічну, нелінійну, нестационарну, непараметричну та хаотичну природу ринків. Для аналізу акцій з метою прогнозування фінансового ринку використовуються різні підходи. Традиційні методи, що засновані на інформації про часові ряди для акцій однієї компанії, не враховують взаємозв'язки між акціями інших компаній. Використання для цих цілей графових нейронних мереж (Graph Neural Networks – GNN), у яких взаємозв'язки часових рядів представлені як структура графа, а змінні представлені як вузли графа, значно підвищує точність прогнозування. Існуючі методи прогнозування зазвичай припускають, що структура графа взаємозв'язків, яка описується матрицею відносин та визначає метод агрегації графової нейронної мережі, фіксована за визначенням. Тому вони не можуть ефективно враховувати динамічні зміни у графах взаємозв'язків. У даній роботі для прогнозування цін акцій на фінансовому ринку пропонується використання еволюціонуючої графової нейронної мережі. Для отримання динамічних кореляцій між рухами цін у фінансових часових рядах будується граф взаємозв'язків у вигляді кластерів, генерація та еволюція структури та параметрів якої реалізуються з використанням дендритної штучної імунної мережі (Dendritic Artificial Immune network – DaiNet). До кожного згенерованого кластера графа взаємозв'язків для визначення цінової інформації виконується кодування цін за допомогою трансформерів. Потім повідомлення із структури графа взаємозв'язків та вхідні часові послідовності агрегуються на основі використання шару уваги часового графа. На останньому шарі GNN виконується остаточний прогноз майбутнього руху ціни кожної акції з використанням багатошарового перцептрона. Проведені експериментальні дослідження показали, що використання динамічної побудови графів та кластеризації акцій на основі DaiNet не лише відстежує часовий характер зв'язків між акціями, але й покращує ефективність прогнозування.

Ключові слова: прогнозування, фінансовий ринок, акції, взаємозв'язок, граф зв'язків, еволюція, графова нейронна мережа, штучна імунна мережа.

М. М. KORABLYOV

Doctor of Technical Sciences, Professor,
Professor at the Department of Computer Intelligent Technologies
and Systems
Kharkiv National University of Radio Electronics
ORCID: 0009-0005-2540-7741

І. В. KOBZEV

Candidate of Technical Sciences, Associate Professor,
Associate Professor at the Department of Multimedia Systems and Technologies
Simon Kuznets Kharkiv National University of Economics
ORCID: 0000-0002-7182-5814

D. O. ANTONOV

Postgraduate Student at the Department of Computer Intelligent Technologies
and Systems

Kharkiv National University of Radio Electronics

ORCID: 0009-0000-2079-3413

USING AN EVOLVING GRAPH NEURAL NETWORK FOR PRICE FORECASTING ON THE STOCK MARKET

Stock price forecasting is essential for making informed investment decisions in the financial market. Analyzing financial market movements and stock price behavior is extremely complex due to the dynamic, nonlinear, non-stationary, non-parametric, and chaotic nature of markets. Various approaches are used to analyze stocks for the purpose of financial market forecasting. Traditional methods based on time series information for stocks of one company do not take into account the relationships between stocks of other companies. The use of graph neural networks (GNN) for this purpose, in which time series relationships are represented as a graph structure and variables are represented as graph nodes, significantly improves the accuracy of forecasting. Existing forecasting methods usually assume that the structure of the relationship graph, which is described by the relationship matrix and determines the aggregation method of the graph neural network, is fixed by definition. Therefore, they cannot effectively account for dynamic changes in the relationship graphs. In this paper, the use of an evolving graph neural network is proposed for forecasting stock prices in the financial market. To obtain dynamic correlations between price movements in financial time series, a cluster-based relationship graph is constructed, the generation and evolution of the structure and parameters of which are implemented using a dendritic artificial immune network (DaiNet). For each generated cluster of the relationship graph, price coding is performed using transformers to determine price information. Then, messages from the relationship graph structure and input time sequences are aggregated based on the use of the attention layer of the time graph. The final forecast of the future price movement of each stock is performed at the last layer of the GNN using a multilayer perceptron. Experimental studies have shown that the use of dynamic graph construction and stock clustering based on DaiNet tracks the temporal nature of the relationships between stocks and improves forecasting performance.

Key words: forecasting, financial market, stocks, relationship, connection graph, evolution, graph neural network, artificial immune network.

Постановка проблеми

Моделювання багатовимірних часових рядів (Multivariate Time Series – MTS) відіграє важливу роль у сучасних інтелектуальних системах. Однак точне прогнозування MTS все ще залишається складним завданням через можливість наявності прихованих змінних кореляцій як усередині часових рядів, так і між ними. Здатність прогнозувати ціни на акції є важливою для прийняття обґрунтованих інвестиційних рішень на фінансовому ринку.

Для вирішення задачі прогнозування фінансового ринку використовуються різні підходи: статистичні методи, розпізнавання образів, графіки, машинне навчання тощо. Традиційні методи навчання розглядають часові ряди змін акцій як незалежні та рівномірно розподілені відносно один одного, що не збігається з реальною ситуацією на фінансовому ринку. Наприклад, дві акції в одному секторі можуть мати вищу кореляцію, ніж акції в різних сферах. Ефект зв'язку на фінансовому ринку, де на ціни акцій впливають ціни пов'язаних акцій, вимагає використання більш повних даних. Врахування взаємозв'язків між акціями може підвищити ефективність прогнозування цін акцій.

Для обробки нелінійних залежностей використовуються методи глибокого навчання. Одними з перших моделей прогнозування MTS на основі глибокого навчання були LSTNet та TPA-LSTM [1], які поєднують згорткову нейронну мережу (CNN) та рекурентну нейронну мережу (RNN) для вилучення як внутрішньо-, так і міжчасових залежностей. Останнім часом для прогнозування MTS ефективно використовуються GNN, в яких взаємодії часових рядів представлені як структура графа зв'язків, а змінні представлені як вузли графа [2]. Існуючі методи прогнозування зазвичай припускають, що структура графа зв'язків, яка описується матрицею відносин та визначає метод агрегації графової нейронної мережі, є фіксованою (статичною) за визначенням і будується або вручну експертом, або за допомогою обробки природної мови (Natural Language Processing – NLP), або є самонавчальною.

Використання методів NLP для прогнозування стикається зі значними труднощами у виведенні зв'язків з високою точністю. Крім того, зв'язки можуть динамічно змінюватися з часом. Існуючі методи прогнозування цін на акції, що засновані на навчанні графів, є неоптимальними в динамічно мінливих ситуаціях. Щоб зробити GNN гнучкою та практичною структурою, необхідно моделювати в ній еволюціонуючі взаємодії часових рядів, тобто одночасно фіксувати попарні кореляції та часову залежність.

Таким чином, методи прогнозування цін на акції, які припускають фіксовану структуру графа зв'язків, мають низьку точність прогнозування. У реальних застосуваннях взаємодія змінних є динамічною та еволюційною. Крім того, взаємодія часових рядів у різних часових масштабах також може бути різною. Оскільки у реальних даних MTS кореляції з часом змінюються, то прогнозування з використанням статичного графа зв'язків може призвести до значних зміщень.

Таким чином, розробка моделі прогнозування цін акцій на фондовому ринку на основі еволюціонуючої графової нейронної мережі, яка враховує зміни взаємозв'язків між акціями, є актуальним завданням, яке може підвищити точність прогнозування цін на акції.

Аналіз існуючих досліджень і публікацій

Методи прогнозування MTS можна розділити на дві категорії: а) методи, засновані на неявній залежності; та б) методи, засновані на структурній залежності. У першій категорії методів, одним із репрезентативних методів якої є LSTNet [1], залежність змінних фіксується за допомогою згортки над змінними. У другій категорії методів кореляція змінних представлена у вигляді графів зв'язків, а прогнозування реалізується за допомогою GNN.

Як відомо, різні фактори фінансового ринку суттєво впливають на зміни цін на акції. В існуючих дослідженнях найпоширенішим підходом є ручна побудова різних факторів як вхідних функцій [3]. Так, ринкові дані інтегруються з фундаментальними та технічними індикаторами акцій для прийняття рішень. У [4] встановлюється зв'язок між новою інформацією та пов'язаними об'єктами для прогнозування руху цін на акції.

Щоб вивчити послідовні приховані особливості історичної інформації та застосувати їх до задачі прогнозування, більшість існуючих методів використовують рекурентні нейронні мережі та їх варіанти, такі як LSTM та GRU [5]. Однак ринкові дані для кожної акції обробляються незалежно, що не враховує внутрішні зв'язки між акціями, що призводить до низької точності прогнозування та низької продуктивності. Інформація про кореляцію акцій використовується як вхідні дані для моделі прогнозування, але динамічні зміни у зв'язках між акціями не реєструються автоматично.

У [6] зазначається, що зміни цін на акції пов'язані не лише з їхніми історичними цінами, але й з акціями інших компаній, а для зберігання та представлення цих зв'язків використовуються графи знань. Для ефективного навчання на графічно структурованих даних у [7] пропонується використовувати графову нейронну мережу (GNN), яка показала високу продуктивність у різних сферах. Зв'язки між компаніями моделюються в графах знань, а для прогнозування змін цін на акції використовуються графові згорткові мережі. У [8] для вивчення кореляцій між компаніями використовується графова нейронна мережа уваги. Слід зазначити, що GNN, побудовані за допомогою цих методів, обмежені фіксованими, попередньо визначеними зв'язками між компаніями, які підтримуються за допомогою ручного редагування або методів обробки природної мови.

У [9] Graph Wavenet використовується для вивчення кореляції змінних часових рядів за допомогою статичного представлення вузлів та захоплення часової закономірності за допомогою згорткових нейронних мереж (CNN). Також вивчається статична кореляція змінних часових рядів, але для прогнозування MTS запропоновано новий модуль згортки графів. Динамічний зв'язок між змінними в [10] моделюється за допомогою механізмів самоуваги, але побудовані GNN дуже чутливі до вхідних даних, що призводить до значної дисперсії в прогнозуванні.

У [11] запропоновано гібридну модель аналізу акцій, яка використовує комбінацію різних інтелектуальних технологій: рекурентних нейронних мереж (RNN) для отримання характеристик ціни акцій, штучних імунних систем (AIS) для отримання інформації про взаємозв'язок між акціями та графових нейронних мереж (GNN) для оцінки прибутковості акцій. Але структура згенерованого графа взаємозв'язку також фіксована.

У деяких роботах досліджуються графові структури, які змінюються з часом. Однак ці графові структури не безпосередньо відповідають задачі прогнозування, що може призвести до упереджених результатів. У [12] для прогнозування MTS використовуються трансформери, але вони не повністю враховують питання динамічної залежності змінних. Однак у реальних умовах корпоративні відносини змінюються з часом, і графи відносин, що їх описують, можуть бути неоднорідними, тобто між компаніями може існувати кілька типів відносин.

Таким чином, існуючі методи не дозволяють повною мірою використовувати всю інформацію з реальних графів взаємозв'язків компаній.

Формулювання мети дослідження

Метою роботи є побудова еволюціонуючої графової нейронної моделі для аналізу акцій фінансового ринку, яка б інтегрувала інформацію про зміни цін на акції з часом та взаємозв'язки між ними, а також підвищила точність їх прогнозування.

Викладення основного матеріалу дослідження

Розглянемо архітектуру запропонованої нейронної мережі на основі часового графу та її компоненти (рисунок 1), яка використовується для прогнозування цін на акції на фінансовому ринку.

Спочатку, на основі вхідних часових рядів характеристик торгівлі акціями, генерується граф взаємозв'язків між акціями компаній з виділеними кластерами, який визначає динамічні взаємозв'язки на ринку для кожного торгового дня. Потім ціни кодуються за допомогою трансформерів, які вибирають центральні часові вузли кластерів та їхні сусідні вузли для визначення цінової інформації для кожного згенерованого кластера графа взаємозв'язків. Далі виконується агрегація повідомлень зі структури графа взаємозв'язків та вхідних часових послідовностей на основі використання шару уваги часового графа, який адаптивно розраховує важливість сусідів та агрегує інформацію за важливістю сусідів.




Рис. 1. Архітектура нейронної мережі на основі часового графу

В останньому шарі GNN виконується остаточний прогноз майбутнього руху ціни кожної акції за допомогою багатшарового перцептрона (MLP) для інтеграції вищезазначених компонентів. Використання повністю зв'язаних шарів дозволяє моделі агрегувати витягнуті ознаки часового ряду, що спрощує процес прогнозування. Останній шар з функцією активації SoftMax використовується для виведення ймовірностей прогнозування майбутнього руху кожної акції. Розглянемо детальніше реалізацію цих етапів.

Створимо GNN для вилучення динамічних кореляцій між змінними з часових рядів для вирішення задачі прогнозування ціни акцій. Часові ряди в аналізі фінансового ринку – це хронологічні набори спостережень, такі як щоденні результати продажів та ціни акцій компаній. Використаємо набори спостережень для створення часових графів відносин компаній для кожного торгового дня. Вхідними даними багатшарового перцептрона (MLP) є часові ряди торгових характеристик акцій $X = (X^{(1)}, X^{(2)}, \dots, X^{(n)}, \dots, X^{(T)})$, $X \in R^{N \times T \times n}$, де N – кількість акцій, T – довжина часового ряду, n – розмірність акції. На виходах MLP отримуємо характеристики (представлення) цін акцій кожного часового ряду $P_t^i = (p_1^i, p_2^i, \dots, p_i^i, \dots, p_T^i)$, $i = \overline{1, N}$ для торгового дня t :

$$P_t^i = \theta_t(X_t^i), \quad (1)$$

де θ_t – функція перетворення.

Виходи MLP P_t^i далі використовуються для визначення відносин між акціями для кожного торгового дня t у вигляді часових графів, які представлені матрицями відносин:

$$A_t^i = \mathcal{F}_t(P_t^i), \quad (2)$$

де $\mathcal{F}_t$ – функція формування матриць відносин.

Таким чином, часові графи для кожного торгового дня представлені набором взаємопов'язаних вузлів та ребер $G = \{V, E\}$ з часовими мітками, де V та E вказують на набір вузлів та ребер відповідно. Ребро $e_{ij} \in E$ графа може бути представлене впорядкованим кортежем $\{v_i, v_j\}$, який вказує на точки ребер від вузла v_i до вузла v_j . Графи взаємозв'язків компаній розглядаються як набори часових графів, що автоматично генеруються на основі історичних цінових послідовностей, i в яких вузли $V = \{V_{t_1}, V_{t_2}, \dots, V_{t_T}\}$ позначають компанії, а ребра $E = \{E_{t_1}, E_{t_2}, \dots, E_{t_T}\}$ представляють їхні зв'язки. Кожен вузол V_{t_i} у різні торгові дні t_i може бути пов'язаний зв'язками з кількома ребрами E_{t_i} з часовими мітками. У цьому випадку характеристики вузлів V_{t_i} та ребер E_{t_i} у різні торгові дні t_i можуть бути різними.

Як зазначалося, зв'язки між змінними графа не лише змінюються з часом, але й змінюються в різних часових масштабах, що ускладнює опис таких кореляцій за допомогою фіксованої матриці зв'язків. Крім того, моделі розвитку структури графа також неоднакові в різних часових масштабах. Таким чином, існують проблеми, які необхідно вирішити:

1. Структура графа взаємозв'язків змінюється з часом. Більшість існуючих робіт використовують фіксовану та статичну матрицю суміжності від початку до кінця, яка, очевидно, не може впоратися з такою умовою.

2. Структура графа взаємозв'язків змінюється залежно від різних шкал спостереження. Кореляція між змінними в короткостроковій перспективі може відрізнятися від довгострокової. Наприклад, у короткостроковій перспективі дві акції можуть одночасно зростати та падати, коли змінюється фінансова політика, але в довгостроковій перспективі вони можуть розходитися, якщо одна компанія процвітає, а інша збанкрутує. Використання фіксованої матриці взаємозв'язків також не впорається з цією умовою.

Для визначення зв'язків між змінними за певні часові інтервали згенеруємо структуру графа з еволюційними зв'язками. Завдання визначення зв'язків між акціями компаній можна вважати завданням кластеризації, яке забезпечує своєчасний та адекватний спосіб отримання кореляцій між акціями для кожного торгового дня. Сьогодні широке поширення набули методи кластеризації, що використовують біологічні принципи організації обчислень, зокрема, штучні імунні системи.

Для вирішення проблеми кластеризації акцій пропонується використовувати модель дендритної штучної імунної мережі (DaiNet) [13], яка дозволяє сформувати К-зв'язний граф. Вершини графа – це антитіла, що описують характеристики цін на акції компаній, а ребра – спорідненість, що визначає ступінь зв'язності між ними. Формування DaiNet – це багатоетапний процес оптимізації, спрямований на зменшення кількості зв'язків між антитілами та використання для цього значень спорідненості та авідності [13]. DaiNet дозволяє автоматизувати та спростити процес формування графа зв'язків між акціями компаній. Результатом кластеризації буде мережа антитіл з певними кластерами, які для торгового дня t представлені еволюціонуючим графом навчання, що описується матрицею зв'язків $A^{(t)}$. Параметри матриці зв'язків $A^{(t)}$ для торгового дня $(t + 1)$ залежать від змін торгових характеристик акцій $X^{(t)}$ та параметрів матриці $A^{(t)}$ для торгового дня t :

$$A^{(t+1)} = Q(A^{(t)}, X^{(t)}), \quad (3)$$

де Q – функція, що визначає еволюцію GNN.

Слід зазначити, що кореляції між багатовимірними часовими рядами в практичних задачах змінюються з часом, отже, характеристики вузлів та дуг графа відносин акцій компаній також підлягають змінам при переході від одного торгового дня до іншого. Тому, щоб GNN мала еволюційні властивості, що враховують зміну кореляцій як у межах, так і між часовими рядами акцій компаній, необхідно генерувати відповідні матриці співвідношень $A^{(t)}$ для послідовності торгових днів, що підвищить точність прогнозування.

З кожного згенерованого кластера графа взаємозв'язків G вибираються центри кластерів та їхні сусідні вузли, а інформація про рух ціни кодується у часові представлення за допомогою конвертера-кодера. Вхідна характеристика руху цінових послідовностей акцій у торговий день t визначається як $X = (X^{(1)}, X^{(2)}, \dots, X^{(t)}, \dots, X^{(T)})$, $X \in R^{N \times T \times n}$, де N – кількість акцій, n – розмірність акцій, T – кількість торгових днів. Щоб отримати вхідний тензор $H^{(t)} \in R^{N \times T \times n}$ акцій, використовується лінійне перетворення для торгових характеристик

$$H_i^{(t)} = F_i X^{(t)} + a_i, \quad (4)$$

де $F_i \in R^{N \times n}$ та $a_i \in R^N$ – параметри навчання. Таким чином, для кодування цінової інформації вибираються центри кластерів та сусідні з ними вузли.

Враховуючи вихідні послідовності вузлів кодера $V_i^{(t)}$ та часовий граф відносин $G^{(t)} = \{V^{(t)}, E^{(t)}\}$ для кожного торгового дня t , для агрегації повідомлень на послідовних входах був використаний механізм уваги до графів. Для агрегації повідомлень зі структур графів відносин та вхідних часових послідовностей виконується згладжування вбудованих вузлів та використовується двоетапний механізм часової уваги. Двоетапні шари часової уваги обчислюють важливість сусідів, агрегують повідомлення відповідно до їх важливості та одночасно агрегують повідомлення з усіх кластерів графів відносин. Агрегація повідомлень реалізується наступним чином:

$$S_r^{(t)} = AL_r \cdot P_{0,r}, \quad (5)$$

де $S_r^{(t)} \in R^{n \times N}$ – вихід шару уваги часового графіка у торговий день t , $P_{0,r}$ – вихідна матриця проекції, AL_r – вершина шару уваги часового графа, яка описується наступним чином:

$$AL_r = \sum_j \sigma \cdot \left(\sum_i (p_{i,j} \cdot h_i) \right), \quad (6)$$

де σ – сигмоїдна функція активації, h_i – i -й рядок вбудовування ціни, $p_{i,j}$ – важливість часової межі (i, j) в i -й вершині графа, яка визначається за допомогою функції активації ReLU. Таким чином, використання шару уваги графа дозволяє адаптивне обчислення важливості сусідів у графі зв'язків та агрегування інформації відповідно до їхньої важливості.

Останній шар GNN, використовуючи багатошарове сприйняття з функцією активації виходу SoftMax, виконує ймовірнісний прогноз майбутнього руху ціни кожної акції. Використання перехресної ентропії як функції втрат у цій задачі дозволяє моделі оптимізувати свої ваги таким чином, щоб максимізувати прогнозовані ймовірності фактичних позначок результуючих класів. Це забезпечує більш точне та надійне прогнозування цін на акції на фінансовому ринку за допомогою глибокого навчання та GNN. Вузли в повністю зв'язаному шарі з'єднані з усіма вузлами попереднього шару, що дозволяє ефективно комбінувати та класифікувати ознаки, витягнуті з попередніх етапів обробки, та спростити процес прогнозування.

Експериментальні дослідження

Експериментальні дослідження проводилися з акціями 16 відомих технологічних компаній: Apple (AAPL), Amazon (AMZN), Cisco (CSCO), Electronic Arts (EA), eBay (EBAY), Meta (META), Google (GOOG), IBM (IBM), Intel (INTC), Microsoft (MSFT), Netflix (NFLX), NVIDIA (NVDA), Oracle (ORCL), Qualcomm (QCOM), Tesla (TSLA) і Adobe (ADBE). Були отримані історичні дані про акції, включаючи щоденні ціни закриття, обсяги торгів та вибрані технічні індикатори, що охоплюють T торгових днів. На рисунку 2 показані графіки змін середньомісячних цін на акції 16 ІТ-компаній в період з січня 2023 року по березень 2025 року.




Рис. 2. Зміни середньомісячних цін на акції ІТ-компаній

Експериментальні дані про щодобові ціни на акції були поділені на три інтервали:

- 1) навчальна вибірка (1 січня 2022 р. – 1 липня 2024 р.);
- 2) перевірна вибірка (1 липня 2024 р. – 1 січня 2025 р.);
- 3) тестовий набір (з 1 січня 2025 р. по 1 квітня 2025 р.).

Дані були попередньо оброблені наступним чином:

1. Нормалізація. Усі ознаки були нормалізовані за допомогою нормалізації z-оцінки для забезпечення порівняльного масштабу.

2. Генерація ковзного вікна. Для вхідного часового ряду було сформовано ковзне вікно тривалістю 20 торгових днів, що забезпечує кожну вибірку достатнім історичним контекстом для побудови часового графа.

3. Інженерія ознак: Окрім необроблених цінових даних, були обчислені та включені до набору ознак технічні індикатори, наприклад, ковзні середні.

Ці кроки дають змогу отримати багатовимірний набір даних часових рядів, який слугує основою для побудови часових графів.

Під час навчання нейронних мереж кількість ітерацій моделі було встановлено рівним 500. В якості характеристик акцій було взято шість типів денних торгових даних: ціна відкриття, ціна закриття, висока ціна, низька ціна, обсяг і швидкість обороту, оскільки вони типові, поширені та легко доступні.

Для визначення взаємозв'язків між акціями застосовано імунну модель DaiNet. Це дозволило отримати інформацію про акції технологічних компаній у вигляді графа (рисунок 3), вершини якого відображають характеристики часових рядів про акції, а дуги – відносини між ними.

Отриманий після кластеризації граф взаємозв'язків між акціями технологічних компаній вказав на створення трьох кластерів.

До першого кластеру ввійшли наступні компанії: Adobe, Amazon, EA, eBay, Intel, Meta, Netflix, центром кластера є компанія Meta. Компанії в цьому кластері мають високу позитивну кореляцію одна з одною, що вказує на те, що ціни на їхні акції мають тенденцію рухатися разом. Ці компанії можуть належати до технологічних або пов'язаних із технікою секторів, оскільки вони мають подібну ринкову динаміку та на них можуть впливати загальні галузеві тенденції.

До другого кластеру ввійшли наступні компанії: Apple, Cisco, Google, Microsoft, Nvidia, Oracle, Qualcomm, Tesla, центром кластера є компанія Microsoft. Цей кластер складається з компаній, які мають позитивні кореляції одна з одною, але не такі сильні, як компанії в кластері 1. Ці компанії можуть належати до різних секторів, але мають спільні ринкові тенденції або мають взаємопов'язану динаміку бізнесу.




Рис. 3. Граф кластеризації технологічних компаній

До третього кластеру ввійшла компанія IBM, яка є єдиною компанією в цьому кластері, що вказує на те, що її взаємозв'язок з курсами акцій інших компаній у наборі даних відносно низький. Це може бути унікальним у своїй поведінці на ринку порівняно з іншими компаніями.

Для кожного торгового дня будується граф, в якому кожен вузол представляє окрему акцію, а межі встановлюються шляхом обчислення спорідненості між історичними рухами цін на акції (у ковзному вікні). До значень спорідненості застосовується поріг для створення матриці відносин. Цей процес фіксує взаємозалежності між акціями, що призводить до створення часового графа, який розвивається залежно від ринкових умов і гарантує побудову графа, що відображає зміну взаємозв'язків між акціями щодня.

Щоб створити граф відносин та виділити значущі підструктури, застосовується алгоритм DaiNet до кожного щоденного графа [13]:

1. Обчислення спорідненості. Для кожної пари вузлів спорідненість обчислюється як Манхеттенська відстань між їхніми векторами ознак. Поріг спорідненості NAT визначається як середня спорідненість для всіх пар вузлів.
2. Обрізання ребер. Ребра зі значеннями спорідненості нижче NAT обрізаються з графа. Це зменшує шум і підкреслює більш значущі зв'язки.
3. Визначення рівнів стимуляції та ідентифікація центрів кластерів. Для кожного вузла рівень стимуляції обчислюється на основі його спорідненостей. Вузли, що мають високі рівні стимуляції, позначаються як центри кластерів.
4. Призначення до кластерів на основі авідності: Решта вузлів призначаються до кластерів шляхом оцінки їхньої авідності – кількісного визначення сили зв'язку з кожним ідентифікованим центром.

Цей ітеративний процес призводить до розвитку кластерів, які динамічно відображають основні міжгрупові зв'язки. Кластеризація на основі DaiNet ефективно перетворює динамічний граф на набір когерентних підграфів, кожен з яких представляє кластер тісно пов'язаних акцій.

Реалізація моделі прогнозування була здійснена за допомогою Python. Ключові бібліотеки включають: Pandas та NumPy – для маніпулювання даними та попередньої обробки; Scikit-learn – для попередніх експериментів з кластеризації та оцінки мір подібності; PyTorch Geometric – для реалізації компонентів графової нейронної мережі; NetworkX та Matplotlib – для візуалізації еволюціонуючих графових структур.

Для кожного торгового дня часовий граф був побудований та кластеризований за допомогою описаних вище кроків. Отримані кластери служили вхідними даними для кодера на основі трансформера, який фіксував часові цінові характеристики. Ці характеристики, агреговані через рівень уваги часового графа, передавались до MLP для ймовірного прогнозування.

Експерименти виконувалися протягом 50 епох та були отримані результати у вигляді двох ключових метрик: середньоквадратична помилка прогнозування (RMSE) (рисунок 4) та точність прогнозування (рисунок 5).

Видно, що прогнозоване середньоквадратичне відхилення (RMSE) моделі графа, що еволюціонує, залишається меншим, ніж у статичній моделі графа протягом усього навчання. Постійно менше середнє відхилення (RMSE) підкреслює перевагу фіксації динамічних зв'язків за допомогою структур графа, що еволюціонують.

Точність прогнозування руху показує, що обидві моделі покращуються з майже 50 % (випадкове вгадування) до значно вищого 55–65 %. Однак модель еволюціонуючого графа перевершує статичний підхід приблизно на 5–10 % у більшості епох, досягаючи піку близько 65 %. Загалом, ці результати вказують на перевагу використання динамічної кластеризації та часово-залежної графової уваги для більш точного та надійного прогнозування цін на акції.

Висновки

Використання графових нейронних мереж (GNN), в яких взаємозв'язки часових рядів представлені у вигляді графа, значно підвищує точність прогнозування. Однак в існуючих методах структура та параметри графа




Рис. 4. Прогнозоване RMSE




Рис. 5. Точність прогнозу

відносин фіксована за визначенням. У роботі для прогнозування цін акцій на фінансовому ринку використовується еволюційна GNN, в якій генерація та еволюція її структури та параметрів, представлених у вигляді кластерів, реалізується за допомогою DaiNet. Вершини графа – це антитіла, що описують характеристики цін на акції компаній, а ребра – спорідненість, що визначає ступінь зв'язності між ними. Результатом кластеризації є мережа антитіл з певними кластерами.

Для визначення цінової інформації для кожного згенерованого кластера графа взаємозв'язків ціни кодуються за допомогою трансформерів. На основі використання шару уваги часового графа інформація агрегується за важливістю сусідів. Останній шар GNN, використовуючи багатшарове сприйняття з функцією активації виходу SoftMax, дозволяє отримати ймовірнісний прогноз майбутнього руху ціни кожної акції.

Проведені експериментальні дослідження показали, що використання динамічної побудови графів та кластеризації акцій на основі DaiNet не лише відстежує часовий характер зв'язків між акціями, але й покращує ефективність прогнозування. Для покращення характеристик аналізу акцій та прогнозування фінансового ринку плануються подальші дослідження щодо побудови еволюційних неоднорідних у часі GNN.

Список використаної літератури

1. Shih S.-Y., Sun F.-K., and Lee H.-Y. Temporal pattern attention for multivariate time series forecasting. *Machine Learning* 108, 8, 2019, pp. 1421–1441. DOI: 10.48550/arXiv.1809.04206
2. Patel M., Jariwala K., and Chattopadhyay C. A Systematic Review on GNN-based Methods for Stock Market Forecasting. *ACM Computing Surveys*, Vol. 57, Iss. 2, Art. No 34, 2024, pp. 1–38. <https://doi.org/10.1145/3696411>
3. Cheng D., Yang F., Xiang S., and Liu J. Financial time series forecasting with multi-modality graph neural network. *Pattern Recognition* 121, 2022, 108218. <https://doi.org/10.1016/j.patcog.2021.108218>
4. Li W., Bao R., Harimoto K., Chen D., Xu J., and Su Q. Modeling the Stock Relation with Graph Network for Overnight Stock Movement Prediction. In *IJCAI*, 2020, pp. 4541–4547. <https://doi.org/10.24963/ijcai.2020/626>
5. Jin Z., Yang Y., & Liu Y. Stock closing price prediction based on sentiment analysis and LSTM. *Neural Computing and Applications*, 32 (13), 2020, pp. 9713–9729. <https://doi.org/10.1007/s00521-019-04504-2>

6. Liu W., Zhang Y., Wang J., He Y., Caverlee J., Chan P., Yeung D.S., and Heng P.-A. Item Relationship Graph Neural Networks for E-Commerce. *IEEE Transactions on NNLS*, 2021, pp. 1–15. DOI: 10.1109/TNNLS.2021.3060872
7. Wu Z., Pan S., Chen F., Long G., Zhang C., and Philip S.Y. A comprehensive survey on GNN. *IEEE Transactions on NNLS*, 32, 1, 2020, pp. 4–24. <https://doi.org/10.48550/arXiv.1901.00596>
8. Sawhney R., Agarwal S., Wadhwa A., and Shah R. Deep Attentive Learning for Stock Movement Prediction from Social Media Text and Company Correlations. In *Proceedings of the Conference on Empirical Methods in NLP*, 2020, pp. 8415–8426. DOI: 10.18653/v1/2020.emnlp-main.676
9. Wu Z., Pan S., Long G., Jang J., and Zhang C. Graph wavenet for deep spatial-temporal graph modeling. *arXiv preprint arXiv:1906.00121*, 2019. <https://doi.org/10.48550/arXiv.1906.00121>
10. Zhang Q., Chang J., Meng G., Xiang S., and Pan C. Spatio-temporal graph structure learning for traffic forecasting. In *Proceedings of the AAAI Conference on Artificial Intelligence*, V. 34, 2020, pp. 1177–1185. DOI: 10.1609/aaai.v34i01.5470
11. Korablyov M., Fomichov O., Antonov D., Dykyi S., Ivanisenko I., and Lutsky S. A hybrid stock analysis model for financial market forecasting. *IEEE Proceedings of the 18th Intern. Confer. on Computer Science and Information Technologies*, 2023, pp. 1–4. DOI: 10.1109/CSIT61576.2023.10324069
12. Xu M., Dai W., Liu C., Gao X., Lin W., Qi G. J., and Xiong H. Spatial-temporal transformer networks for traffic flow forecasting. *ArXiv abs/2001.02908*, 2020. <https://doi.org/10.48550/arXiv.2001.02908>
13. Korablyov M., Fomichov O., Ushakov M., and Khudolei M. Dendritic Artificial Immune Network Model for Computing. *Proceedings of the 7th International Conference on Computational Linguistics and Intelligent Systems (CoLInS 2023)*, 2023, pp. 206–217. <https://ceur-ws.org/Vol-3403/>

References

1. Shih S.-Y., Sun F.-K., and Lee H.-Y. (2019) Temporal pattern attention for multivariate time series forecasting. *Machine Learning* 108, 8, pp. 1421–1441. DOI: 10.48550/arXiv.1809.04206
2. Patel M., Jariwala K., and Chattopadhyay C. (2024) A Systematic Review on GNN-based Methods for Stock Market Forecasting. *ACM Computing Surveys*, Vol. 57, Iss. 2, Art. No 34, pp. 1–38. <https://doi.org/10.1145/3696411>
3. Cheng D., Yang F., Xiang S., and Liu J. (2022) Financial time series forecasting with multi-modality graph neural network. *Pattern Recognition* 121, 108218. <https://doi.org/10.1016/j.patcog.2021.108218>
4. Li W., Bao R., Harimoto K., Chen D., Xu J., and Su Q. (2020) Modeling the Stock Relation with Graph Network for Overnight Stock Movement Prediction. In *IJCAI*, pp. 4541–4547. <https://doi.org/10.24963/ijcai.2020/626>
5. Jin Z., Yang Y., & Liu Y. (2020) Stock closing price prediction based on sentiment analysis and LSTM. *Neural Computing and Applications*, 32 (13), pp. 9713–9729. <https://doi.org/10.1007/s00521-019-04504-2>
6. Liu W., Zhang Y., Wang J., He Y., Caverlee J., Chan P., Yeung D.S., and Heng P.-A. (2021) Item Relationship Graph Neural Networks for E-Commerce. *IEEE Transactions on NNLS*, pp. 1–15. DOI: 10.1109/TNNLS.2021.3060872
7. Wu Z., Pan S., Chen F., Long G., Zhang C., and Philip S.Y. (2020) A comprehensive survey on GNN. *IEEE Transactions on NNLS*, 32, 1, pp. 4–24. <https://doi.org/10.48550/arXiv.1901.00596>
8. Sawhney R., Agarwal S., Wadhwa A., and Shah R. (2020) Deep Attentive Learning for Stock Movement Prediction from Social Media Text and Company Correlations. In *Proceedings of the Conference on Empirical Methods in NLP*, pp. 8415–8426. DOI: 10.18653/v1/2020.emnlp-main.676
9. Wu Z., Pan S., Long G., Jang J., and Zhang C. (2019) Graph wavenet for deep spatial-temporal graph modeling. *arXiv preprint arXiv:1906.00121*. <https://doi.org/10.48550/arXiv.1906.00121>
10. Zhang Q., Chang J., Meng G., Xiang S., and Pan C. (2020) Spatio-temporal graph structure learning for traffic forecasting. In *Proceedings of the AAAI Conference on Artificial Intelligence*, V. 34, pp. 1177–1185. DOI: 10.1609/aaai.v34i01.5470
11. Korablyov M., Fomichov O., Antonov D., Dykyi S., Ivanisenko I., and Lutsky S. (2023) A hybrid stock analysis model for financial market forecasting. *IEEE Proceedings of the 18th Intern. Confer. on Computer Science and Information Technologies*, pp. 1–4. DOI: 10.1109/CSIT61576.2023.10324069
12. Xu M., Dai W., Liu C., Gao X., Lin W., Qi G. J., and Xiong H. (2020) Spatial-temporal transformer networks for traffic flow forecasting. *ArXiv abs/2001.02908*. <https://doi.org/10.48550/arXiv.2001.02908>
13. Korablyov M., Fomichov O., Ushakov M., and Khudolei M. (2023) Dendritic Artificial Immune Network Model for Computing. *Proceedings of the 7th International Conference on Computational Linguistics and Intelligent Systems (CoLInS 2023)*, pp. 206–217. <https://ceur-ws.org/Vol-3403/>