

УДК 004.89

**ПРОГНОЗУВАННЯ ФІНАНСОВОГО РИНКУ НА ОСНОВІ
МОДЕЛІ АНАЛІЗУ АКЦІЙ, ЯКА ВРАХОВУЄ ЇХ ЗВ'ЯЗКИ**

Dr.Sci. М. Корабльов ORCID: 0000-0002-8931-4350

Харківський національний університет радіоелектроніки, Україна

E-mail: mykola.korablyov@nure.ua

Д. Антонов ORCID: 0009-0000-2079-3413

Харківський національний університет радіоелектроніки, Україна

E-mail: danylo.antonov@nure.ua

О. Ткачук ORCID: 0009-0006-2943-9887

Харківський національний університет радіоелектроніки, Україна

E-mail: alexander.k.tkachuk@gmail.com

Анотація. *Здатність передбачати ціни на акції має важливе значення для обґрунтування інвестиційних рішень на фінансовому ринку. Для аналізу акцій з метою прогнозування фінансового ринку використовуються різні підходи: статистичні методи, розпізнавання образів, графіки, машинне навчання тощо. Так як акції існують на великому та взаємопов'язаному ринку, то традиційні методи, що ґрунтуються на інформації про часові ряди для окремої акції, не враховують взаємозв'язків між іншими акціями. Ефект зв'язку на фінансовому ринку, де на ціни акцій впливають ціни взаємопов'язаних акцій, вимагає використання інших підходів. Врахування взаємозв'язків між акціями може підвищити ефективність прогнозування цін на акції. Пропонується гібридна модель аналізу акцій, в якій використовується комбінація різних інтелектуальних технологій: рекурентних нейронних мереж для визначення характеристик часових рядів акцій; штучних імунних мереж для визначення взаємозв'язків між акціями; графових нейронних мереж, що дозволяють прогнозувати фінансовий ринок для прийняття більш обґрунтованих рішень з метою отримання високих прибутків за низьких ризиків. Проведено експериментальні дослідження з акціями 16 відомих технологічних компаній, які показали, що показник середньоквадратичної помилки для всіх акцій не перевищив 2%. Це вказує на достатньо високу ефективність запропонованої гібридної моделі аналізу акцій для прогнозування фінансового ринку.*

Ключові слова *акція, фінансовий ринок, прогнозування, прибуток, взаємодія, нейронна мережа, штучна імунна мережа*

1. Вступ

Фінансові ринки завжди впливали на багато сфер людської діяльності, такі як бізнес, освіта, технології та ін., що в цілому впливає на економіку. Протягом багатьох років фахівці займалися розробкою та дослідженням моделей поведінки цін на акції. Слід зазначити, що аналіз поведінки ціни акції є дуже складним процесом, оскільки рух ринку цін має динамічний, нелінійний,

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

нестационарний, непараметричний, зашумлений і хаотичний характер [1-4]. Крім того, на ринок цін на акції впливає безліч тісно взаємопов'язаних факторів, таких як економічні, політичні, психологічні, специфічні для конкретної компанії та ін.

Зі збільшенням обсягу даних використання традиційних методів аналізу фінансових ринків, заснованих на інформації про часові ряди для окремої акції, дає велику похибку прогнозу. Тому були запропоновані алгоритми інтелектуального аналізу даних для підтримки прийняття рішень інвесторами на різноманітних фінансових ринках. Аналіз фінансового ринку сьогодні побудований з використанням комбінації різних технологій [5-8], таких як машинне навчання, статистика, експертні системи та ін., які взаємодіють одна з одною для полегшення ухвалення більш обґрунтованих рішень.

У той самий час існує взаємозв'язок між змінами цін кількох пов'язаних акцій, які можуть виявлятися в одночасному зміні цін. Тому розробка моделей аналізу акцій, що використовують різні технології інтелектуального оброблення інформації та враховують взаємозв'язки між акціями, є актуальним завданням, що дозволяє підвищити точність прогнозування цін на акції.

2. Методи аналізу фінансових ринків

Для інвестування в акції з метою отримання високого прибутку за низьких ризиків інвестори використовують два основних підходи до прийняття рішень на фінансових ринках [9] – технічний та фундаментальний аналізи.

Технічний аналіз (ТА) – це комплекс методів оцінки та прогнозування ситуації на фінансових ринках. Методи ТА є ключовим інструментом для аналізу ринку, допомагаючи зрозуміти, коли та які акції варто купувати чи продавати. ТА на основі статистичних закономірностей у динаміці цін допомагає приймати виважені торговельні та інвестиційні рішення. Виявлені закономірності використовуються як індикатори для прогнозування. ТА спирається на вивчення цінових рухів, виявлення повторюваних моделей та визначення моделей, які дозволяють передбачати зміни цін у найближчому майбутньому.

Біржові аналітики використовують різні індикатори ТА, які допомагають аналізувати ринок. Власне, це є математичні функції, що засновані на динаміці ціни, обсязі торгів та інших статистичних даних, і навіть на кореляціях між ними. Вони допомагають формувати торгові сигнали, тобто, підказки трейдерам продавати чи купувати, які акції та у якій кількості, які торгові пари використовувати та ін.

Проте використання лише ТА не завжди давало бажаний результат. Тому купівля чи продаж акцій має ґрунтуватися на використанні додаткових факторів, таких як фундаментальний аналіз (ФА) [1]. Для ФА існують різні підходи до оцінки, такі як метод апроксимації середнього зростання та метод апроксимації постійного зростання.

Останні досягнення в галузі аналізу акцій та прогнозування фінансових ринків відносяться до чотирьох категорій [10-12]: статистика, розпізнавання

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

образів, машинне навчання (МО) та аналіз настроїв. Ці категорії переважно підпадають під ширшу категорію ТА, проте є деякі методи машинного навчання, які також поєднують ширші категорії ТА з підходами ФА для прогнозування фінансових ринків [13-15]. Розпізнавання образів є складовою машинного навчання, але стосовно біржового аналізу ці два методи застосовуються зовсім по-різному. Розпізнавання образів фокусується на виявленні закономірностей та тенденцій у даних. Паттерни на фондових ринках – це послідовності, що повторюються і зустрічаються на графіках, які трейдери використовували як сигнали на купівлю і продаж.

Технічний аналіз спирається на закономірності, виявлені безпосередньо у біржових даних. Він включає візуальний аналіз графіків, побудованих з плином часу, щоб показати зміни ціни, обсягу або інших похідних показників, таких як імпульс ціни тощо. Машинне навчання широко вивчалось щодо його використання у прогнозуванні фінансових ринків [6-8]. Для прогнозування цін на акції використовувалися такі прості методи як дерева рішень, дискримінантний аналіз та наївний байєсівський аналіз.

Потім були використані ефективніші методи, такі як випадковий ліс, логістична регресія та нейронні мережі. Використання глибоких нейронних мереж стало основним інструментом аналізу фінансового ринку завдяки своїм нелінійним, керованим даними та легко узагальнюваним характеристикам.

Водночас підвищення якості аналізу та точності прогнозування фінансового ринку можна отримати шляхом використання гібридного підходу, який реалізує комбінацію кількох різних методів. Гібридний підхід використовує комбінацію кількох різних підходів підвищення продуктивності, наприклад, гібрид статистичних підходів і підходів до розпізнавання образів, чи гібрид статистичних підходів і підходів машинного навчання. Слід зазначити, що традиційні методи, що базуються на інформації про часові ряди окремих акцій, не враховують взаємозв'язки між іншими акціями. На фінансовому ринку існує кореляційний зв'язок між акціями, який необхідно враховувати під час аналізу та прогнозуванні [10].

В даний час інформація про взаємозв'язок акцій в основному виходить із використанням даних галузевої класифікації, але ці дані часто є приблизними. Тому мета даного дослідження полягає в тому, щоб побудувати модель аналізу акцій для прогнозування фінансового ринку, яка б інтегрувала інформацію про зміну цін акцій у часі та взаємозв'язки між ними з використанням різних технологій інтелектуальної обробки інформації.

3. Модель аналізу акцій з урахуванням їх взаємозв'язків

3.1. Структура моделі аналізу акцій

Побудуємо модель аналізу акцій, яка об'єднує інформацію про час та взаємозв'язки. Для отримання характеристик часового ряду кожної акції доцільно використовувати рекурентну нейронну мережу (RNN). Для отримання відповідних взаємозв'язків між акціями у вигляді графа відносин

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

необхідно виконати кластеризацію акцій із використанням однієї з моделей, наприклад, штучну імунну мережу (aiNET). Для інтеграції інформації про часові ряди, отриманої з використанням RNN, з інформацією про взаємозв'язки між акціями, отриманої з використанням моделі кластеризації у вигляді графа, використовуємо графову нейронну мережу (GNN). Це дозволить більш обґрунтовано прогнозувати ціни на акції. Структура гібридної моделі аналізу акцій для прогнозування фінансового ринку наведена на рис. 1.

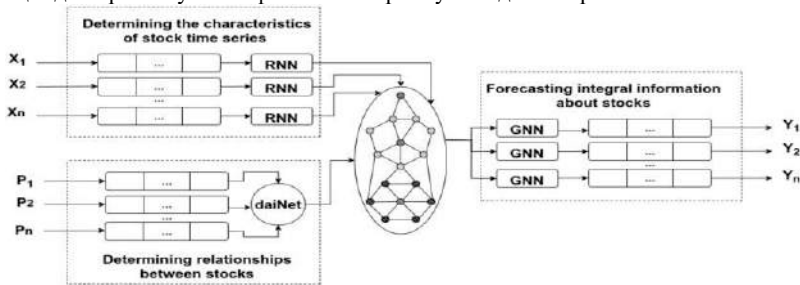


Рисунок 1. Структура гібридної моделі аналізу акцій

На входи RNN подаються часові ряди торгових характеристик акцій $X_i = (X_1^i, X_2^i, \dots, X_t^i, \dots, X_T^i)$, $i = \overline{1, N}$, де $X_t^i = (x_1, x_2, \dots, x_n)$, n – розмірність акції, N – число акцій, t – торговий день, T – довжина часового ряду. RNN дозволяє отримати характеристики часових рядів зміни цін на акції $P_i = (p_1^i, p_2^i, \dots, p_t^i, \dots, p_T^i)$, що подаються на вхід моделі кластеризації, за допомогою якої можна отримати інформацію про взаємозв'язки між акціями у вигляді графа. Отриманий граф відносин та характеристики часових рядів акцій, які використовуються як параметри вузлів графа, подаються на вхід GNN для прогнозування цін на акції. На виході GNN отримуємо оцінки дохідності акцій $Y_i = (Y_1, Y_2, \dots, Y_N)$, $i = \overline{1, N}$ на наступний період.

Таким чином, запропонована гібридна модель аналізу акцій для прогнозування фінансового ринку, яка враховує взаємозв'язки між акціями і включає в себе три модуля, кожен з яких реалізує відповідну модель інтелектуальної обробки інформації: рекурентну нейронну мережу (RNN), штучну імунну мережу (aiNET) та графову нейронну мережу (GNN).

3.2. Визначення характеристик часових рядів акцій

Для аналізу акцій та прогнозування фінансових ринків широко використовується статистичний підхід [12]. Часові ряди в аналізі фінансових ринків є хронологічним набором спостережень, таких як щоденні підсумки продажу та ціни акцій. Проте статистичні методи, які дозволяють аналізувати та прогнозувати акції, передбачають лінійність, стаціонарність та нормальність, що суттєво обмежує їх можливості. Тому сучасні методи

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

інтелектуального аналізу даних, представлені машинним навчанням, є ефективнішим засобом для аналізу акцій та прогнозування фінансових ринків.

Для отримання часової інформації про акції доцільно використовувати рекурентні нейронні мережі (RNN) (рис. 2) [16]. RNN – це модель глибокого навчання, яка навчена обробляти та перетворювати послідовний набір вхідних даних у послідовний набір вихідних даних. Тобто, RNN представляє собою архітектуру, яка здатна працювати з послідовними даними. Вона використовує механізм повторного входу, що дозволяє враховувати попередні стани та використовувати їх при обробці вхідних даних [16]. RNN називається рекурентною, тому що вона виконує одну і ту ж задачу для кожного елемента послідовності, причому вихід залежить від попередніх обчислень. Крім того, RNN – це мережа, яка має «пам'ять», що враховує попередню інформацію. Теоретично RNN може використовувати інформацію у довільно довгих послідовностях, але на практиці вона обмежена лише кількома кроками.




Рисунок 2. Рекурентна нейронна мережа та її розгортання

На відміну від традиційної глибокої нейронної мережі, яка використовує різні параметри в кожному шарі, RNN має однакові параметри (U , V , W) на всіх етапах. Це означає те, що виконується одне й те завдання на кожному кроці, використовуючи лише різні входи.

Це значно зменшує кількість параметрів, які потрібно підібрати. Основною особливістю RNN є прихований стан, який містить деяку інформацію про послідовність. Хоча RNN повинна працювати з усією послідовністю, на жаль, є проблема "загасаючого градієнта" (vanishing gradient problem). Це означає, що старші входи не впливають на вихід.

Різновидом RNN є довга короткострокова пам'ять (Long Short-Term Memory – LSTM) [17, 18]. Модель LSTM вирішує проблему "загасаючого градієнта", додаючи додаткові параметри (separate memory). LSTM принципово не відрізняється від RNN, але вона використовує функцію для обчислення прихованого стану (рис. 3).

LSTM є розширенням RNN, спроектованим для подолання проблем втрати та зсуву градієнтів. Для вирішення проблем зникнення та вибуху градієнта під час навчання довгих послідовностей у LSTM використовується кілька шарів нейронної мережі в одному рекурентному блоці. Вона використовує спеціальні блоки пам'яті, які дозволяють зберігати та оновлювати інформацію на тривалій термін. Пам'ять в LSTM є осередками, які можна розглядати як чорні

скриньки, що приймають попередній стан h_{t-1} як вхідні дані і поточний вхідний параметр x_t .




Рисунок 3. Довга короткострокова пам'ять (LSTM) та її комірка

Усередині ці осередки вирішують, яку пам'ять зберегти і яку стерти. Потім вони поєднують попередній стан, поточну пам'ять та вхідний параметр. Виявляється, ці типи одиниць дуже ефективні у захопленні (зберіганні) довгострокових залежностей.

Модель LSTM описується наступними рівняннями [18]:

$$\begin{aligned} f_t &= \sigma(W_f[h_{t-1}, x_t] + b_f), \quad i_t = \sigma(W_i[h_{t-1}, x_t] + b_i), \\ \tilde{C}_t &= \tanh(W_C[h_{t-1}, x_t] + b_C), \quad C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \\ y_t &= \sigma(W_y[h_{t-1}, x_t] + b_y), \quad h_t = y_t * \tanh(C_t). \end{aligned} \quad (1)$$

де x_t – вхідний вектор; h_t – вихідний вектор; C_t – вектор станів; W_f, W_i, W_C, W_y – матриці параметрів; b_f, b_i, b_C, b_y – вектори параметрів; f_t, i_t – вектори вентилів, σ – сигмоподібна функція активації; \tanh – функція активації “гіперболічний тангенс”.

Таким чином, використання довготривалої короткочасної пам'яті (LSTM) дозволяє ефективно отримувати інформацію про часові ряди акцій та прогнозувати ціни на них.

3.3. Визначення взаємозв'язків між акціями

Задача визначення зв'язків між акціями вважається задачею кластеризації, що забезпечує отримання кореляцій між акціями. Для цих цілей може бути використаний один із методів кластеризації. Широке поширення інформаційних технологій призвело до створення великої кількості методів кластеризації, які широко використовуються в машинному навчанні, інтелектуальному аналізі даних, аналізі бізнес-процесів, розпізнаванні образів, завданнях із звуковими даними тощо. Ієрархічні методи, дерева рішень, метод С-середніх і метод опорних векторних машин сьогодні широко використовуються для вирішення практичних задач кластеризації [19]. Однак ці методи мають свої особливості, які ускладнюють їх застосування для

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

вирішення практичних завдань. Тому широкого поширення набули методи, що використовують біологічні принципи організації обчислювальної техніки, серед яких можна виділити штучні імунні системи [20].

Для вирішення завдання кластеризації акцій на основі імунного підходу доцільно використовувати модель штучної імунної мережі (aiNet). Це пояснюється тим, що модель aiNet передбачає аналіз не лише взаємодії типу антитіло-антиген, але й взаємодії типу антитіло-антитіло. Пропонується використовувати модель деревоподібної штучної імунної мережі (daiNet), запропонованої в [21], яка дозволяє формувати K -зв'язний граф. Вершинами графа є антитіла, що описують показники цін на акції $P_i = (p_1^i, p_2^i, \dots, p_T^i)$, $i = \overline{1, N}$, а ребрами – значення афінностей, що визначають ступінь зв'язності між ними.

Формування деревоподібної структури імунної мережі є багатоетапним оптимізаційним процесом, орієнтованим на скорочення кількості зв'язків між антитілами, використовуючи для цього значення афінностей та авідностей між антитілами. Результатом кластеризації буде мережа антитіл із визначеними кластерами.

На першому кроці мережа антитіл формується у вигляді графа (рис. 4) [22], де кожна вершина з'єднана з усіма іншими вершинами цього графа.




Рисунок 4. Перший етап формування деревовидної імунної мережі

Процес формування мережі антитіл – це процес оптимізації повнозв'язного графа, вершинами якого є антитіла, а ребрами – спорідненості між ними. Оптимізація означає зменшення кількості зв'язків між антитілами. Поріг природної спорідненості (NAT), який є спорідненістю між усіма антитілами в популяції, використовується як критерій, що регулює кількість афінних зв'язків між антитілами [23]:

$$NAT(AB) = \frac{\sum_{i=1}^n \sum_{j=1}^{n-1} aff(ab_i, ab_j)}{n(n-1)}, \quad (2)$$

де n – кількість антитіл у популяції; $aff(ab_i, ab_j)$ – значення афінності між i -м та j -м антитілами:

$$aff_{ij} = (1 + d_{ij})^{-1}, \quad (3)$$

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

де d_{ij} – евклідова або манхеттенська відстань між ознаками i -го та j -го імунних об'єктів.

Відповідно до цього зв'язки між антитілами видаляються, якщо їх афінності не перевищують значення NAT . При зменшенні кількості зв'язків між антитілами мережі daiNet передбачається використання деякого вхідного параметру K , який обмежує кількість зв'язків між антитілами мережі. Тобто, кожне антитіло може створювати не більше ніж K зв'язків з іншими антитілами мережі. Інші зв'язки, які створює це антитіло, видаляються. Ця ідея запозичена з алгоритму класифікації K найближчих сусідів (kNN) [19].

На другому етапі після формування K -пов'язаної мережі антитіл відбувається обчислення рівня стимуляції s_i кожного антитіла на основі його афінності з іншими імунними об'єктами, що формують мережу:

$$s_i = \frac{1}{K} \sum_{j=1}^K aff(ab_i, ab_j). \quad (4)$$

На основі значення рівня стимуляції $s_i, i = \overline{1, n}$ кожного антитіла відбувається визначення кандидатів в центри кластерів.

На третьому етапі формування мережі daiNet формується множина антитіл, які характеризуються високими рівнями стимуляції та кількістю зв'язків, що перевищують зазначений раніше параметр K . Під час вибору центрів кластерів з усіх антитіл-кандидатів у центри обирається антитіло, яке характеризується максимальною кількістю зв'язків з іншими антитілами мережі та максимальним рівнем стимуляції. Таке антитіло буде обрано у якості центра першого кластера. Центри інших кластерів визначаються відносно обраного центру першого кластера.

На четвертому етапі після розподілу центрів кластерів відбувається процес визначення приналежності до них антитіл імунної мережі. Спочатку кластеризуються імунні об'єкти, які характеризуються міцним афінним зв'язком з антитілами, які є центрами кластерів, тобто об'єкти, які мають прямі зв'язки з кластерами в daiNet з K зв'язками. Для проведення кластеризації інших антитіл, які не характеризуються міцним по афінності зв'язком з жодним із центрів сформованих кластерів, відбувається визначення авідностей до кожного з кластерів та його антитіл, що формують центр сильного згущення. Визначення авідності базується на спорідненості та афінності між імунними об'єктами. У цьому випадку авідність антитіла з іншими антитілами, що належать до одного кластера, визначається як сума афінностей між ними:

$$av_i = \sum_{j=1}^m aff(ab_i, ab_j), \quad (5)$$

де av_i – значення авідності i -го антитіла з іншими антитілами кластера; m – кількість антитіл у кластері; $aff(ab_i, ab_j)$ – значення афінності між антитілами одного кластера згідно з (3).

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

Визначена таким чином авідність відображає рівень міцності імунного зв'язку між об'єктами кластеру та цим антитілом. Поняття авідності між антитілами та антигенами, або між антитілами імунної мережі часто використовується в моделях штучних імунних мереж, які використовуються для вирішення задач класифікації, кластеризації та аналізу даних.

На п'ятому етапі відбувається кластеризація інших об'єктів за величиною авідності i -го антитіла до інших антитіл кластера шляхом запуску імунних процесів в деревовидній імунній мережі антитіл з використанням операторів клонування, мутації, супресії клонів та мережі антитіл, що не належать до жодного кластеру. При цьому для кожного клону після його мутації відбувається визначення авідностей з цільовими об'єктами, якими є антитіла, що кластеризовані, і які формують кластери з центром сильного згущення.

Під час відбору для кожного клонованого антитіла зі всієї множини його клонів обирається один об'єкт, що характеризується максимальною авідністю з антитілами, що формують центр кластеру сильного згущення. Цей клон замінює собою антитіло, від якого він був створений під час роботи оператора супресії популяції антитіл з невизначеною приналежністю до кластеру. Слід зазначити, що імунний процес клонування, мутації, супресії клонів та супресії антитіл деревовидної імунної мережі завершиться у випадку, коли у мережі не залишиться жодного антитіла, що має авідність до одного з центрів кластеру, яка буде меншою за авідність у кластерах з центрами сильного згущення. Результатом кластеризації деревовидної штучної імунної мережі буде мережа антитіл з визначеними кластерами.

Приклад кластеризації штучної імунної деревовидної мережі антитіл, розподілених між двома визначеними кластерами, наведено на рис. 5. Внаслідок роботи моделі daiNet відбувається кластеризація початкової популяції антитіл. При цьому об'єкти належать до одного з виділених кластерів у процесі імунної взаємодії деревовидної К-зв'язної мережі антитіл. Проведення етапу визначення авідностей дозволяє провести кластеризацію антитіл до кластерів сильного згущення.




Рисунок 5. Приклад кластеризації антитіл, розподілених між двома кластерами

Процес кластеризації набору вхідних об'єктів на основі імунної моделі daiNET можна представити як послідовність виконання наступних етапів:

- 1) встановлення параметрів кластеризації та отримання початкового набору об'єктів;
- 2) визначення шкал ознак досліджуваних об'єктів;

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

- 3) формування K -зв'язної деревовидної імунної мережі;
- 4) виділення центрів кластерів;
- 5) визначення авідностей кластерів;
- 6) імунна саморегуляція мережі;
- 7) висновок про кластеризацію об'єктів.

Відповідно до цього, на рівні імунних операторів модель daiNet представляється виконанням відповідних етапів, поданих виразом (6):

У виразі (6) $Dendric-aiNet(AB, K, C)$ є умовним позначенням методу кластеризації вхідних об'єктів AB при використанні деревоподібної K -зв'язної імунної мережі антитіл та критерію C , що використовується для вказівки кількості кластерів, що формуються методом набору об'єктів.

Етап підготовки до кластеризації позначається скороченням PRP і містить кілька операторів: оператор $Scaling(AB)$ – використовується для проведення шкалювання об'єктів; оператор $Presentation(AB)$ – використовується для визначення афінностей між антитілами формованої імунної мережі; оператор $NATCalculation(AB)$ – використовується для визначення порогової афінності NAT в популяції антитіл.

Етап роботи, спрямований на формування K -зв'язної імунної мережі, має умовне позначення DKN і містить такі оператори: оператор $DKnetCreation(AB, K)$ – застосовується для формування K -зв'язної деревовидної мережі антитіл; оператор $CalcStimulation(AB)$ – застосовується для визначення рівня стимуляції антитіл; оператор $CentersSelection(AB, c, NAT)$ – використовується для виділення центрів кластерів; оператор $DendricClustering(AB')$ – використовується для формування кластерів сильного згущення.

$$Dendric - aiNet(AB, K, c) = \overset{PRP}{\left[\begin{array}{l} Scaling(AB) \rightarrow \\ Presentation(AB) \rightarrow \\ NATCalculation(AB) \end{array} \right]} \Rightarrow$$

$$\Rightarrow \overset{DKN}{\left[\begin{array}{l} DKnetCreation(AB, K) \rightarrow \\ CalcStimulation(AB) \rightarrow \\ CentersSelection(AB, c, NAT) \rightarrow \\ DendricClustering(AB') \end{array} \right]} \Rightarrow \quad (6)$$

$$\Rightarrow \overset{NET}{\left[\begin{array}{l} Cloning(AB'', CL) \rightarrow \\ Mutation(CL) \rightarrow \\ Presentation(CL, AB', AB'') \rightarrow \\ CLSupression(CL, AB', AB'') \rightarrow \\ NetSupression(CL, AB'') \rightarrow \\ AvCalculation(AB'') \rightarrow \\ ClusterSelection(AB'') \end{array} \right]},$$

Етап мережевої взаємодії має позначення NET і містить наступні оператори: оператор клонування $Cloning(AB'', CL)$ – що використовується

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

для поширення популяції антитіл, не пов'язаних з жодним із сформованих кластерів; оператор мутації $Mutation(CL)$ – використовується для зміни ознак клонів; оператор подання цільових об'єктів $Presentation(CL, AB', AB'')$ – використовується для визначення афінностей між клонами та об'єктами, що формують кластери сильного згущення; оператор супресії клонів $CLSupression(CL, AB', AB'')$ – використовується для редагування популяції клонів; оператор супресії мережі антитіл $NetSupression(CL, AB'')$ – використовується задля скорочення кількості об'єктів; оператор визначення авідностей між антитілами та кластерами сильного згущення $AvCalculation(AB'')$ – використовується для розподілу не кластеризованих об'єктів між кластерами, що формуються; оператор $ClusterSelection(AB'')$, який використовується задля визначення належності антитіл кластерам.

Таким чином, використання теорії графів для створення дендритної моделі імунної мережі daiNet дозволяє вирішити проблему підвищення продуктивності та зменшення складності формування мережі антитіл і областей розпізнавання, тим самим спростити визначення зв'язків між акціями.

3.4. Витяг інформації про взаємозв'язки між акціями

Для оцінки впливу зв'язків між акціями та характеристиками їх часових рядів на прогнозування курсу акцій використаємо графову нейронну мережу (GNN) [24, 25]. На входи GNN подається граф, вузли якого відображають ознаки часових рядів акцій, а дуги показують зв'язок між ними.

GNN є багаторівневою мережею, кожен рівень якої описується виразом [24]:

$$h_v^k = \sigma \left(W_k \sum_{u \in N(v)} \frac{h_u^{k-1}}{|N(v)|} + B_k h_v^{k-1} \right), \quad (6)$$

де σ – функція активації, W_k – вагові коефіцієнти, B_k – зсув, k – кількість шарів мережі.

Таким чином, на входи GNN надходять два типи даних: матриця суміжності, яка представляє зв'язок між акціями, і матриця особливостей часових характеристик акцій. Вихідний шар описується виразом:

$$y_v = h_v^k \quad (7)$$

і представляє прибутковість акцій на наступний період, що дозволяє прогнозувати інтегральну інформацію про акції для прийняття більш обґрунтованих рішень та підвищення стійкості фінансових ринків з метою отримання високих прибутків за низьких ризиків.

Результатом роботи GNN є доходність акцій.

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

4. 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).

Запропонована модель була реалізована за використанням Python.

За допомогою Yahoo Finance API через бібліотеку *pandas_datareader* були зібрані дані про щодобові ціни акцій за період з 1 січня 2021 р. по 1 січня 2023 р. На рис. 6 наведені графіки зміни цін на акції, де кожна точка на графіку – це середня ціна акції за місяць.

Дані про окремі акції були об'єднані в єдиний DataFrame, з якого була вилучена відповідна інформація, така як дата, ціна закриття та символ акції.

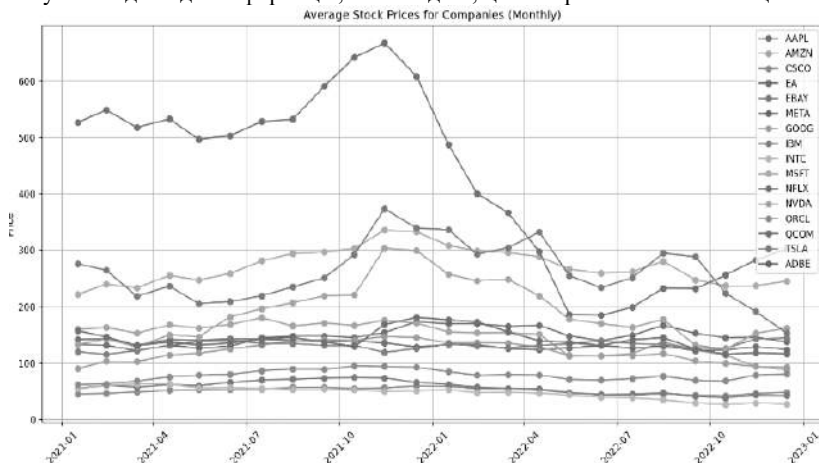


Рисунок 6. Графіки зміни цін на акції технологічних компаній

Експериментальні дані про щодобові ціни на акції за період з 1 січня 2021 р. по 1 січня 2023 р. були поділені на три інтервали:

- 1) навчальна вибірка (1 січня 2021 р. – 1 липня 2022 р.);
- 2) перевірна вибірка (1 липня 2022 р. – 1 жовтня 2022 р.);
- 3) тестовий набір (з 1 жовтня 2022 р. по 1 січня 2023 р.).

Під час навчання нейронних мереж кількість ітерацій моделі було встановлено рівним 500. В якості характеристик акцій було взято шість типів внутрішньо денних торгових даних: ціна відкриття, ціна закриття, висока ціна, низька ціна, обсяг і швидкість обороту, оскільки вони типові, поширені та легко доступні. Для оцінки якості моделі використовувалася середня квадратична помилка (MSE). Проведене моделювання показало, що цей показник для всіх акцій не перевищував 2%, що свідчить про досить високу ефективність запропонованої гібридної моделі аналізу акцій та прогнозування

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

фінансового ринку. Для отримання характеристик часових рядів про акції використовувалася рекурентна нейронна мережа LSTM, кількість шарів якої було взято рівним 2, а довжина часового ряду була встановлена рівною 30, тобто один місяць. Завдання визначення взаємозв'язків між акціями розглянуто як завдання кластеризації, для вирішення якої застосовано імунний підхід, а саме модель деревоподібної імунної мережі daiNet. Це дозволило отримати інформацію про акції технологічних компаній у вигляді графа (рис. 7), вершини якого відображають характеристики часових рядів про акції, а дуги – кореляції між акціями. Щоб дослідити кореляцію між цінами на момент закриття акцій технологічних компаній, використано DataFrame. Це дозволило впорядкувати дані за датою у вигляді рядків та кожний символ акцій у вигляді стовпців (матриця кореляції). Візуалізація теплової карти (рис. 8) створена за допомогою бібліотеки *seaborn* і *matplotlib*, що забезпечує інтуїтивно зрозуміле представлення кореляційної матриці.




Рисунок 7. Граф кластеризації технологічних компаній




Рисунок 8. Візуалізація теплової карти кореляцій акцій технологічних компаній

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

На тепловій карті більш темні відтінки зеленого вказують на позитивні взаємозв'язки, тоді як відтінки червоного вказують на негативні взаємозв'язки. Чим ближче значення до +1, тим сильніша позитивна кореляція, і навпаки, чим ближче до -1, тим сильніша негативна кореляція. Значення близько 0 вказують на слабкий взаємозв'язок або на його відсутність. За допомогою цього аналізу можна зрозуміти, як ціна акцій технологічних компаній пов'язана протягом заданого періоду часу. Виявляючи сильні позитивні чи негативні кореляції, можна отримати уявлення про потенційні моделі чи залежності між різними акціями. Це дослідження може надати цінну інформацію інвесторам, трейдерам і фінансовим аналітикам, оскільки воно може виявити, які акції мають тенденцію рухатися разом, а які демонструють контрастні рухи. Крім того, досліджуючи кореляційні тенденції, інвестори можуть потенційно оптимізувати свої стратегії диверсифікації портфеля, мінімізувати ризик і підвищити прибутки шляхом розподілу активів між позитивно зв'язаними акціями. Дослідження також може призвести до виявлення технологічних компаній, які мають більший вплив на загальний рух ринку протягом зазначеного періоду. Ці акції можуть впливати на ринкові настрої та є актуальними для аналізу та прогнозування ринкових тенденцій.

Дослідження дозволяють виявити технологічні компанії, які мають більший вплив на загальний рух ринку протягом зазначеного періоду. Крім того, розуміння взаємозв'язку між акціями в технологічному секторі може вказати на загальний стан і стабільність галузі. Наприклад, високий ступінь позитивної кореляції між технологічними акціями може свідчити про те, що галузь переживає зростання або занепад, у той час як низькі кореляції можуть вказувати на відмінності в продуктивності окремих компаній. Це може привести до використання більш складних методів моделювання та прогнозування, які включають взаємозв'язки між акціями. У результаті, наглядно видно що є досить висока позитивна кореляція в парах Microsoft & Nvidia, Microsoft & Google та ін. Як наслідок, результати цього дослідження можуть сприяти поповненню існуючого масиву знань у сферах фінансів, економіки та інвестицій. Отриманий після кластеризації граф взаємозв'язків між акціями технологічних компаній (рис 7) 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. До третього кластеру ввійшла компанія IBM, яка є єдиною компанією в цьому кластері, що вказує на те, що її

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

взаємозв'язок з курсами акцій інших компаній у наборі даних відносно низький. Вона має тільки слабкий взаємозв'язок з компаніями Oracle та Cisco з кластеру 1. Це може бути унікальним у своїй поведінці на ринку порівняно з іншими компаніями. Отриманий граф взаємозв'язків між акціями технологічних компаній, який містить три кластери, з характеристиками часових рядів акцій, що використовуються як вираз вузлів на графі, подається на дві графові нейронні мережі GNN, кожна з яких є тришаровою і створена для кластерів 1 і 2. Для кластеру 3 немає необхідності створювати мережу GNN, так як він складається тільки з однієї компанії IBM.

Таким чином, кожна GNN дозволяє отримати прогнозовані ціни акцій наступного дня, після чого можна обирати акції з найбільшою прогнозованою прибутковістю на наступний період.

5. Висновки

Аналіз поведінки цін на акції є складним процесом. На ринок цін на акції впливає багато тісно взаємопов'язаних факторів. Крім того, дані про ціни на акції мають низьке відношення сигнал/шум, що робить прогнозування цін на акції складним завданням. Фінансовий ринок сьогодні збудований з використанням комбінації різних технологій, які взаємодіють один з одним для полегшення прийняття більш обґрунтованих рішень. У той самий час існує взаємозв'язок між коливаннями цін кількох пов'язаних акцій, які можуть виявлятися у одночасному зростанні чи падінні цін. Тому актуальним є розробка моделей аналізу акцій та прогнозування фінансових ринків, що враховують взаємозв'язки між акціями, що дозволяє підвищити точність прогнозування цін на акції.

Дослідження методів аналізу акцій та прогнозування фінансових ринків дозволило вибрати гібридний підхід, який використовує різні технології інтелектуальної обробки інформації та інтегрує інформацію про зміни цін на акції у часі і взаємозв'язки між ними. Запропоновано модель аналізу акцій та прогнозування фінансових ринків, у якій:

1. Для отримання часової інформації про акції використано рекурентну нейронну мережу LSTM, яка може ефективно витягувати інформацію про часові ряди акцій та прогнозувати ціни на акції.

2. Для вирішення завдання кластеризації акцій використано модель деревовидної штучної імунної мережі daiNet, яка дозволяє формувати K -пов'язаний граф, що враховує зв'язки, відносини та характеристики часових рядів акцій.

3. Для інтеграції інформації про часові ряди, отриманої з використанням моделі LSTM, з інформацією про взаємозв'язки між акціями, отриманої за допомогою моделі daiNet у вигляді графа, використана графова нейронна мережа GNN, на входи якої надходять дані двох видів: матриця зв'язків між акціями, та матриця ознак часових характеристик акцій. Виходами GNN є прибутковість акцій.

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

Проведено експериментальні дослідження з акціями 16 відомих технологічних компаній, дані про щодобові ціни акцій яких були взяті за період з 1 січня 2021 р. по 1 січня 2023 р.

Проведене моделювання показало, що показник середньоквадратичної помилки для всіх акцій не перевищив 2%, що вказує на достатньо високу ефективність запропонованої гібридної моделі аналізу акцій для прогнозування фінансового ринку. Дослідження дозволили виявити технологічні компанії, які мають більший вплив на загальний рух ринку у вказаний період.

6. Література

- [1] R. Bhowmik, S. Wang, “Stock Market Volatility and Return Analysis: A Systematic Literature Review”, *Journals Entropy*, Vol., 22 Iss. 5, 2020, 522. doi 10.3390/e22050522.
- [2] P. Li, J. Xu, “A Study of Different Existing Methods for the Stock Selection in the Field of Quantitative Investment”, *Wireless Communications and Mobile Computing*, 2022. <https://doi.org/10.1155/2022/2695099>.
- [3] D. Shah, H. Isah, and F. Zulkernine, “Stock Market Analysis: A Review and Taxonomy of Prediction Techniques”, *Int. J. Financial Stud.*, 7(2), 2019, 26. <https://doi.org/10.3390/ijfs7020026>.
- [4] H. Liu, S. Huang, P. Wang, Z. Li, “A review of data mining methods in financial markets”, *Data Science in Finance and Economics*, Vol. 1, Iss. 4, 2021, pp. 362-392. doi 10.3934/DSFE.2021020.
- [5] K. Olorunnimbe, H. Viktor, “Deep learning in the stock market – a systematic survey of practice, backtesting, and applications”, *Artificial Intelligence Review*, Vol. 56, 2023, pp. 2057–2109. <https://doi.org/10.1007/s10462-022-10226-0>.
- [6] M. M. Kumbure, C. Lohrmann, P. Luukka, J. Porras, “Machine learning techniques and data for stock market forecasting: A literature review”, *Expert Systems With Applications*, 197, 2022, 116659.
- [7] Y. Guo, “Stock Price Prediction Using Machine Learning”, *Södertörn University / School of Social Science Master, Dissertation 30hp, Economics Spring, 2022*, 41 p.
- [8] A. Singh, P. Gupta, N. Thakur, “An Empirical Research and Comprehensive Analysis of Stock Market Prediction using Machine Learning and Deep Learning Techniques”, *IOP Conf. Series: Materials Science and Engineering*, 1022, 2021, 012098, <https://doi:10.1088/1757-899X/1022/1/012098>.
- [9] Y.J. Chen, Y.M. Chen, S.T. Tsao, et al., “A novel technical analysis-based method for stock market forecasting”, *Soft Comput* 22, 2018, pp. 1295–1312. <https://doi.org/10.1007/s00500-016-2417-2>.
- [10] C. Zhao, P. Hu, X. Liu, X. Lan, H. Zhang, “Stock Market Analysis Using Time Series Relational Models for Stock Price Prediction”, *Journals Mathematics*, 11(5), 2023, 1130. <https://doi.org/10.3390/math11051130>.
- [11] Y. Chen, J. Liu, Y. Gao, W. He, H. Li, G. Zhang, and H. Wei. “A new stock market analysis method based on evidential reasoning and hierarchical belief rule

ADVANCES IN INFORMATION-CONTROL SYSTEMS AND TECHNOLOGIES

- base to support investment decision making". *Frontiers in Psychology*. 2023; 14: 1123578. <https://doi.org/10.3389/fpsyg.2023.1123578>.
- [12] C. Xiao, W. Xia, & J. Jiang, "Stock price forecast based on a combined model of ARI-MA-LS-SVM. *Neural Computing and Applications*". Vol. 32, 2020, pp. 5379–5388. <https://doi.org/10.1007/s00521-019-04698-5>.
- [13] H. Widiputra, A. Mailangkay, E. Gautama, "Multivariate CNN-LSTM Model for Multiple Parallel Financial Time-Series Prediction". *Complexity*, 2021, 9903518. <https://doi.org/10.1155/2021/9903518>.
- [14] S. Barra; S. Mario Carta; A. Corriga; A. S. Podda, and D. R. Recupero. "Deep learning and time series-to-image encoding for financial forecasting". *IEEE/CAA Journal of Automatica Sinica*, Vol. 7, Iss, 2020, pp. 683 – 692. <https://doi.org/10.1109/JAS.2020.1003132>.
- [15] J. Wang, J. Kim. Predicting Stock Price Trend Using MACD Optimized by Historical Volatility. *Mathematical Problems in Engineering*, 2018(4), pp. 1-12. <https://doi.org/10.1155/2018/9280590>.
- [16] L. Zheng, H. He. Share price prediction of aerospace-relevant companies with recurrent neural networks based on PCA. "Expert Systems with Applications". Vol. 183, 2021, 115384. <https://doi.org/10.1016/j.eswa.2021.115384>.
- [17] S. Arifin, A. K. Wijaya, R. Nariswari, A. Yudistira, Suwarno, Faisal, D. Wihardini. "Long Short-Term Memory (LSTM): Trends and Future Research Potential". *International Journal of Emerging Technology and Advanced Engineering*, 2023. https://doi.org/10.46338/ijetae0523_04.
- [18] G.V. Houdt, C. Mosquera, G. Nápoles. "A Review on the Long Short-Term Memory Model". *Artificial Intelligence Review*, 53, 2020. <https://doi.org/10.1007/s10462-020-09838-1>.
- [19] R.O. Duda, P.E. Hart, D.G. Stork, "Pattern classification". Wiley & Sons, 2010.
- [20] H. Park, J.E. Choi, D. Kim, S.J. Hong, Artificial immune system for fault detection and classification of semiconductor equipment. *Electronics*, Vol. 10, No. 8, 944, 2021, pp. 1-14. <https://doi.org/10.3390/electronics10080944>.
- [21] M. Korablyov, O. Fomichov, M. Ushakov, M. Khudolei, "Dendritic Artificial Immune Network Model for Computing", *Proceedings of the 7th International Conference on Computational Linguistics and Intelligent Systems (CoLInS 2023)*. Volume III: Intelligent Systems Workshop, Kharkiv, Ukraine, April 20-21, 2023, pp.206-217.
- [22] R. Diestel, *Extremal Graph Theory*. In: *Graph Theory*. Graduate Texts in Mathematics, Vol 173, Springer, Berlin, Heidelberg, 2017. <https://doi.org/10.1007/978-3-662-53622-3>.
- [23] K.B. Bahekar, Classification techniques based on Artificial immune system algorithms for Heart disease using Principal Component Analysis. *International Journal of Scientific Research in Science, Engineering, and Technology, IJSRSET*, Vol. 7, Iss. 5, 2020, pp. 150-160. <https://doi.org/10.32628/IJSRSET207542>.
- [24] L. Wu, P. Cui, J. Pei, L. Zhao, "Graph Neural Networks. Foundations, Frontiers, and Applications". Springer, Singapore, 2022, 689 p.

[25] A. Keramatfar, M. Rafiee, H. Amirkhani, "Graph Neural Networks: a bibliometrics overview", ELSEVIER, Machine Learning with Applications. Vol. 10, 2022, 100401. <https://doi.org/10.48550/arXiv.2201.01188>.

**FORECASTING THE FINANCIAL MARKET BASED ON A STOCK
ANALYSIS MODEL THAT TAKES INTO ACCOUNT THEIR
RELATIONSHIPS**

Dr. Sci. M. Korablyov¹, ORCID: 0000-0002-8931-4350

D. Antonov², ORCID: 0009-0000-2079-3413

O. Tkachuk³, ORCID: 0009-0006-2943-9887

Kharkiv National University of Radio Electronics, Ukraine,

E-mail: ¹mykola.korablyov@nure.ua, ²danylo.antonov@nure.ua,

³alexander.k.tkachuk@gmail.com

***Abstract.** The ability to predict stock prices is essential for justifying investment decisions in the financial market. Various approaches are used to analyze stocks for the purpose of forecasting the financial market: statistical methods, pattern recognition, graphs, machine learning, etc. Because stocks exist in a large and interconnected market, traditional methods based on time series information for an individual stock do not take into account the relationships between other stocks. The linkage effect in the financial market, where stock prices are influenced by the prices of related stocks, requires other approaches. Taking into account the relationships between stocks can improve the effectiveness of stock price forecasting. A hybrid model of stock analysis is proposed, which uses a combination of various intelligent technologies: recurrent neural networks to determine the characteristics of time series of stocks; artificial immune networks to determine the relationships between actions; graph neural networks that allow forecasting the financial market to make more informed decisions in order to obtain high profits at low risks. Experimental studies were conducted with the shares of 16 well-known technology companies, which showed that the average squared error for all shares did not exceed 2%. This indicates the sufficiently high efficiency of the proposed hybrid model of stock analysis for forecasting the financial market.*

***Keywords** stock, financial market, forecasting, profit, interaction, neural network, artificial immune network*