

УДК 004.94

С.В. ГОЛУБ*, Д.В. ТОЛБАТОВ**

МАШИННЕ НАВЧАННЯ БАГАТОШАРОВИХ ПРОГНОЗНИХ МОДЕЛЕЙ БІРЖОВИХ ПОКАЗНИКІВ

*Черкаський державний технологічний університет, м. Черкаси, Україна

**Інститут проблем математичних машин і систем НАН України, м. Київ, Україна

Анотація. Розглядається важливість прогнозування ціни на золото за допомогою штучних інтелектуальних систем. Наводяться аргументи щодо значення точного прогнозування цінових тенденцій у галузі золота, яка є ключовою для інвесторів, фінансових установ та економічних аналітиків. Використання штучного інтелекту (ШІ) у цьому контексті може допомогти у покращенні стратегій управління ризиками та прийнятті рішень на фінансових ринках. За допомогою інтелектуального моніторингу люди отримують інформацію про властивості об'єкта чи процесу шляхом створення та використання бази модельних знань під час обробки результатів спостережень. При використанні інтелектуального моніторингу для прогнозування фінансових показників виникає потреба у синтезі прогнозуючих моделей на обмеженій вихідній інформації про історію процесу, оскільки кожна майбутня величина прогнозованого показника визначається факторами, які існували в минулому. Моделювання процесів ціноутворення біржових облігацій проходить в умовах структурної та інформаційної невизначеності. З метою зниження невизначеності процесу прогнозування біржових показників у роботі подаються результати досліджень використання нового методу машинного навчання як додаткового структурного елемента у поєднанні з уже існуючими алгоритмами синтезу моделей багатощарового агентного синтезатора предикторів. Не завжди використання нового елемента приводить до покращення характеристик системи в цілому. Перевірялась гіпотеза про покращення характеристик агентних синтезаторів моделей при використанні нового методу машинного навчання як структурного елемента шару. Для прикладу досліджено процес прогнозування цін золота на біржі. Запропоновано одночасно зі створенням нових методів машинного навчання змінювати структуру багатощарового синтезатора моделей. Досліджено, яким чином нові властивості структурного елемента одного із шарів змінюють структуру агентного синтезатора моделей в цілому. Результати досліджень доводять ефективність процесу побудови нового методу машинного навчання як структурного елемента багатощарового агентного синтезатора моделей.

Ключові слова: інтелектуальні системи, інтелектуальний моніторинг, прогнозування біржових показників, машинне навчання.

Abstract. The importance of predicting the price of gold using artificial intelligence systems is considered. Proofs concerning the importance of accurate forecasting of price trends in the gold industry, which is a key factor for investors, financial institutions, and economic analysts, are provided. Using AI in this context can help to improve risk management strategies and decision-making in financial markets. Today, people use intelligent monitoring to obtain information about the properties of an object or process by creating and using a model knowledge base while processing the results of observations. When using intelligent monitoring to forecast financial indicators, there is a need to synthesize forecasting models based on limited information about the process history. Each future value of the forecasted indicator is determined by factors that took place in the past. The modeling of exchange bond pricing processes occurs under both structural and informational uncertainty. In order to reduce the uncertainty of the process of forecasting stock indicators, the paper presents the research results using a new method of machine learning as an additional structural element in combination with already existing algorithms for synthesizing models of a multilayer agent synthesizer of predictors. The use of a new element does not always improve the characteristics of the system as a whole. The hypothesis about the improvement of the characteristics of model agent synthesizers when using a new machine learning method as a structural element of the layer was tested. For example, the process of forecasting prices of gold on the stock exchange was studied.

Simultaneously with the creation of new methods of machine learning, it is proposed to change the structure of the multilayer synthesizer of models. It was investigated how the new properties of the structural element of one of the layers change the structure of the agent synthesizer of models as a whole. The research results prove the effectiveness of the process of building a new method of machine learning as a structural element of a multi-layer agent synthesizer of models.

Keywords: intelligent systems, intelligent monitoring, stock market forecasting, machine learning.

DOI: 10.34121/1028-9763-2024-3-4-100-108

1. Вступ

На сьогоднішній день технологія моніторингу — це спостереження та обробка результатів їхнього застосування з метою отримання інформації для підтримки рішень у певній області. Якщо говорити про агента, який проводить моніторинг, то він обробляє результати спостережень для одержання інформації про властивості об'єктів, їх взаємодії, про стани та закономірності, які впливають на ці властивості. Під час обробки моніторинговий агент вирішує складні завдання. До них відносяться, наприклад, класифікація, ідентифікація, прогнозування та ін. Результати спеціально зберігають у вигляді моделей. Також результати спеціально зберігаються й використовуються в базі даних. Особливості, які мають залишитися такими, що вирішуються, визначаються функцією агента [1].

Deep Learning займається навчанням багатосарових штучних нейронних мереж, які також називаються Deep Neural Networks. Після того, як у 1950-х роках було розроблено перцептрон Розенблата, інтерес до нейронних мереж був відсутній до 1986 року, коли доктор Хінтон і його колеги розробили алгоритм зворотного поширення для навчання багатосарової нейронної мережі. Сьогодні — це гаряча тема для багатьох провідних компаній, таких як Google, Facebook і Microsoft, які інвестують значні кошти у програми, що використовують глибокі нейронні мережі [2].

Багатосарова нейронна мережа містить більше одного шару штучних нейронів або вузлів. Вони дуже відрізняються за дизайном. Важливо відзначити, що хоча односарові нейронні мережі були корисними на початку еволюції ШІ, переважна більшість мереж, які використовуються сьогодні, мають багаторівневу модель.

Багатосарові нейронні мережі можна налаштувати різними способами. Як правило, вони мають принаймні один вхідний рівень, який надсилає зважені вхідні дані до серії прихованих шарів, і вихідний рівень у кінці. Ці складніші налаштування також пов'язані з нелінійними конструкціями, що використовують сигмоїди та інші функції для керування запуском або активацією штучних нейронів. Хоча деякі з цих систем можуть бути побудовані фізично з фізичними матеріалами, більшість із них створено за допомогою програмних функцій, які моделюють нейронну активність. Згорткові нейронні мережі (CNN), такі корисні для обробки зображень і комп'ютерного зору, а також рекурентні нейронні мережі, глибокі мережі та глибокі системи переконань — усі це приклади багаторівневих нейронних мереж. CNN, наприклад, можуть мати десятки шарів, які послідовно працюють над зображенням. Все це є ключовим для розуміння того, як функціонують сучасні нейронні мережі [3].

Штучні нейромережі (ШНМ) використовуються для інформаційного моделювання у ситуаціях, де є невизначеність, включаючи параметричні та непараметричні випадки. Вони широко використовуються для передбачень, прогнозів, класифікації, ущільнення даних та інших завдань обробки інформації. У деяких ситуаціях, особливо, коли маємо справу з великими завданнями з властивими значними нелінійностями, багатосарові перцептрони (БШП) не завжди ефективно вирішують завдання в обмежений час, оскільки їх навчання вимагає складних процедур багатовимірної оптимізації. Цей недолік можна вирішити шляхом розробки нових методів навчання для ШНМ без ітерацій або створення спеціалізованого обладнання для роботи з ними. Отже, актуальною є розробка високоефективних ШНМ, які базуються на нових підходах до навчання без ітерацій. Архітектура

багатошарових перцептронів (БШП) має бути націлена на реалізацію нейромереж із високою продуктивністю та обробкою даних у реальному часі на паралельних обчислювальних структурах. Для переходу до таких обчислювальних архітектур використовують методи просторово-часового відображення алгоритмів навчання та функціонування БШП на паралельних структурах із високою ефективністю обладнання. Хоча апаратне відтворення графів ШНМ значно поліпшує роботу у режимі функціонування, воно не вирішує проблеми ефективного навчання. Процедури навчання вимагають послідовної передачі сигналів у відповідності з методами мінімізації відхилень мережі від еталонних значень. Отже, апаратне відтворення графів ШНМ не допомагає значно покращити швидкодію, але може стати занадто великим та складним. Враховуючи різноманітність обчислювальних процедур та відмінності між функціонуванням та навчанням БШП зі зворотним поширенням помилок на виходах, подібні апаратні нейрокомп'ютери виявилися неефективними та дорогими і не отримали широкого застосування [4].

Проблема оптимального визначення напрямку зміни ціни на біржі в умовах обмеженої кількості даних остаточно не вирішена.

Метою статті є розробка нового методу як структурного елемента підсистеми у складі більшої системи.

2. Використання методів машинного навчання для прогнозування біржових показників

Фондові біржі відіграють ключову роль на фінансовому ринку та становлять важливу частину глобальної фінансової системи. Зі свого боку, фондова біржа виконує функції регулятора фінансового ринку [5].

У традиційному програмуванні розробник має створити алгоритм та написати код для отримання результату. Потім, задавши вхідні параметри, алгоритм обробляє дані та надає результат.

Моніторинг — це технологія, яка забезпечує інформацією процеси прийняття рішень через неперервні спостереження та обробку їх результатів. Інтелектуальний моніторинг, зі свого боку, полягає у зборі інформації про властивості об'єкта за допомогою створення та використання бази модельних знань під час обробки результатів спостережень [6].

Процес синтезу забезпечено багаторівневою технологією синтезу прогнозуючих моделей, що поєднує на проміжних рівнях класифікаційні моделі з прогнозуючими елементами. При погіршенні якості вихідних сигналів синтез здійснюється за рахунок заміни прогнозуючого елемента створенням нової моделі даного об'єкта моніторингу. Це супроводжується заміною всіх прогнозуючих елементів верхніх рівнів, з якими вони пов'язані. Заміну прогнозуючих моделей забезпечує синтезатор із дворівневим структуруванням, на основі якого реалізована підсистема управління якістю обробки інформації. На нижньому рівні підсистеми управління реалізується синтез прогнозуючих моделей об'єктів моніторингу відповідного рівня [6].

Оскільки проводяться систематичні спостереження за фінансовими та якісними параметрами об'єктів у зонах підвищеного ризику для прогнозування фінансових показників, то масив вхідних даних постійно оновлюється та поповнюється [7].

Підвищення інформаційної достатності та точності прогнозування при обробці обмежено інформативного масиву вхідних даних забезпечено поглибленням технології розпізнавання образів [6].

Елемент часового ряду — це числове значення характеристики об'єкта. Елементи часового ряду отримуються під час моніторингу промислових процесів або відстеження показників корпоративної діяльності. Інформативність означає можливість точного відображення властивостей об'єкта в певний момент спостереження. Елементи ряду викорис-

товуються алгоритмами синтезу прогностичних моделей (АСПМ). Надійне відображення властивостей об'єкта на визначених інтервалах дозволяє АСПМ побудувати модель прогнозу з великим прогностичним горизонтом. Прогнозування часових рядів — це використання моделі для передбачення числових значень характеристики об'єкта на основі раніше спостережених значень [8].

Різна інформативність елементів часового ряду виникає через зміну стану прогнозованого об'єкта, збурення зовнішніх та внутрішніх факторів, реєстрацію числових характеристик об'єкта різними технічними засобами з різними показниками точності вимірювань та ін. [9].

Прогнозні моделі корисні, якщо стан об'єкта в майбутньому не зміниться. На сьогодні стан об'єкта за допомогою прогностичної моделі на основі елементів часового ряду має різну інформативність.

У роботі для вивчення використання часових рядів зі змінною інформативністю елементів був використаний прогностичний фільтр Колмогорова-Габора [10]. Це аналоговий або цифровий пристрій, на вхід якого подаються як значення цільової функції, так і значення відповідних змінних (корельованих). Використовуються як значення змінних на даний момент, так і їх значення в будь-якій точці попередньої історії. Наступне значення прогнозованої функції виводиться зі значень цієї функції у минулому. Частота дискретизації вивченої функції є постійною.

Елементи часового ряду мають свою структуру, яка змінюється з часом. Це робить аналіз часового ряду з елементами різної інформативності відмінним від середніх досліджень, які не мають природного порядку спостережень. Аналіз такого часового ряду відрізняється від аналізу просторових даних, де спостереження зазвичай є географічними (наприклад, ціни на житло за місцем розташування, а також внутрішні характеристики будівель). Стихійна модель часового ряду підтверджує факт, що спостереження, наближені в часі, не завжди пов'язані більше, ніж раніше. Наприклад, при зміні статусу об'єкта моніторингу, такого як перехід до кризового моніторингу, прогностична модель, побудована на елементах часового ряду, фіксованих у нормальному режимі, втратить свою корисність.

Крім того, моделі часових рядів часто використовують однобічне упорядкування. Отже, елементи часового ряду, отримані протягом цього періоду, будуть похідними від попередніх елементів часового ряду відповідно до цього періоду.

Розкриваються залежності між кількістю правильно передбачених характеристик динаміки процесу та кількістю кроків прогнозу моделі на заданому часі [9].

Виявлено особливості використання результатів прогнозування моделі на основі фільтра Колмогорова-Габора при оцінці зміни стану об'єкта з метою ідентифікації моменту, після якого використання прогностичної моделі на основі історичних даних втрачає свою актуальність.

Пропонується оцінити точність прогнозування з урахуванням зміни стану передбачуваного об'єкта.

Для побудови прогностичних моделей на основі часового ряду з елементами різної інформативності важливо враховувати зміну стану об'єкта, внутрішню структуру часового ряду та ідентифікацію історичних періодів з подібними властивостями елементів часового ряду.

Методи аналізу часових рядів поділяються на два класи: у частотній та часовій областях. Перші, крім спектрального аналізу і вейвлет-аналізу, містять у собі автокореляційний та крос-кореляційний аналізи. У часовій області кореляційний аналіз повинен відбуватися у вигляді фільтра, використовуючи масштабовану кореляцію, в міру зменшення потреби працювати у частотній області.

Методи аналізу часових рядів поділяються на параметричні та непараметричні. Параметричні підходи передбачають, що базовий стаціонарний випадковий процес має

певну структуру, яку можна описати за допомогою невеликої кількості параметрів (наприклад, за допомогою авторегресійної моделі або рухомого середнього). У таких підходах викликом є оцінка параметрів моделі, яка описує випадковий процес. Зі свого боку, непараметричні підходи явно оцінюють коваріацію або спектр процесу не дивлячись, що процес має певну структуру [11].

Методи аналізу часових рядів також поділяють на лінійні та нелінійні, а ще одновимірні та багатовимірні. Моделі для заданих часових рядів можуть приймати багато форм і відображати різні випадкові процеси. У моделюванні змін рівня процесу використовують три основні класи: авторегресійні (AR) моделі, інтегровані (I) моделі та моделі рухомого середнього (MA) [8].

Нелінійна залежність рівня ряду від попередніх точок даних надає можливість створення хаотичного часового ряду. Емпіричні дослідження можуть показати деякі переваги використання прогнозів, отримані з нелінійних моделей, порівняно з лінійними моделями, як, наприклад, в нелінійних авторегресійних екзогенних моделях. Іншою категорією нелінійними часовими рядами є моделі, що включають зміни дисперсії з часом (гетероскедастичність). Це умовна гетероскедастичність авторегресії, а колекція таких пропозицій включає широкий спектр джерел представлень (GARCH, TAR, EGARCH, FIGARCH, CGARCH та ін.). У цьому випадку зміни у змінності зв'язані або передбачені за останніми значеннями спостережуваного ряду. Це відрізняється від інших можливих концепцій локально змінної змінності, де змінність може бути модельована окремим часово-змінним процесом, як, наприклад, у двобічній стохастичній моделі [11].

У недавньому аналізі без моделі визнані методи, що базуються на хвильових перетвореннях (наприклад, локально стаціонарні хвильові перетворення та хвильово-розкладені нейронні мережі). Мультимасштабні методи (часто відомі як багаторезольюційні) розширюють цей часовий ряд, намагаючись проілюструвати залежність у часі на кількох шкалах. Слід узяти до уваги марковські перехідні мультифрактальні методи (МПММ) для моделювання еволюції варіативності. Прихована модель Маркова (ПММ) є статистичною моделлю, в якій симулювання системи вважається процесом з непозначеними (прихованими) станами. ПММ можна вважати найпростішою байєсівською динамічною мережею. ПММ широко використовується в розпізнаванні мови для перетворення часового ряду вимовлених слів у тексті [8].

3. Постановка задачі

Прогнозування — це одне з завдань інтелектуального аналізу даних. Відмінність цієї задачі полягає в тому, що вона враховує час як один із параметрів і передбачає чисельні характеристики подій, які ще не відбулися. У цьому дослідженні основна увага була спрямована на прогнозування показників фондової біржі (золото).

Дано:

– експертно визначений перелік (словник) ознак факторів X , які, на думку експертів, впливають на ціну золота на біржі і є доступними для визначення їх чисельних характеристик:

$$X = \{x_1, x_2, \dots, m\}, \quad (1)$$

де m — кількість ознак у словнику;

– масив історичних даних у формі значення чисельних характеристик цін на різні показники біржі:

$$Y = \{y_{t_1}, y_{t_2}, \dots, y_{t_n}\}, \quad (2)$$

де y_{t_n} — ціна золота на момент закриття біржі, зафіксована у момент часу t_n ;

n — кількість моментів часу, коли проводились спостереження, значення чисельних характеристик ознак масиву X_t , зафіксованих впродовж часу $t_1 - t_n$ через дискретні проміжки часу Δt , що зветься кроком прогнозування;

– тривалість кроку прогнозування Δt :

$$\Delta t = t_n - t_{n-1}. \quad (3)$$

Необхідно розрахувати значення ціни на золото у момент часу t_{n+k} , де k — горизонт прогнозування (на скільки кроків у майбутнє можна довіряти результатам прогнозування). Гіпотези:

1. Результат прогнозування $y_{t_{n+k}}$ визначається як функціональна залежність:

$$y_{t_{n+k}} = f(Y, X_t), \quad (4)$$

де $y_{t_{n+k}}$ — ціна золота на момент закриття на горизонті прогнозування k .

2. Масив історичних даних має недостатню інформативність, тому для побудови корисного прогнозу необхідно визначити оператор f виразу (4) у формі багат шарового поєднання функціональних залежностей:

$$f = f(f_1(Y, X_t), f_2(Y, X_t), \dots, f_l(Y, X_t)), \quad (5)$$

де l — кількість моделей у шарі.

3. Для побудови прогнозної моделі відповідно до виразу (5) необхідно застосувати метод синтезу багат шарових прогнозних моделей, побудований із залученням багат шарової моделі, прогнозуючого фільтра та нейромережі як структурних елементів шару.

Для перевірки цих гіпотез були проведені дослідження, результаті яких подані у цій роботі.

Ставилось завдання застосувати принцип синтезу багат шарових моделей при побудові нового методу не як автономної системи, а як структурного елемента надсистеми для прогнозування ціни на золото.

4. Дослідження та результати

Щоб отримати результати досліджень нового методу синтезу багат шарового предиктора [1], нами проводились дослідження процесу використання алгоритму синтезу моделей (АСМ), побудованого за новим методом, у процесі функціонування агентного синтезатора моделей. Одна із стратегій поведінки синтезатора передбачає поєднання кількох АСМ у єдину структуру. Відомо, що не будь-яке поєднання елементів дозволяє отримати систему. Для цього необхідно було виявити, яким чином використання додаткового елемента вплине на результати роботи агента при виконанні завдань прогнозування біржових показників.

Низька інформативність історичних даних, що описують процеси ціноутворення облігацій, зокрема на золото, викликана впливом факторів, які поки не вдається врахувати при формуванні первинного опису (ПО) об'єкта прогнозування (біржових цін, зокрема на золото). Тому новий АСМ [1] обов'язково буде використаний як структурний елемент багат шарової прогнозної моделі. Тому задача параметричної оптимізації процесу синтезу предиктора новим АСМ повинна проводитися за критерієм якості у формі функції невідзначеності результатів агентного прогнозування в цілому. Мається на увазі, що досліджувати новий метод треба не як автономний процес побудови агентної моделі, а як структурний елемент поєднання кількох АСМ.

Для дослідження використовувались АСМ, побудовані на основі нейронної мережі [12], прогнозуючого фільтра Колмогорова-Габора [10] та нового методу синтезу багатопарних прогнозних моделей [1]. Особливістю цього дослідження було те, що багатомодельна структура будувалась для виконання агентного завдання з прогнозування біржового показника. Тобто передбачається робота моніторингового агента в умовах низькоінформативного масиву результату спостережень — історичних даних.

Для дослідження використовувались дані з фондових бірж [13], зібрані впродовж лютого-березня 2016 року. Прогнозувалась ціна на золото в момент закриття біржі. Для навчання системи використовувався масив вхідних даних, сформований з S&P, австралійського долара, канадського долара, казначейських облігацій, довгострокових облігацій, індексу долара та ін. (рис. 1).

Date	Gold	S&P	Australian (Ishares 7-11shares 1-3)	Canadian (International Vanguard I Invesco DE Gold -3	Gold -2	Gold -1						
19/02/2016	115.49	192.00	71.53	110.49	84.96	72.01	46.96	89.85	25.07	115.48	118.29	117.58
22/02/2016	117.22	194.78	72.43	110.38	84.97	72.33	46.83	90.03	25.26	118.29	117.58	115.49
23/02/2016	117.61	192.32	72.18	110.60	84.98	72.02	46.85	90.27	25.27	117.58	115.49	117.22
24/02/2016	117.92	193.20	72.04	110.60	85.00	72.44	46.90	90.33	25.29	115.49	117.22	117.61
25/02/2016	117.11	195.54	72.35	110.93	85.02	73.21	47.03	90.62	25.27	117.22	117.61	117.92
26/02/2016	118.64	195.09	71.33	110.39	84.91	73.37	46.87	90.21	25.44	117.61	117.92	117.11
29/02/2016	117.77	193.56	71.43	110.57	84.96	73.27	46.74	90.41	25.49	117.92	117.11	118.64
01/03/2016	118.68	198.11	71.81	109.55	84.80	73.91	46.59	89.37	25.50	117.11	118.64	117.77
02/03/2016	120.73	199.00	72.95	109.36	84.79	73.82	46.56	89.54	25.48	118.64	117.77	118.68
03/03/2016	120.54	199.78	73.63	109.49	84.82	74.00	46.92	90.07	25.32	117.77	118.68	120.73
04/03/2016	121.14	200.43	74.32	109.12	84.76	74.44	46.91	90.08	25.25	118.68	120.73	120.54
07/03/2016	120.58	200.59	74.70	108.90	84.70	74.67	46.99	90.21	25.20	120.73	120.54	121.14
08/03/2016	119.58	198.40	74.35	109.53	84.76	73.87	47.29	90.71	25.21	120.54	121.14	120.58
09/03/2016	121.50	199.38	74.86	109.10	84.73	74.81	46.96	90.60	25.22	121.14	120.58	119.58
10/03/2016	119.41	199.54	74.52	108.71	84.72	74.30	47.22	90.71	24.97	120.58	119.58	121.50
11/03/2016	117.87	202.76	75.62	108.40	84.64	74.93	47.39	90.58	24.95	119.58	121.50	119.41
14/03/2016	117.96	202.50	75.09	108.48	84.64	74.74	47.22	90.88	25.05	121.50	119.41	117.87
15/03/2016	120.59	202.17	74.60	108.46	84.67	74.18	47.20	91.14	25.07	119.41	117.87	117.96
16/03/2016	120.13	203.34	75.64	109.03	84.84	75.56	47.82	91.19	24.80	117.87	117.96	120.59
17/03/2016	119.80	204.63	76.48	109.15	84.83	76.30	48.39	91.66	24.58	117.96	120.59	120.13
18/03/2016	118.96	204.38	76.05	109.34	84.85	76.05	48.37	91.93	24.64	120.59	120.13	119.80
21/03/2016	119.31	204.67	75.87	109.03	84.84	75.77	48.19	91.86	24.72	120.13	119.80	118.96

Рисунок 1 — Масив вхідних даних біржових показників

Як ознаки, що прогнозувались, використано:

- 1) напрям зміни значення ціни золота Δ ;
- 2) абсолютне значення ціни на золото.

Адекватність результатів прогнозування оцінювалась у такий спосіб. Якщо біржова ціна на золото зростала у порівнянні з минулим показником, результат прогнозування Δ фіксувався знаком «+», якщо ціна спадала — знаком «-». Результат прогнозування вважався адекватним, якщо напрям зміни спрогнозованого значення ціни на золото Δ співпадав із напрямом зміни дійсної ціни цієї облігації. Якщо результати прогнозування співпадали з дійсним напрямом, цей результат вважався адекватним і його позначали як $\Delta = 1$. У протилежному випадку $\Delta = 0$.

Оцінка адекватності результатів прогнозування розраховувалась за виразом

$$N = \frac{\sum_{i=1}^n \Delta_i}{n} 100\% , \quad (1)$$

де Δ_i — результат прогнозування;

n — кількість прогнозів.

Оцінку невизначеності прогнозу ціни облігацій для окремого спостереження розраховували за виразом

$$\delta_i = \frac{y_i - y_i^*}{y_i}, \quad i = \overline{1, n}, \quad (2)$$

де n — кількість прогнозів.

Невизначеність прогнозування визначалась за виразом

$$\bar{\delta}_i = \frac{\sum_{i=1}^n \delta_i}{n} 100\%, \quad (3)$$

де $\bar{\delta}_i$ — невизначеність окремого прогнозу.

Результати досліджень подані у табл. 1.

Таблиця 1 — Порівняння різних методів прогнозування

№ експерименту	АСМ, структурні елементи агентної моделі	Кількість адекватних прогнозів N , %	Невизначеність прогнозування $\bar{\delta}_i$, %
1	Прогнозуючий фільтр	24,00	1,92
2	Нейромережа	52,00	1,06
3	Новий метод	54,00	1,91
4	Прогнозуючий фільтр + нейромережа	56,00	0,89
5	Поєднання всіх елементів	56,00	0,70

За результатами досліджень, поданими у табл. 1, можна стверджувати, що АСМ, створений на основі нового методу синтезу багат шарових предикторів (експеримент 3), переважає за адекватністю результатів прогнозування АСМ, побудованих на основі окремих прогнозних методів (експерименти 2 і 3). За використанням АСМ, побудованого за новим методом, як структурний елемент агентної моделі адекватність прогнозування не знижується у порівнянні з результатами експерименту. При цьому невизначеність прогнозування знижується. У такий спосіб вдається досягнути емерджентності поєднання АСМ у структурі агентної моделі у формі зниження невизначеності прогнозування.

5. Висновки

У ході дослідження експериментально підтверджена гіпотеза, що використання параметричної оптимізації при побудові АСМ за новим методом синтезу багат шарових предикторів покращує характеристики агентної моделі.

Доведено, що параметрична оптимізація АСМ, побудованого за новим методом синтезу прогнозних предикторів, дозволяє його використовувати як структурний елемент агентної моделі і дозволяє побудувати цю агентну модель як систему. Характеристики результатів його прогнозування є кращими за характеристики результатів моделювання будь-якого його елемента (АСМ на основі прогнозуючого фільтра, нейромережі, нового методу синтезу прогнозних моделей).

Доведено, що поєднання різнорідних АСМ у структурі агентної моделі здатне розв'язувати завдання прогнозування біржової вартості золота.

У статті поданий приклад впровадження нового методу синтезу багат шарових предикторів у практику побудови агентних моделей.

СПИСОК ДЖЕРЕЛ

1. Голуб С.В., Толбатов Д.В. Метод синтезу багатошарової моделі моніторингового програмного агента. *Математичні машини і системи*. 2023. № 1. С. 101–111.
2. An Overview on Multilayer Perceptron (MLP). URL: <https://www.simplilearn.com/tutorials/deep-learning-tutorial/multilayer-perceptron>.
3. Multi-Layer Neural Network. URL: <https://www.techopedia.com/definition/33268/multi-layer-neural-network>.
4. Ткаченко Р., Цмоць І., Скорохода О. Синтез високоефективних багатошарових перцептронів із неітераційним навчанням. *Комп'ютерні науки та інформаційні технології*. 2009. Вип. 650. С. 44–55.
5. Бойко С. Машинное обучение в повседневной жизни. URL: <https://dou.ua/lenta/articles/ml-in-real-life>.
6. Голуб С.В. Багаторівневе моделювання в технологіях моніторингу оточуючого середовища: монографія. Черкаси: Вид. ЧНУ імені Богдана Хмельницького, 2007. 220 с.
7. Голуб С.В., Толбатов Д.В. Інформаційні моделюючі технології, системи та комплекси (сучасний стан та шляхи розвитку інформаційних технологій, технологій моделювання інформаційних та інтелектуальних систем і комплексів у соціумі). *Матеріали I міжнар. наук.-практ. конф. ІМТСК-2019*. Черкаси, 2019. С. 100–102.
8. Time series. URL: https://en.wikipedia.org/wiki/Time_series.
9. Process or Product Monitoring and Control. URL: <https://www.itl.nist.gov/div898/handbook/pmc/pmc.htm>.
10. Ivahnenko A.G. Models of Complex Systems. К.: Nauk. dumka, 1982. 296 p.
11. Classical time series forecasting methods in python. URL: <https://machinelearningmastery.com/time-series-forecasting-methods-in-python-cheat-sheet/>.
12. Neural network (machine learning). URL: [https://en.wikipedia.org/wiki/Neural_network_\(machine_learning\)](https://en.wikipedia.org/wiki/Neural_network_(machine_learning)).
13. Фондові біржі. URL: <https://finance.yahoo.com/>.

Стаття надійшла до редакції 27.08.2024