

КУШНІР М. Я., ТОКАРЕВА К. А.

## ГІБРИДНА МОДЕЛЬ САМООРГАНІЗАЦІЙНОЇ КАРТИ КОХОНЕНА ТА АДАПТИВНОЇ НЕЙРО-НЕЧІТКОЇ СИСТЕМИ ВИВОДУ У ЗАДАЧАХ ПРОГНОЗУВАННЯ ЦІН ФОНДОВИХ ІНДЕКСІВ

Досліджено використання методів штучного інтелекту у прогнозуванні і аналізі часових рядів фінансових даних, оскільки останні мають нелінійну, хаотичну, багатовимірну та просторову природу, що робить прогнозування складним процесом. Запропоновано гібридну модель самоорганізаційної карти Кохонена та адаптивної нейро-нечіткої системи виводу для задачі прогнозування цін фондових індексів. Виявлено, що гібридні моделі є кращими предикторами, оскільки вони швидкі, ефективні та мають менше помилок. Запропонований гібридний метод з адаптивною нейро-нечіткою системою виводу продемонстрував зменшення похибок та вищу загальну точність.

*Ключові слова і фрази:* машинне навчання, часовий ряд фінансових даних, організаційна карта Кохонена, адаптивна нейро-нечітка система виводу.

---

Yuriy Fedkovych Chernivtsi National University, Chernivtsi, Ukraine  
e-mail: *kushnirnick@gmail.com, tokarieva.chnu@gmail.com*

### ВСТУП

В математичній науковій літературі існують численні результати [11] прогнозування фінансових даних, однак науковці та практики зіштовхуються з певними труднощами при спробі моделювати таку складну систему, як фондовий ринок, оскільки він має нелінійну, хаотичну, багатовимірну та просторову природу, що робить прогнозування складним процесом. Моделі, з допомогою яких здійснюється оцінка нестаціонарних фінансових часових рядів, можуть включати шум та схильні до помилок. Взаємозв'язок між вхідними та вихідними параметрами моделей по суті є нелінійним, де ціни на акції включають змінні вищого ступеня, що ускладнює моделювання та прогнозування фондового ринку. Хаотичні системи є детермінованими нелінійними, вони мають чутливу залежність від початкових умов, де незначні зміни початкових умов можуть призвести до різних результатів у майбутньому. Враховуючи, що ринок – це складна система, яка містить випадкові характеристики, деякі дослідження [7] продемонстрували як змінюються характеристики оцінок фінансових даних спираючись на фактори початкових

---

УДК 519.866

2010 *Mathematics Subject Classification:* AMS 62M10.

умов. Крім того, в публікації [10] детально досліджено характеристики фондового ринку та зроблено однозначний висновок наявності хаосу.

Ще однією особливістю фінансових часових рядів є їх багатовимірність, оскільки загальновідомо, що ціни на акції мають багатоваріантний характер, на них впливає безліч факторів, таких як економіка, політика, екологія тощо. Дослідження досліджували зв'язок ціни та поведінкові, часові та політичні моделі. Аналіз та оцінка багатовимірних системи та їх прогнозування повинні здійснюватися саме моделями машинного навчання, виділяючи корисні моделі. Технічний підхід до дослідження інвестицій має бути визначальним при аналізі зміни цін, що пов'язано із зміною ставлення інвесторів, які є частиною різноманітних економічних, грошових, політичних та психологічних процесів.

## 1 АНАЛІЗ ОСТАННІХ ДОСЛІДЖЕНЬ І ПУБЛІКАЦІЙ

Підкреслимо, що проблема прогнозування фондового ринку та отримання якісних прогнозів є актуальною задачею, а методи та моделі машинного навчання мають бути основним математичним інструментарієм у розв'язанні вищеописаних задач і проблем. На нашу думку, таким інструментарієм може бути популярний алгоритм машинного навчання самоорганізаційної карти Кохонена (SOM) [9], який використовується для візуалізації багатовимірних даних шляхом конфігурації нейронів з метою квантування або кластеризації вхідного простору в топологічну структуру. Такі характеристики зазначеного алгоритму роблять його привабливим у розв'язанні багатьох задач, що включають кластеризацію, особливо для прогнозування ціни акцій. Детальне дослідження використання самоорганізаційної карти Кохонена у фінансовій галузі було проведене в праці [5], де автори виявили, що результати застосування цього алгоритму перевищують очікування, особливо через нестационарну залежність. Наприклад, використання локальних моделей на базі SOM з мережею радіально-базисних функцій для кластеризації німецького фондового індексу DAX стало найбільш придатним для цього часового ряду через його історично нестабільну природу. В додаток, в праці [1] розробили гібридний варіант самоорганізаційної карти Кохонена та методу зворотного поширення помилки і прийшли до висновку, що знаходження гібриду є кращим предиктором, оскільки він швидкий, ефективний та має менше помилок у класифікації.

Однак, при використанні самоорганізаційної карти Кохонена відсутнє припущення про те, що одна модель здатна "охопити динаміку" всього часового ряду. Крім того, розглянуті методи у працях вище, спонукають нас застосувати цей кластерний підхід для представлення іншої структури даних для прогнозування. Так, моделі адаптивної нейро-нечіткою системи виводу (ANFIS) поєднують характеристики як нейронних мереж, так і нечіткої логіки. Теорія нечіткої логіки підходить для складних та нелінійних задач завдяки своїй здатності оцінювати детерміновані невизначеності. Як результат, адаптивна нейро-нечітка система виводу широко застосовується у фінансовій сфері для прогнозування фондових ринків, іноземної валюти та індексів [4]. Біллах [2], в свою чергу, зробив висновок, що адаптивна нейро-нечітка система виводу дає більш точні результати прогнозування фондових індексів у порівнянні з штучною нейронною мережею. Більше того, зазначений метод дав кращі результати у порівнянні різних функцій

приналежності та параметрів на основі розрахунку помилок. Поєднання методу найменших квадратів та зворотного поширення помилки для оптимізації параметрів дали змогу отримати точність у 74% [6].

## 2 ПОСТАНОВКА ЗАВДАННЯ

Враховуючи той факт, що правило гібридного навчання та теорія логіки – це однозначна перевага адаптивної нейро-нечіткої системи виводу, яка має обчислювальні переваги перед іншими методами ідентифікації параметрів, запропонуємо новий гібридний алгоритм інтеграції самоорганізаційної карти Кохонена з адаптивною нейро-нечіткою системою виводу, яка ще не застосовувалася для прогнозування цін фондових індексів.

## 3 ВИКЛАД ОСНОВНОГО МАТЕРІАЛУ

Кохонен [9] запропонував алгоритм, який належить до нейронної мережі без учителя, і який використовується для побудови багатовимірного простору в простір з нижчою розмірністю. Топологічні карти формуються на основі алгоритму навчання, що стосується подібності вхідних зразків, наприклад, перетворення простору вищої розмірності в просторове відношення між нейронами, що представляють вхідні дані. Потім алгоритм оновлює ваги використаного нейрона, але тільки тих, що знаходяться в просторовій близькості, на основі зон активації кожного нейрона.

Етапи тренувань, як показано нижче, повторюються для адаптації вагових векторів та конкурентоспроможності, доки не буде виконано критерій зупинки. Алгоритм виглядає так:

1. Вхідний вектор  $x$  представляється в мережу;

2. Через конкурентний процес, відстань обчислюється між вхідним вектором і всіма нейронами вихідного шару з метою знаходження так званого найкращого нейрона. Відомо, що під час встановлення відповідностей між нейронами отримується нейрон-переможець (найкращий нейрон), тобто нейрон, чий ваговий вектор лежить ближче до вхідного вектора:

$$\|x - w_i\| = 1, 2, \dots, l, \quad (1)$$

де  $l$  – це кількість вихідних нейронів,  $w$  – вектор ваги;

3. Через процес адаптації ваг, вагові вектори оновлюються в момент часу  $t + 1$  в околі найкращого нейрона, а сусідні нейрони визначаються зоною активації:

$$w_i(t + 1) = w_i(t) + \eta(t)\pi_{i,i^*}(t)(x(t) - w_i(t)), \quad (2)$$

де  $\pi_{i,i^*}(t)$  – функція сусідства, а  $\eta(t)$  – коефіцієнт навчання, який залежить від відстані між найкращим нейроном  $i^*$  та нейроном  $i$ . Функція сусідства, як правило, є функцією Гауса, визначена як:

$$\pi_{i,i^*} = \exp\left(\frac{-\|p_i - p_{i^*}\|}{g(t)}\right), \quad (3)$$

де  $p_i^*$  – найкращий нейрон,  $p_i$  – вектор-позиція сусіднього нейрона, а  $g(t)$  – параметр, який монотонно зменшується.

З іншого боку, адаптивна нейро-нечітка система виводу є прикладом штучної нейронної мережі, яка базується на нечіткій системі виводу Такагі-Сугено. Нечітка система виводу формує параметри функції належності, які налаштовані або за допомогою алгоритму зворотного поширення помилки, або в поєднанні з методом найменших квадратів, що дозволяє нечіткій системі вчитися на змодельованих даних. Нечітка система виводу має два входи  $x$  та  $y$  та один вихід  $z$ . Нечітка модель Сугено першого порядку має такі 2 правила:

Правило 1: якщо  $A_1(x)$  та  $B_1(y)$ , тоді  $f_1 = p_1x + q_1y + r_1$ .

Правило 2: якщо  $A_2(x)$  та  $B_2(y)$ , тоді  $f_2 = p_2x + q_2y + r_2$ .

З правил випливає, що  $вихід = \frac{w_1f_1 + w_2f_2}{w_1 + w_2}$ .

Для досягнення точних результатів модель повинна вибрати правильну функцію належності.

Сам процес навчання можна описати як використання спостережень для оптимального розв'язання задачі. Нейронна штучна мережа представляє клас функцій  $F$ , метою якого є розв'язок певної задачі.

Процес навчання намагається знайти  $f^* \in F$  з метою оптимізації завдання. Отже, навчання можна описати як мінімізацію функції втрат  $C : F \rightarrow \mathbb{R}$ , такої що  $C(f^*) \leq C(f)$  для всіх  $f \in F$ .

Штучна нейронна мережа дозволяє моделювати як лінійні, так і нелінійні взаємозв'язки між вхідним і вихідним простором. Для того, щоб змоделювати взаємозв'язок функції  $f^* \in F$ , набір параметрів  $f^*$  є обов'язковим. Мірою того, наскільки добре штучна нейронна мережа відображає шукані взаємозв'язки, є функція втрат,  $C$ . Тоді функція втрат  $C$  оцінює залишки  $e_p$  з  $p = \{1, 2, \dots, P\}$ , які визначаються як різниця між вихідними значеннями  $y_p$  та прогнозованими значеннями  $\hat{y}_p$ :

$$e_p = y_p - \hat{y}_p, \quad (4)$$

де  $\hat{y}_p = f^*(y_{(p-\tau)}, y_{(p-\tau-1)}, \dots)$ ,  $\tau$  – діапазон часу, від якого залежить вказане наближення. В нашому випадку вихідні значення  $t - 1$  були використані як вхідні предиктори для прогнозування ціни.

Існують різні функції втрат, які можуть бути вибрані в даному випадку. В межах даного дослідження визначимо функцію втрат як суму квадратичних похибок  $p$  спостережень

$$E_p = \sum_{k=1}^{N(L)} e_{p,k}^2 = \sum_{k=1}^{N(L)} (y_{p,k} - \hat{y}_{p,k})^2, \quad (5)$$

де  $N(L) > 1$  відображає випадок штучної нейронної мережі з декількома виходами, а  $L$  позначає шар;  $y_{p,k}$  – актуальне вихідне значення  $p$ -го спостереження в  $k$ -й змінній;  $\hat{y}_{p,k}$  – еквівалент прогнозу.

В загальному функція втрат включає всі інші функції втрат для всіх  $P$  спостережень

і визначається як

$$E = \sum_{p=1}^P E_p. \quad (6)$$

В результаті даний набір параметрів визначає вихід штучної мережі.

Існує велика кількість методів навчання штучної нейронної мережі. Метод зворотного поширення помилки – це ітеративний градієнтний алгоритм, який використовується для мінімізації помилки роботи багатошарового перцептронну та отримання бажаного виходу. Адаптивна нейро-нечітка система виводу використовує градієнтний алгоритм для мінімізації функції втрат. Градієнт, в даному випадку, – це узагальнення одновимірної концепції похідної функції, а важливою властивістю градієнта є напрямок найбільшої швидкості збільшення. Алгоритм зворотного поширення помилки передбачає використання градієнтного спуску, тобто здійснюється спуск вниз по поверхні помилки та підлаштовується вага в напрямку до мінімуму. Концепція полягає у створенні послідовностей, які "блукають" у кожній ітерації крок за кроком, рухаючись далі у напрямку найбільшого зменшення до досягнення мінімуму. Якщо мінімум досягнуто, послідовність  $(x_1, x_2)$  збігається.

Для кожного параметру  $\alpha$  оновлена формула виглядає як:

$$\Delta\alpha_i = -\eta \frac{\partial E_p}{\partial \alpha_i}, \quad (7)$$

де  $\eta = \frac{K}{\sum_{p=1}^P \left(\frac{\partial E}{\partial \alpha_i}\right)^2}$ , а  $K$  – розмір кроку.

Оскільки метод зворотного поширення помилки реалізовує процес градієнтного спуску, то в такому випадку він має недолік, який полягає у повільності та "інтенсивності розрахунків". Жанг [8] запропонував так зване правило гібридного навчання, яке зменшує навантаження на розрахунки у процесі навчання. Алгоритм використовує комбінацію методів найменших квадратів та градієнтного спуску для оцінки навчального ряду даних:

Таблиця 1

Двонаправлене правило гібридного навчання [8]

	Пряме поширення	Зворотне поширення
Параметр 1	Фіксований	Градієнтний спуск
Параметр 2	Оцінка методом найменших квадратів	Фіксований
Сигнали	Виходи вузлів	Похибки сигналів

Однак, гібридне навчання має припущення про лінійність деяких своїх параметрів, що є критичним для оцінки найменших квадратів. Нечітка система виведення Такагі-Сугено підходить для описаного правила гібридного навчання, оскільки вона містить дві групи параметрів. Там, де параметри, що описують функції належності нечітких множин, містяться в першій групі, а послідовна функція нечітких правил *що-якщо* включається до другої групи.

Розглянемо результати емпіричного дослідження запропонованої гібридної моделі, які здійснювались в системі Matlab. Оскільки модель адаптивної нейро-нечіткої системи виводу є високопараметричною, то потрібно уважно підійти до питання підбору параметрів, щоб уникнути перенавчання. Кількість параметрів залежить від таких факторів:

- кількість вхідних змінних  $u$ ;
- кількість функцій належності на одну вхідну змінну  $v$ ;
- кількість параметрів вибраної функції належності  $z$ .

Загальна кількість параметрів може бути розрахована як  $z \cdot (v^u) + (u + 1) \cdot (v^u)$ , де  $v^u$  – кількість правил. Перша сума містить набір параметрів, що визначають всі функції належності, друга сума містить набір параметрів, що визначають поліноми першого порядку.

Оскільки кількість правил зростає експоненційно до основи  $v$  із силою  $u$ , то контроль  $v$  та  $u$  має суттєвий вплив на загальну кількість параметрів в моделі адаптивної нейро-нечіткої системи виводу. Таким чином, в зв'язку з описаним впливом  $u$ -ї змінної на загальну кількість параметрів, а також вкладенням розмірності модель містить не більше 2-х вхідних параметрів. Аналогічно, кількість функцій приналежності  $v$  на одну змінну теж встановлена на рівні 2. В додаток, була вибрана три-параметрична узагальнена колоподібна функція приналежності, яка найбільше відображає природу досліджуваного ряду даних. Отже, загальна кількість параметрів відповідно до описаних характеристик складає  $3 \cdot 2^2 + (2 + 1) \cdot 2^2 = 24$ .

Емпіричний підбір параметрів було виконано у два кроки. Перший крок полягає в тому, що спочатку для історичних даних для порядку  $(t - 1)$  було здійснено розділення на навчальний та валідаційний ряд. Оскільки не існує єдиного прийнятного алгоритму для визначення оптимального розміру карти Кохонена для тренування без учителя, ми використали розмір, використаний у роботі [3]. Відповідна розмірність – це 100 кластерів, представлених 10 рядками та 10 стовпцями. Початкове розміщення нейрону було обрано як 2d-структуру сітки. На рис. 1 зображено кінцеві оновлені позиції нейронів (жирні точки), адаптованої до топологічної форми набору даних.

Рис. 1 відображає алгоритм навчання самоорганізаційної карти Кохонена на завершальному етапі ітерації, коли досяглась збіжність. Еволюція положення нейронів наближена до точок даних, що відображають основні кластери (скупчення); на рисунку ми чітко бачимо високу кореляцію ваги 1 проти ваги 2, створюючи сітку в 45 градуссах і яскраво виражене згущення в центрі (приблизно 0,5). U-матриці, зображені на рис. 2-3, відображають відстані найближчих груп сусідів (темніші кольори відображають більші ваги) з жирними шестикутниками, що представляють нейрони.

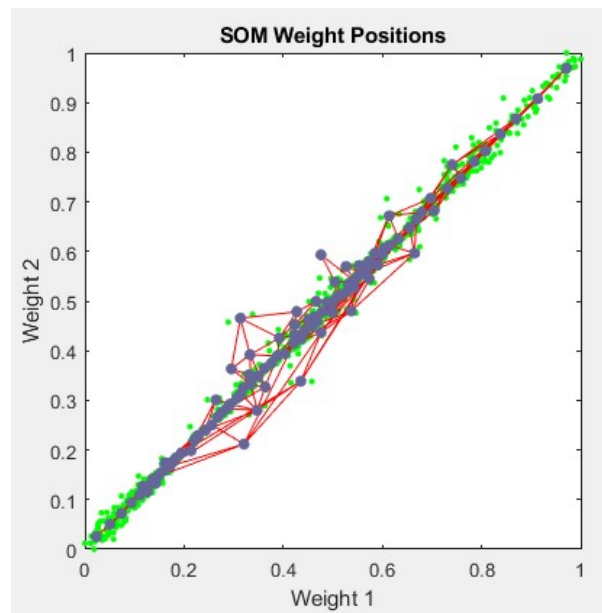


Рис. 1. Позиція нейронів самоорганізаційної карти Кохонена




Рис. 2. U-матриця: вхідні вагові вектори




Рис. 3. U-матриця: відстань між ваговим вектором вузла та його найближчими сусідами

Темна сегментація (рис. 3), що виходить з нижньої центральної області до центру, вказує на чітке групування показників. На рис. 4 зображено розподіл навчального ряду та ряду валідації вздовж топології карти Кохонена. Найбільші скупчення даних спостерігаються в кластері 51, розташованому внизу ліворуч, і, разом з тим, відсутні скупчення по центру, що вказує на чітке розділення.




Рис. 4. Розподіл навчального та тестового набору в кластерній топології самоорганізаційної карти Кохонена

Відповідно, на другому етапі була застосована модель адаптивної нейро-нечіткої системи виводу для прогнозування цін. Загальна кількість входів – 2 з лагом в один день та нормалізованих методом мінімаксу. Відповідні параметри моделі наведені в табл. 2.

Таблиця 2

Параметри моделі адаптивної нейро-нечіткої системи виводу

Параметр	Значення
Тип	Сугено
Функція приналежності	Гаусова
Метод оптимізації	Гібрид
Кількість кластерів	Автоматична
Ог метод	Ймовірнісний
Метод дефузіфікації	Зважене середнє
Вхід	1x2
Вихід	1x1
Правило	1x4
Кількість епох	10



Після 10 епох отримано прогноз для навчального ряду, що зображено на рис. 5.

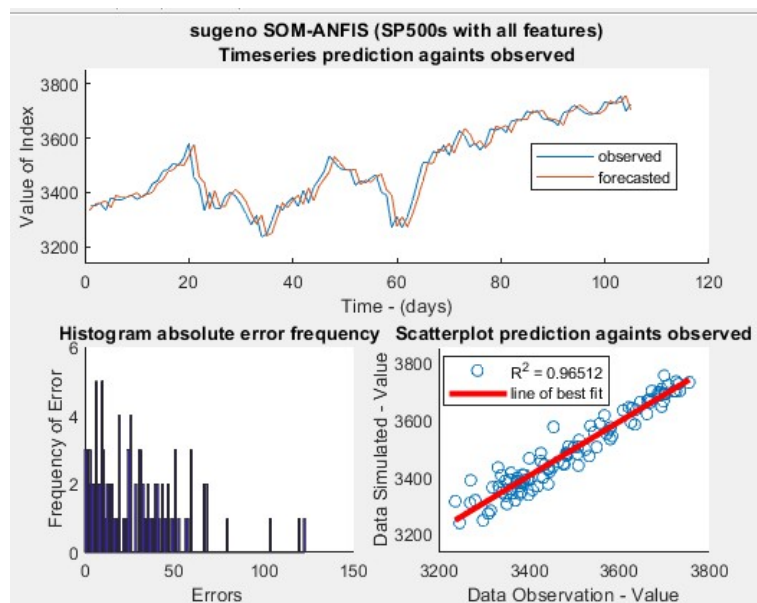


Рис. 5. Ефективність навчання з допомогою гібридної моделі

З рис. 5. можна зробити висновок про ефективність запропонованого методу: на діаграмі розсіювання наведено доволі високу кореляцію ( $R^2 = 0,965$ ) між спостережними та змодельованими значеннями. Крім того, візуалізація абсолютної різниці частот між спостережуваними та імітаційними значеннями зображена в нижній лівій гістограмі. Вершини помолок нижче частоти 100, а також існує правий асиметричний розподіл з екстремальним значенням приблизно в 50. Часовий ряд (верхній рисунок) демонструє зміну спостережуваної змінної з обох змодельованих та тестових даних.

Ми порівняли результати (на основі 4-х відомих похибок MAE, MSE, MAPE та RMSE), отримані за допомогою запропонованого алгоритму та інших моделей, які були побудовані нами в інших дослідженнях та, які ще не опубліковані. Дані таблиці 3 свідчать про високу результативність гібридної моделі самоорганізаційної карти Кохонена та адаптивної нейро-нечіткої системи виводу. Модель має високу кореляцію між вихідними і прогнозованими значеннями та менші значення похибок у порівнянні з попередніми моделями.

Для зручності поєднання ефективності побудованих зобразимо похибки в одній таблиці:

Таблиця 3

Оцінка ефективності гібридних моделей

	MAE	MSE	MAPE	RMSE
ARIMA (0,1,0)	1,136	2666,053	45,417	78,808
ARIMA (3,1,1)	0,243	850,329	27,599	36,783
Гібридна модель ARIMA та багатошарового перцептронну Румельхарта	0,2324	1993,534	19,485	44,649
Гібридна модель ARIMA та рекурентної нейронна мережа	1,321	3600,330	39,525	60,003
Запропонована гібридна модель	0,123	801,081	17,432	31,324

## ВИСНОВКИ

Таким чином, проблема прогнозування фондового ринку та отримання якісних прогнозів є актуальною задачею, а методи та моделі машинного навчання мають бути основним математичним інструментарієм у розв'язанні вищеписаних задач і проблем. Одним із таких інструментаріїв може бути популярний алгоритм машинного навчання самоорганізаційної карти Кохонена, який використовується для візуалізації багатовимірних даних шляхом конфігурації нейронів з метою квантування або кластеризації вхідного простору в топологічну структуру. Такі характеристики зазначеного алгоритму роблять його привабливим у розв'язанні багатьох задач, що включають кластеризацію, особливо для прогнозування ціни акцій. В додаток моделі адаптивної нейро-нечіткої системи виводу поєднують характеристики як нейронних мереж, так і нечіткої логіки. Теорія нечіткої логіки підходить для складних та нелінійних задач завдяки своїй здатності оцінювати детерміновані невизначеності. Запропонований гібридний метод зазначених методик продемонстрував зменшення похибок та вищу загальну точність.

## СПИСОК ЛІТЕРАТУРИ

- [1] Afolabi M.O., Olude O. Predicting stock prices using a hybrid Kohonen self organizing map (SOM). In System Sciences, January, 2007. HICSS 2007. 40th Annual Hawaii International Conference on (pp. 48-48). IEEE.
- [2] Billah M., Waheed S. and Hanifa A. *Predicting Closing Stock Price using Artificial Neural Network and Adaptive Neuro Fuzzy Inference System (ANFIS): The Case of the Dhaka Stock Exchange*. International Journal of Computer Applications, 2015, **129**(11), 1–5.
- [3] Bowden Gavin, Maier Holger, Dandy Graeme. *Optimal Division of Data for Neural Network Models in Water Resources Applications*. Water Resources Research – WATER RESOUR RES, 2002. 38. 10.1029/2001WR000266
- [4] Boyacioglu M.A. and Avci D. *An adaptive network-based fuzzy inference system (ANFIS) for the prediction of stock market return: the case of the Istanbul stock exchange*. Expert Systems with Applications, 2010, **37**(12), 7908–7912.
- [5] Dablemont S., G. Simon, A. Lendasse, A. Ruttiens, F. Blayo and M. Verleysen. Time series forecasting with SOM and local non-linear models-Application to the DAX30 index prediction. In: Proceedings of the workshop on self-organizing maps, 2003, Kitakyushu, Japan, Citeseer.
- [6] Durbin J, Koopman SJ. *Time Series Analysis by State Space Methods*. Oxford University Press, Oxford, 2001.
- [7] Ghosh I., Sanyal M.K. and Jana R.K. *Fractal Inspection and Machine Learning-Based Predictive Modelling Framework for Financial Markets*. Arabian Journal for Science and Engineering, 2017, 1–15.
- [8] Jang JS. ANFIS: adaptive-network-based fuzzy inference system. IEEE transactions on systems, man, and cybernetics, May, 1993, **23**(3), 65–85.
- [9] Kohonen T. *Self-organized formation of topologically correct feature maps*. Biological cybernetics, 1982, **43**(1), 59–69.
- [10] Meng J., Zhu T., Chen X. and Yin X., The nonlinear dynamics characteristics of stock market and its variation. In Proceedings of the 2nd International Conference on Computer Science and Electronics Engineering (ICCSEE 2013), March, 2013, Published by Atlantis Press, Paris, France. 0450–0455.

- [11] Kushnir M.Ya., Tokareva K.A. *The use of artificial intelligence systems in forecasting tasks of financial indices: a review of scientific sources*. Radio electronic and computer systems, 2020, **3**(95), 108–117. doi: 10.32620/reks.2020.3.11

Надійшло 02.04.2021

---

Kushnir M. Ya., Tokarieva K. A. *Hybrid model of self-organizing map and adaptive neuro fuzzy inference system in stock indexes forecasting*, Bukovinian Math. Journal. **9**, 2 (2021), 70–80.

The paper investigates methods of artificial intelligence in the prognostication and analysis of financial data time series. It is uncovered that scholars and practitioners face some difficulties in modelling complex system such as the stock market because it is nonlinear, chaotic, multi-dimensional, and spatial in nature, making forecasting a complex process. Models estimating nonstationary financial time series may include noise and errors. The relationship between the input and output parameters of the models is essentially non-linear, where stock prices include higher-level variables, which complicates stock market modeling and forecasting. It is also revealed that financial time series are multidimensional and they are influenced by many factors, such as economics, politics, environment and so on. Analysis and evaluation of multi-dimensional systems and their forecasting should be carried out by machine learning models.

The problem of forecasting the stock market and obtaining quality forecasts is an urgent task, and the methods and models of machine learning should be the main mathematical tools in solving the above problems. First, we proposed to use self-organizing map, which is used to visualize multidimensional data by configuring neurons to quantize or cluster the input space in the topological structure. These characteristics of this algorithm make it attractive in solving many problems, including clustering, especially for forecasting stock prices. In addition, the methods discussed, encourage us to apply this cluster approach to present a different data structure for forecasting. Thus, models of adaptive neuro-fuzzy inference system combine the characteristics of both neural networks and fuzzy logic.

Given the fact that the rule of hybrid learning and the theory of logic is a clear advantage of adaptive neuro-fuzzy inference system, which has computational advantages over other methods of parameter identification, we propose a new hybrid algorithm for integrating self-organizing map with adaptive fuzzy inference system to forecast stock index prices. This algorithm is well suited for estimating the relationship between historical prices in stock markets. The proposed hybrid method demonstrated reduced errors and higher overall accuracy.