

УДК 338.27

*А. В. Матвійчук*  
д-р екон. наук, доцент*Д. Б. Кайданович**ДВНЗ «Київський національний економічний університет імені Вадима Гетьмана»***РОЗПІЗНАВАННЯ ОБРАЗІВ У СТРУКТУРІ ЦІНОВИХ  
КРИВИХ ТА ПРОГНОЗУВАННЯ ЇХ ПОДАЛЬШОГО  
РОЗВИТКУ ІЗ ЗАСТОСУВАННЯМ НЕЙРОННИХ МЕРЕЖ  
ЗУСТРІЧНОГО РОЗПОВСЮДЖЕННЯ**

Ринкові кризи останнього десятиріччя, зокрема 2000–2003, 2008–2009 років, які принесли інвесторам по всьому світу збитки більш ніж на сто трильйонів доларів, красномовно свідчать про те, що використовувані досі методики та моделі прогнозування розвитку фінансових показників фондового ринку практично вичерпали себе. Проте необхідних висновків із цих криз (перегляд методів прогнозування) дотепер було зроблено недостатньо, що не дозволяє у сучасних умовах ефективно запобігати виникненню нових кризових явищ. Зокрема, О. О. Недосекін охарактеризував період 2000–2002 рр. у світовій економіці як парадигмальний епістемологічний розрив, унаслідок чого взагалі ставиться під сумнів можливість використання ретроспективних даних для отримання прогнозу через якісний перелом ринкових тенденцій [1, с. 9].

Якщо здійснити аналіз причинно-наслідкових зв'язків такої непередбачуваної поведінки фінансових систем як розвинутих країн, так і країн з перехідною економікою, то можна дійти висновків, що, з одного боку, наслідком зазначених різких коливань фінансових показників є неможливість їх адекватного прогнозування із використанням класичних математичних підходів. А з іншого боку, саме зростаюча неспроможність широко розповсюджених економіко-математичних методів і моделей адекватно здійснювати аналіз та прогнозування розвитку фінансово-економічних систем стає однією з головних причин виникнення таких значних криз на фондових ринках. Адже, який інвестор вкладав би кошти в акції, якщо би міг передбачити подальше значне падіння їхнього курсу або виявити значну їх переоцінку, використовуючи адекватні методи фінансового аналізу? Подібна ситуація потребує перегляду математичного апарату, що застосовується в управлінні фінансами, і не лише на фондовому ринку.

Взагалі, для прогнозування реальних фінансових процесів необхідно застосовувати методики, що дозволяють виявляти існуючі функціональні залежності в цих процесах і, ґрунтуючись на цьому, здійснювати прогноз їх розвитку в майбутньому. Ці функціональні залежності у найпростішій постановці визначають за допомогою методів апроксимації, які базуються на припущенні, що для відомих значень прогнозованої змінної  $y(t)$  можна підібрати деяку функцію заданого виду  $\hat{y}(t)$ , яка є близькою у певному сенсі до  $y(t)$  і просто обчислюється. Міра подібності може визначатись, наприклад, за відстанню Евкліда, Махаланобіса, Чебишева, Хеммінга або іншими критеріями.

У процесі вибору математичного інструментарію для побудови моделей прогнозування розвитку показників фондового ринку авторами апробовано досить велику кількість різноманітних підходів і зроблено такі висновки [2]. Було вирішено відмовитись від застосування для прогнозування методів екстраполяції (економетричні моделі, сплайни тощо) через їх сильну чутливість до змін значень фінансових показників, особливо на

краях інтервалу, що розглядається. Для прогнозування курсів цінних паперів не бажано використовувати підходи, які базуються на принципі усереднення, як то математичне сподівання, ковзне середнє, експонентне згладжування або регресійні моделі. Застосування подібних моделей передбачає стаціонарність досліджуваних часових рядів та статистичну незмінність зовнішніх умов, чого насправді у реальній економіці немає. Деякі з цих підходів можна використовувати лише для попередньої обробки даних перед здійсненням прогнозу із застосуванням інших методів.

Ефективним математичним інструментарієм, який останнім часом все частіше застосовується для прогнозування розвитку фінансових показників, є методи штучних нейронних мереж. Здатність нейронних мереж до навчання, можливість працювати з будь-якими даними та відсутність значних бар'єрів для використання нейромережових моделей зробили їх надзвичайно популярними серед трейдерів та науковців [3–19]. Автори статті проаналізували існуючий на сьогодні досвід прогнозування розвитку фінансових показників на підґрунті нейромережових технологій та зробили ряд висновків щодо розроблених на сьогодні моделей. Існуючі підходи ґрунтуються здебільшого на використанні нейронних мереж перцептронного типу із зворотнім поширенням помилки або рекурентних нейронних мереж. Такі нейронні мережі здатні відтворювати складні функціональні залежності між значеннями результуючого показника та пояснюючих змінних моделі. Тобто, прогнозування майбутніх значень фінансового часового ряду здійснюється шляхом виявлення закономірностей від його попередніх значень чи інших факторів.

Зокрема, у роботі [19] запропоновано багатофакторну модель, яка здійснює прогноз значення індексу S&P 500 на наступний день на основі цін шістнадцяти ф'ючерсних контрактів (сім контрактів на товари, шість на іноземні валюти, три на державні цінні папери, бони та облігації) та трьох біржових індексів (DJIA, NYSE Composite Index та S&P 500). В інших наукових роботах чи прикладних програмних продуктах застосовується для прогнозування інший перелік факторів або попередні значення аналізованого індексу чи курсу цінного папера.

Проведений в авторській роботі [2] аналіз результатів експериментів із нейромережовими моделями перцептронного типу засвідчив, що при прогнозуванні вони виявилися позбавленими багатьох недоліків класичних екстраполяційних підходів та продемонстрували значно вищу точність передбачення розвитку фінансових показників. На основі результатів проведеного аналізу було зроблено висновки та надано пропозиції щодо структури і внутрішніх параметрів нейронних мереж та форми подання даних на їхні входи. Проте було виявлено, що прогноз курсу цінних паперів, який отримується з використанням перцептронів, здебільшого практично повторює попереднє значення часового ряду (якщо прогнозування здійснюється лише на основі попередніх значень досліджуваного показника). Точність прогнозу можна підвищити шляхом включення до моделі різних факторів або за рахунок ефективної попередньої обробки даних та пошуку оптимальної конфігурації нейромережі. Якщо робити прогноз на змінах курсів, вдається виключити загальну тенденцію розвитку фінансового показника та залежність від його попереднього значення. Але, у будь-якому разі, правильність угаданих напрямів зміни курсу виявляється дуже низькою — лише трохи більше 50 %.

Проте, створюючи моделі прогнозування фінансових часових рядів, необхідно зважати на те, що переважна більшість учасників торгів на фондовому ринку є спекулятивними гравцями [20], які здійснюють свої вкладення з метою отримання максимального прибутку, а не мінімізації середньоквадратичного відхилення, як це прийнято у випадку апроксимації функцій. І величина прибутку залежатиме у першу чергу від правильності передбачення напрямку зміни курсу, адже гравець фондового ринку отримує дохід здебільшого від гри на пониження-підвищення.

У такому випадку з метою максимізації прибутку від здійснення операцій купівлі-продажу на фондовому ринку з'являються підстави для прогнозування саме напрямів зміни фінансового показника, а не значень самого курсу. У наукових працях [2, 21, 22]

викладено авторський підхід до прогнозування напрямів змін фінансових показників із застосуванням економіко-математичних моделей на нечіткій логіці, база знань яких була сформована з урахуванням правил розвитку ринку з теорії технічного аналізу, зокрема теорії хвиль Елліотта. Побудовані моделі здійснюють передбачення напрямку та відносної величини зміни фінансового показника за рахунок ідентифікації в ціновій кривій відомих хвильових форм, заданих на основі базової восьмихвильової моделі Елліотта та деяких специфічних правил розвитку ринку, таких як подовження, усікання тощо.

Правильність передбачення напрямку зміни індексу S&P 500 із застосуванням побудованої моделі склала 61,9 %, що забезпечило середню прибутковість системи 0,31 % на кожній укладеній угоді (враховуючи й збиткові) без урахування транзакційних витрат. Зазначимо, що це є досить високим показником порівняно з іншими торговими системами та інвестиційними альтернативами [23, 24]. Для вітчизняного фондового індексу ПФТС ефективність роботи розробленої системи виявилась ще вищою — 73,2 % правильності передбачення напрямку зміни індексу. Однак середня прибутковість на кожній угоді становила 0,22 %. Зазначимо, що ці показники ефективності, отримані за умови ґрунтовної попередньої обробки вихідного часового ряду, відсіювання незначних цінових коливань тощо.

Результати проведених експериментів продемонстрували високу ефективність запропонованого підходу на нечіткій логіці до прогнозування напрямків змін аналізованого фінансового показника. Спробуємо ще більше підвищити точність прогнозування подальшої зміни фінансових часових рядів, застосувавши математичний апарат штучних нейронних мереж зустрічного розповсюдження, який є потужним інструментарієм для розпізнавання образів. Зокрема, нейронні мережі зустрічного розповсюдження застосовують для розпізнавання графічних зображень літер абетки та цифр. Так, поданий на входи нейронної мережі графічний образ знаходить своє відображення на двовимірній решітці карти Кохонена шляхом проекції до одного конкретного нейрона. Цей нейрон належить до деякого кластера, який відповідатиме одному із заздалегідь збережених образів літер та цифр. Інтерпретація результату проекції здійснюється шаром Гроссберга, який співвідносить збуджений нейрон карти самоорганізації із конкретним класом (із певною літерою чи цифрою).

Подібного роду класифікацію ми пропонуємо здійснювати для прогнозування розвитку фінансових показників, тільки класами результуючої змінної тут вирішено обрати можливі варіанти зміни аналізованого показника, а вхідними факторами можуть бути, наприклад, значення цього показника протягом кількох попередніх спостережень. У такому випадку досліджуваним образом є динаміка курсу фінансового показника на певному відрізку часу і завданням нейромережі стає розпізнавання цього образу та встановлення класу, якому він відповідає. Подібним чином може діяти досвідчений фінансовий аналітик, який за зовнішнім виглядом цінової кривої здатен з певною вірогідністю передбачати подальший її розвиток. Тільки із застосуванням інструментарію нейронних мереж вдається уникнути суб'єктивності у процесі прийняття рішень.

Нейронна мережа зустрічного розповсюдження (*CounterPropagation Network*) була розроблена Робертом Хехт-Нільсеном [25] як синтез шару генерації (який функціонує за принципом «знизу догори») та шару розпізнавання («зверху донизу»). Для реалізації шару генерації Хехт-Нільсеном було застосовано карту самоорганізації Кохонена (*Kohonen Self-Organizing Map*) [26, 27], а шару розпізнавання — вихідну зірку Гроссберга (*Grossberg Outstar*) [28–30]. Завдяки здатності до самоорганізації шар Кохонена розбиває досліджувані образи на кластери, здійснюючи таким чином розпізнавання і збереження у пам'яті вхідних прикладів. Шар Гроссберга здійснює інтерпретацію результату кластеризації та віднесення поданого образу до одного із встановлених класів змін досліджуваного показника. У такій мережі кожен елемент вектора вхідних даних пов'язаний з усіма нейронами шару Кохонена. У свою чергу, усі нейрони шару Кохонена

мають зв'язки із усіма нейронами шару Гроссберга. Графічно структуру нейронної мережі зустрічного розповсюдження подано на рис. 1.




Рис. 1. Структура нейронної мережі зустрічного розповсюдження

Карта самоорганізації являє собою нейронну мережу без зворотних зв'язків, налаштування параметрів якої здійснюється із застосуванням алгоритму навчання «без учителя» шляхом виявлення невідомих образів та структур у статистичних даних пояснюючих показників досліджуваних об'єктів. Алгоритм навчання забезпечує відображення простору великої розмірності на карту малої розмірності, зберігаючи при цьому її топологічну структуру. Властивість збереження топології означає, що в результаті самоорганізації схожі вектори вхідних даних проєктуються на нейрони, розташовані на карті Кохонена близько один до одного.

Нейрони вхідного шару не здійснюють перетворення вхідних сигналів, вони лише передають їх до усіх елементів карти самоорганізації. Отже, на кожному нейрон шару Кохонена надходить інформація щодо об'єкту дослідження у вигляді вектора  $\mathbf{x}$ , який складається з пояснюючих змінних  $\{x_1, \dots, x_i, \dots, x_n\}$  (наприклад, із  $n$  попередніх значень досліджуваного фінансового показника).

При надходженні на вхідний шар мережі нового вектора даних усі нейрони карти самоорганізації беруть участь у змаганні за право бути переможцем. У результаті такого змагання переможцем стає той нейрон, який більше за інших подібний до вектора вхідних даних. Міра подібності вектора даних до кожного нейрона може бути визначена, наприклад, за Евклідовою відстанню:

$$\|\mathbf{x} - \mathbf{w}^j\| = \sqrt{\sum_{i=1}^n (x_i - w_i^j)^2}, j = \overline{1, K}, \quad (1)$$

де  $\mathbf{x}$  — вектор вхідних даних, що складається з елементів  $\{x_1, \dots, x_i, \dots, x_n\}$ , які описують попередню динаміку зміни фінансового часового ряду;  $\mathbf{w}^j$  — вектор параметрів  $j$ -го нейрона карти Кохонена, який складається з елементів  $\{w_1^j, \dots, w_i^j, \dots, w_n^j\}$ ;  $K$  — кількість нейронів карти Кохонена.

Переможцем у такому змаганні нейронів карти самоорганізації стає один нейрон — більше за інших подібний до вектора вхідних даних за Евклідовою відстанню (1). Його виходом буде одиниця, стани всіх інших нейронів карти самоорганізації прирівнюються до нуля:

Функція (2) реалізує правило конкурентного змагання за принципом «переможець отримує все», яке вперше було запропоновано Гроссбергом у праці [28]. Викладений вище алгоритм визначення нейрона-переможця втілений у структурі карти Кохонена, зображеної на рис. 2.

$$y_j = \begin{cases} 1, & \| \mathbf{x} - \mathbf{w}^j \| = \min_{l=1, K} \| \mathbf{x} - \mathbf{w}^l \|, \\ 0, & \| \mathbf{x} - \mathbf{w}^j \| \neq \min_{l=1, K} \| \mathbf{x} - \mathbf{w}^l \|, \end{cases} j = \overline{1, K}. \quad (2)$$

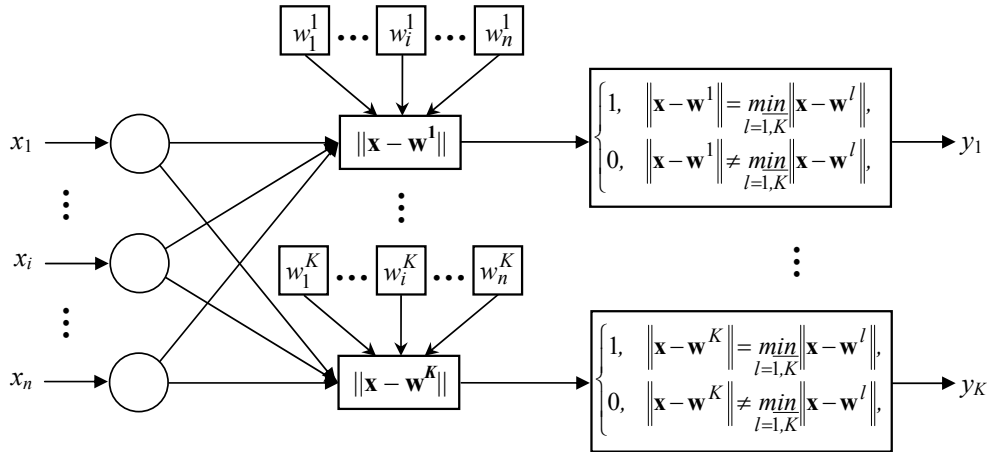


Рис. 2. Деталізована структура карти Кохонена

З метою формування стійких більш-менш однорідних кластерів на карті самоорганізації важливо забезпечити, щоб при топографічному відображенні вектора вхідних даних здійснювалось корегування параметрів не тільки нейрона-переможця, але й найближчих його сусідів. Таким чином відбувається зсув параметрів цілої області нейронів у напрямку вхідного образу. На рис. 3 штриховою лінією на карті самоорганізації виділено топологічну область (*topological neighborhood*) з радіусом в один нейрон навколо нейрона-переможця, яка підлягає корегуванню.

На перших ітераціях навчального алгоритму корегуванню можуть бути піддані всі нейрони карти самоорганізації. У міру проведення навчання розмір топологічної області поступово зменшується і кожний новий вектор вхідних даних здійснює вплив на все меншу кількість нейронів. Наприкінці навчання може здійснюватись модифікація параметрів тільки найближчих сусідів нейрона-переможця, а можливо, лише його самого.

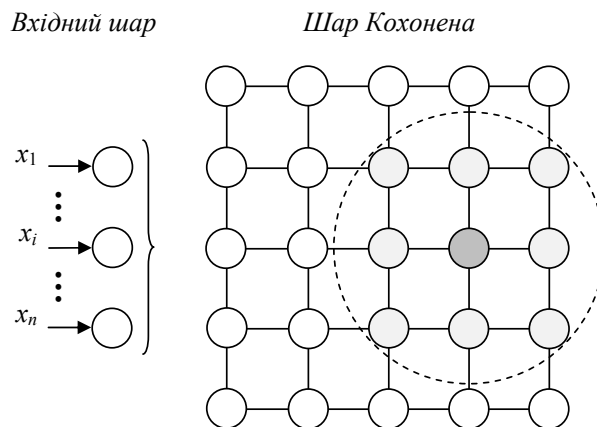


Рис. 3. Спрощена структура карти самоорганізації

Відповідно, після знаходження нейрона-переможця, що є найбільш подібним до вектора вхідних даних, здійснюється коректування його параметрів та найближчих до нього нейронів у деякому околі у напрямку вхідного вектора з урахуванням коефіцієнтів, що визначають темп навчання та відстань до нейрона-переможця:

$$\mathbf{w}^j(t+1) = \mathbf{w}^j(t) + \alpha(t) \cdot h_{oj}(t) \cdot [\mathbf{x}(t) - \mathbf{w}^j(t)], \quad j = \overline{1, K}, \quad (3)$$

де  $\alpha(t)$  — коефіцієнт швидкості навчання ( $0 < \alpha(t) \leq 1$ ), який з кожною епохою навчання  $t$  зменшується;  $h_{oj}$  — сила взаємного впливу для будь-якої пари вузлів  $o$  та  $j$  нейронної мережі.

Вплив вектора вхідних даних на параметри нейронів карти зменшується у міру віддалення від нейрона-переможця та визначається за функцією відстані між відповідними нейронами на топології карти (функцією сусідства), яка може бути представлена, наприклад, гаусовою функцією:

$$h_{oj}(t) = \exp \left[ -\frac{\|\mathbf{r}_o - \mathbf{r}_j\|^2}{2 \cdot \sigma^2(t)} \right], \quad (4)$$

де  $\mathbf{r}_o, \mathbf{r}_j$  — двовимірні вектори локалізації нейрона-переможця  $o$  та  $j$ -го нейрона (координати нейронів на карті);  $\sigma(t)$  — ефективна ширина топологічної області — спеціально підібрана монотонно спадаюча функція часу (наприклад, лінійна або експоненціальна функція, котра зменшується з часом у процесі навчання).

Процедура адаптації нейронів шару Кохонена (3) повторюється у міру подання на входи мережі всіх спостережень  $\mathbf{x}$  з навчальної вибірки. Якщо обсяг вибірки, на якій здійснюється оптимізація параметрів нейронів, є недостатнім для проведення налаштування карти за визначену кількість кроків згідно із встановленим правилом, то необхідно навчальні приклади подавати на входи мережі повторно. Початкові значення параметрів  $\mathbf{w}$  усіх нейронів устанавлюються як малі випадкові величини. На початку процесу налаштування мережі значення фактора швидкості навчання  $\alpha(t)$  задається на рівні близько одиниці (хоча може бути встановлено на рівні 0,5).

Результатом процесу налаштування буде розрахунок параметрів нейронів шару Кохонена, які відповідатимуть різним прикладам з навчальної вибірки. Таким чином здійснюється самоорганізація структури карти Кохонена, яка отримує здатність поєднувати у кластери багатовимірні вектори даних шляхом виявлення в них схожих статистичних характеристик. У результаті початковий простір великої розмірності проектується на двовимірну карту. Оскільки карти самоорганізації характеризуються властивістю узагальнення, то вони можуть розпізнавати вхідні приклади, на яких раніше не налаштовувалися — новий вектор вхідних даних співвідноситься з тим елементом карти, на який він відображається.

Інтерпретацію результатів кластеризації об'єктів дослідження на карті самоорганізації можна здійснити шляхом проведення експертного аналізу, а можна доручити цей процес комп'ютеру, додавши до нейронної мережі після шару Кохонена ще шар розпізнавання. Відповідно, завданням шару Гроссберга стає здійснення відображення виходу шару Кохонена в одне із заздалегідь заданих можливих значень результуючої змінної. Ваги зв'язків між нейронами цих шарів показуватимуть міру відповідності вектора вхідних даних (зведеного в результаті пониження розмірності до єдиного нейрона на карті самоорганізації) кожному з виходів шару Гроссберга. Такими виходами можуть бути наперед устанавлені класи об'єктів дослідження (характеристичні показники яких подаються на входи карти самоорганізації), наприклад, рівні подальшої зміни досліджуваного фінансового показника. Таким чином, налаштування шару Гроссберга здійснюється згідно з принципом навчання «із учителем», у результаті якого кожен нейрон цього шару видаватиме величину ваги зв'язку, що поєднує його з єдиним нейроном карти Кохонена, вихід якого відмінний від нуля.

Корекція ваг зв'язків між нейронами шарів Кохонена і Гроссберга здійснюється згідно з таким алгоритмом. Після опрацювання вектора вхідних даних картою самоорганізації значення нейронів карти передаються до шару Гроссберга (як за звичайного функціонування мережі зустрічного розповсюдження). Далі здійснюється коригування ваг тільки тих міжнейронних зв'язків шару Гроссберга, які сполучені з нейроном-переможцем  $o$  карти самоорганізації (вихід якого відмінний від нуля):

$$w_{og}(t+1) = w_{og}(t) + \beta(t) \cdot [y_g(t) - w_{og}(t)], \quad g = \overline{1, G}, \quad (5)$$

де  $w_{og}(t+1)$ ,  $w_{og}(t)$  — уточнене (скореговане) та попереднє значення ваги зв'язку між нейроном-переможцем  $o$  шару Кохонена та  $g$ -им нейроном шару Гроссберга;  $G$  — кількість нейронів шару Гроссберга;  $y_g(t)$  — відоме значення виходу  $g$ -го нейрона шару Гроссберга, відповідне вектору вхідних даних, поданому на  $t$ -му кроці;  $\beta(t)$  — коефіцієнт швидкості навчання шару Гроссберга ( $0 < \beta(t) \leq 1$ ), що з кожною епохою навчання  $t$  зменшується. У низці досліджень за початкове значення рекомендується брати  $\beta(1) \approx 0,1$ .

Як видно з (5), величина корекції ваги міжнейронного зв'язку пропорційна різниці між цією вагою та реальним значенням виходу відповідного нейрона шару Гроссберга. Так, наприклад, якщо здійснюється розподіл об'єктів на визначені класи, то виходом того нейрона шару Гроссберга, що відповідає класу досліджуваного об'єкта, буде одиниця. Стани інших нейронів шару Гроссберга для такого об'єкта прирівнюються до нуля.

Викладемо результати експериментів з прогнозування змін фінансових показників із застосуванням економіко-математичних моделей, побудованих на нейронних мережах зустрічного розповсюдження, сутність яких полягає у розпізнаванні образів у структурі цінкових кривих з визначенням класів їх подальшої зміни.

Об'єктом дослідження було обрано динаміку розвитку фондового індексу S&P 500. Вихідний часовий ряд було перетворено на вхідні вектори-образи, кожен з яких містить дані за останні п'ять днів, таким чином, що кожний наступний образ починається із другого значення попереднього прикладу, а закінчується його прогнозним значенням. На рис. 4 представлено образ вектору вхідних даних, що містить значення індексу S&P 500 із тестової множини за п'ять днів {1056,89; 996,23; 984,94; 909,92; 899,22}. Значення показника на дату прогнозу — 1003,35, що означає його приріст на рівні 11,58 %.




Рис. 4. Поданий на мережу образ (динаміка індексу S&P 500 за 5 днів) та його подальша зміна

Нейронна мережа розпізнає представлену динаміку та відносить поданий на її входи образ до певного класу, який характеризує зміну фінансового показника наступного дня. Класами результуючої змінної при моделюванні було обрано такі діапазони подальшої зміни показника: перший клас — приріст більше ніж на 4 %; другий — приріст на 1–4 %; третій — незначна зміна показника в діапазоні від –1 % до 1 %; четвертий клас — зменшення показника на 1–4 %; п'ятий — спад індексу більше ніж на 4 %.

Критеріями для вибору класів є потреби розв'язуваної задачі, горизонт прогнозування, характер фінансових даних та результати проведення емпіричного пошуку параметрів, за яких модель демонструватиме найбільшу адекватність. Зокрема, за встановлених вище умов представлений на рис. 4 образ належить до першого класу.

Подібні вхідні вектори для навчання нейронної мережі можна представити у вигляді, зображеному на рис. 5, де кожна лінія відповідає певному образу із масиву даних. Таке розташування вхідних образів відображає динаміку індексу S&P 500, проте з цього рисунка не видно, які з прикладів указують на подальший приріст, які на спад індексу тощо. Відповідно, здійснимо перегрупування множини цих вхідних векторів у вигляді, зручному для виявлення спільних рис у структурі вхідних даних — щоб вектори, які належать до одного результуючого класу, були згруповані разом і відповідним чином представлені графічно.

На рис. 6 наведено розподіл вхідних образів за класами, які відповідають за подальшу зміну аналізованого показника. Ці класи на рисунку позначені римськими цифрами. Першому класу, як указано вище, відповідає множина навчальних прикладів, після яких спостерігалася значне зростання показника. До другого класу, позначеного римською цифрою II, було віднесено образи, після яких відбувалося зростання показника у межах від 1 % до 4 % і т. д.

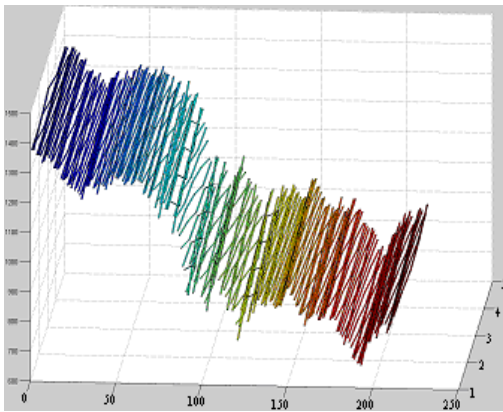


Рис. 5. Множина векторів образів, що подаються на входи нейромережі




Рис. 6. Розподіл навчальних векторів за класами

На рис. 7 представлено результат розпізнавання та узагальнення вхідних векторів шаром Кохонена, де утворені кластери відображають навчальні приклади з подальшою зміною показника від класу падіння до класу зростання. Далі нейрони шару Гроссберга зіставляють відповідні кластери із класами прогнозу зміни фінансового показника.




Рис. 7. Результат розпізнавання вхідних образів картою Кохонена



Під час виконання дослідження було сконструйовано нейронні мережі зустрічного розповсюдження різної конфігурації та проведено значну кількість модельних експериментів з прогнозування змін індексу S&P 500. Відсоток правильно передбачених класів змін досліджуваного показника за встановлених вище діапазонів кожного класу із застосуванням нейронних мереж зустрічного розповсюдження сягав 81 % для тестового масиву прикладів.

З них точність діагностування третього класу (передбачення несуттєвого коливання фінансового показника) доходила аж до 92,1 %. При цьому точність прогнозування подальшого значного зростання курсу (коректного віднесення до класу I або II, за яких доречно здійснювати купівлю цінних паперів) становить 70 %, а точність правильного передбачення істотного спаду фінансового показника (коректного розпізнавання IV та V класу, за яких цінні папери варто продавати) дорівнює 83 %. Загальна точність діагностування подальших суттєвих змін досліджуваного показника, коли є сенс здійснювати купівлю чи продаж цінних паперів (без урахування третього класу результативної ознаки), становила 75 %, що свідчить про надзвичайно високий прибутковий потенціал торговельної системи, розробленої на підґрунті запропонованого підходу.

Рис. 8 ілюструє результат прогнозування індексу S&P 500, отриманий шляхом кількісної інтерпретації класів змін цього індексу, визначених описаною вище нейронною мережею зустрічного розповсюдження. Тут суцільною лінією позначено реальні зміни індексу, а штриховою — результат моделювання.




Рис. 8. Прогнозування індексу S&P 500 на базі нейронної мережі зустрічного розповсюдження

Результати проведених експериментів виявили, що кількість нейронів шару Кохонена та обсяг навчальної вибірки мають істотний вплив на якість прогнозу. Було отримано висновки, що при моделюванні кількість нейронів карти Кохонена повинна бути меншою за кількість вхідних прикладів. Залежність точності прогнозу від обсягу масиву навчальних прикладів має прямо пропорційний характер. У разі незначного обсягу навчальної вибірки, приклади з неї подаються багатократно на входи мережі при оптимізації її параметрів, оскільки зі збільшенням кількості епох навчання точність прогнозу збільшується. Якщо немає помітної зміни у результативності мережі, це означає, що корекція параметрів нейронів уже настільки мала, що може вважатись неістотною — тобто, вже відбулась оптимізація нейромережі.

Також точність класифікації значною мірою залежить від вибору самих образів, на яких навчається нейронна мережа. Нейромережа зустрічного розповсюдження при проведенні оптимізації починає «тяжити» до формування на виході тих сигналів, які найчастіше зустрічаються у множині навчальних прикладів. Початкову статистику бажано формувати так, щоб розподіл вхідних сигналів мав рівномірний характер і містив приблизно у рівній кількості приклади, що відносяться до різних класів результативного показника.

Якщо збільшувати кількість класів, що відображають певний діапазон приросту значень показника, та, відповідно, намагаться таким чином підвищити точність прогнозування, то процент правильно визначених класів зменшується.

Зазначимо, що з метою збільшення адекватності системи необхідно проводити цілеспрямовану оптимізацію її параметрів та відбір тих цінних паперів, курс яких можна спрогнозувати з найвищою точністю. Подібне налаштування системи доцільно здійснювати шляхом вибору часових інтервалів, на яких отримується найбільший прибуток з урахуванням транзакційних витрат, пошуку періодів часу, на яких модель навчається, на яких тестується та на яких буде проводитись реальна торгівля. Подібний аналіз здійснюється з метою визначення слабких сторін системи прогнозування для подальшого її удосконалення та визначення умов, за яких із її застосуванням можна отримати найбільший прибуток.

Але і без цього результати проведених експериментів продемонстрували високу ефективність запропонованого підходу до прогнозування напрямків змін аналізованого фінансового показника, що ґрунтується на застосуванні математичного інструментарію нейронних мереж зустрічного розповсюдження.

Підкреслимо, що основна відмінність розробленого у статті методологічного підходу до моделювання розвитку фінансових показників у порівнянні з альтернативними підходами полягає у вирішенні завдання прогнозування шляхом розпізнавання шаблонних образів у структурі фінансових цінових кривих та віднесення розпізнаних образів до кластерів, які характеризують різні класи зміни досліджуваного показника.

### Література

1. Недосекин А. О. Методологические основы моделирования финансовой деятельности с использованием нечетко-множественных описаний: Дис... докт. экон. наук: 08.00.13 — «Математические и инструментальные методы экономики» / А. О. Недосекин. — СПбГУЭФ. — СПб., 2003. — 280 с.
2. Матвійчук А. В. Штучний інтелект в економіці: нейронні мережі, нечітка логіка : монографія / А. В. Матвійчук. — К. : КНЕУ, 2011. — 439 с.
3. Березький О. Прогнозування курсу акцій за допомогою нейронних мереж / Березький О., Барвінський А., Чирка М. // Вісник Тернопільської академії народного господарства. — 2000. — Вип. 10. — С. 112–117.
4. Головка В. Выбор архитектуры и адаптивное обучение рекуррентной нейронной сети для прогнозирования временных рядов / [Головка В., Савицкий Ю., Саченко А. и др.] // Вісник Тернопільської академії народного господарства. — 2000. — Вип. 10. — С. 37–42.
5. An-Sing Chen. Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index / An-Sing Chen, Mark T. Leung, Hazem Daouk. // Computers & Operations Research. — 2003. — No. 30. — P. 901–923.
6. Gately Ed. Neural Networks for Financial Forecasting / Gately Ed. // Wiley trader's advantage series. — New York: John Wiley & Sons Inc., 1996. — 196 p.
7. Grudnitski G. Forecasting S&P and gold futures prices: an application of neural networks / Grudnitski G., Osburn L. // The Journal of Futures Markets. — 1993. — No. 13. — P. 631–643.
8. Freisleben B. Stock market prediction with backpropagation networks / Freisleben B. // Industrial and Engineering Applications of Artificial Intelligence and Expert System — 5th International Conference in Paderborn, Germany. — 1992. — June. — P. 451–460.

9. Hoptroff R. The principles and practice of time series forecasting and business modelling using neural nets / Hoptroff R. // *Neural Computing and Applications*. — 1993. — No. 1. — P. 59–66.
10. Hu M. Y. E. A cross-validation analysis of neural network out-of-sample performance in exchange rate forecasting / Hu M. Y., Zhang G., Jiang C., Patuwo B. // *Decision Sciences*. — 1999. — No. 30. — P. 197–216.
11. Jingtao Yao. Neural networks for technical analysis: a study on KLCI / Jingtao Yao, Chew Lim Tan, Hean-Lee Poh. // *International Journal of Theoretical and Applied Finance*. — 1999. — Vol. 2. — No. 2. — 221–241.
12. Kim S. Graded forecasting using an array of bipolar predictions: application of probabilistic neural networks to a stock market index / Kim S., Chun S. // *International Journal of Forecasting*. — 1998. — No. 14 (3). — P. 323–337.
13. Lean Yu. A neural-network-based nonlinear metamodeling approach to financial time series forecasting / Lean Yu, Shouyang Wang, Kin Keung Lai. // *Applied Soft Computing*. — 2009. — No. 9. — P. 563–574.
14. Lee T. H. Forecasting creditworthiness: Logistic vs. artificial neural net / Lee T. H., Jung S. // *The Journal of Business Forecasting Methods and Systems*. — 2000. — No. 18 (4). — P. 28–30.
15. Leigh W. Forecasting the NYSE composite index with technical analysis, pattern recognizer, neural network, and genetic algorithm: a case study in romantic decision support / Leigh W., Purvis R., Ragusa J. M. // *Decision Support Systems*. — 2002. — No. 32. — P. 361–377.
16. Saad E. Comparative study of stock trend prediction using time delay, recurrent and probabilistic neural networks / Saad E., Prokhorov D., Wunsch D // *IEEE Transactions on Neural Networks*. — 1998. — No. 9. — P. 1456–1470.
17. Zhang G. Forecasting with artificial neural networks: the state of the art / Zhang G., Patuwo B., Hu M. // *International Journal of Forecasting*. — 1998. — No. 14. — P. 35–62.
18. Gately E. *Neural networks for financial forecasting* / E. Gately. — New York: Wiley, 1996. — 169 p.
19. Shaikh A. Hamid. Using neural networks for forecasting volatility of S&P 500 Index futures prices / Shaikh A. Hamid, Zahid Iqbal // *Journal of Business Research*. — 2004. — No. 57. — P. 1116–1125.
20. Брюзгин А. Вольные размышления на тему трейдинга / Брюзгин А. // *Валютный спекулянт*. — 2002. — № 6. — С. 84–89.
21. Матвійчук А. В. Ідентифікація та прогнозування розвитку фінансових показників за підходами нечіткої логіки / Матвійчук А. В. // *Економіка і прогнозування*. — 2005. — № 4. — С. 114–126.
22. Matviychuk A. Fuzzy logic approach to identification and forecasting of financial time series using Elliott wave theory / A. Matviychuk // *Fuzzy Economic Review*. — 2006. — November. — Vol. XI. — No. 2. — P. 51–68.
23. Джусов А. Международное инвестирование: выбор благоприятного экономического пространства, фондовых активов и тестирование торговых систем / Джусов А. // *Журнал европейской экономики*, 2003. — Т. 2. — № 4. — С. 468–490.
24. Пардо Р. Разработка, тестирование и оптимизация торговых систем для биржевого трейдера / Р. Пардо ; пер. с английского А. Полесчука. — М. : Минакс, 2002. — 224 с.
25. Hecht-Nielsen R. Counterpropagation networks / Hecht-Nielsen R. // *Proceedings of the IEEE First International Conference on Neural Networks* (M. Caudill and C. Butler, eds.). — San Diego, CA: SOS Printing. — 1987. — Vol. 2. — P. 19–32.
26. Kohonen T. The self-organizing map / Kohonen T. // *Proceedings of the Institute of Electrical and Electronics Engineers*, 1990. — Vol. 78. — P. 1464–1480.
27. Kohonen T. Self-organized formation of topologically correct feature maps / Kohonen T. // *Biological Cybernetics*, 1982. — Vol. 43. — P. 59–69.
28. Grossberg S. Some networks that can learn, remember and reproduce any number of complicated space-time patterns / Grossberg S. // *Journal of Mathematics and Mechanics*. — 1969. — No. 19. — P. 53–91.
29. Grossberg S. Embedding fields: Underlying philosophy, mathematics, and applications of psychology, physiology, and anatomy / Grossberg S. // *Journal of Cybernetics*. — 1971. — No. 1. — P. 28–50.
30. Grossberg S. How does a brain build a cognitive code / Grossberg S. // *Psychological Review*. — 1980. — Vol. 87. — P. 1–51.