

Розробка алгоритму навчання штучних нейронних мереж для інтелектуальних систем підтримки прийняття рішень

О. Я. Сова, О. В. Турінський, А. В. Шишацький, В. П. Дудник,
Р. М. Животовський, Є. М. Прокопенко, Т. Г. Гурський, В. В. Гордійчук,
А. П. Нікітенко, А. В. Ремез

Розроблено алгоритм навчання штучних нейронних мереж для інтелектуальних систем підтримки прийняття рішень. Відмінна особливість запропонованого алгоритму полягає в тому, що він проводить навчання не тільки синаптичних ваг штучної нейронної мережі, але й виду та параметрів функції належності. В разі неможливості забезпечити задану якість функціонування штучних нейронних мереж за рахунок навчання параметрів штучної нейронної мережі відбувається навчання архітектури штучних нейронних мереж. Вибір архітектури, виду та параметрів функції належності відбувається з врахуванням обчислювальних ресурсів засобу та з врахуванням типу та кількості інформації, що надходить на вхід штучної нейронної мережі. Також при використанні запропонованого алгоритму не відбувається накопичення помилки навчання штучних нейронних мереж в результаті обробки інформації, що надходить на вхід штучних нейронних мереж.

Розробка запропонованого алгоритму обумовлена необхідністю проведення навчання штучних нейронних мереж для інтелектуальних систем підтримки прийняття рішень, з метою обробки більшої кількості інформації, при однозначності рішень, що приймаються. За результатами дослідження встановлено, що зазначений алгоритм навчання забезпечує в середньому на 16–23 % більшу високу ефективність навчання штучних нейронних мереж та не накопичує помилок в ході навчання. Зазначений алгоритм дозволить проводити навчання штучних нейронних мереж; визначити ефективні заходи для підвищення ефективності функціонування штучних нейронних мереж. Також розроблений алгоритм дозволить підвищити ефективність функціонування штучних нейронних мереж за рахунок навчання параметрів та архітектури штучних нейронних мереж. Запропонований алгоритм зменшує використання обчислювальних ресурсів систем підтримки та прийняття рішень. Використання розробленого алгоритму дозволить виробити заходи, що спрямовані на підвищення ефективності навчання штучних нейронних мереж, та підвищити оперативність обробки інформації

Ключові слова: штучні нейронні мережі, синаптичні ваги, функція належності, обробка інформації, інтелектуальні системи підтримки прийняття рішень

1. Вступ

Системи підтримки прийняття рішень (СППР) активно використовуються в усіх сферах життєдіяльності людей. Особливого поширення вони отримали

при обробці великих масивів даних, забезпечення інформаційної підтримки процесу прийняття рішень особами, що приймають рішення.

Створення інтелектуальних СППР стало природним продовженням широкого застосування СППР класичного типу. Інтелектуальні СППР забезпечують інформаційну підтримку всіх виробничих процесів і служб підприємств (організацій, установ). За допомогою інтелектуальних СППР проводиться проектування, виготовлення і збут продукції, фінансово-економічний аналіз, планування, управління персоналом, маркетинг, супровід створення (експлуатації, ремонту) виробів та перспективне планування. Також зазначені інтелектуальні СППР знайшли широке використання для вирішення специфічних завдань військового призначення, а саме [1, 2]:

- планування розгортання, експлуатації систем зв'язку та передачі даних;
- автоматизація управління військами та зброєю;
- збір, обробка та узагальнення розвідувальних відомостей про стан об'єктів розвідки та інш.

Умовно структуру інтелектуальних СППР умовно можна розділити на 4 великі шари:

- шар інтерфейсу (інтерактивність та візуалізація);
- шар моделювання (статистичні моделі та машинне навчання; числові моделі; моделі на основі теорії ігор та інш.)
- шар обробки даних (організація потоку даних, робота з базами даних та експертні оцінки);
- шар збору даних (веб сканування, сенсори та інтерфейс програмування).

Одним зі шляхів підвищення ефективності систем підтримки прийняття рішень є впровадження штучних нейронних мереж на всіх рівнях їх функціонування.

2. Аналіз літературних даних та постановка проблеми

Аналіз досвіду створення інтелектуальних СППР показує, що найбільш перспективною для побудови є інформаційна технологія, заснована на нейромережевому моделюванні [1–8], зокрема на застосуванні еволюційного підходу до побудови ШНМ [4, 5], які використовуються на кожному з шарів інтелектуальних СППР.

Застосування еволюційного підходу до побудови нейронних мереж в порівнянні з традиційними підходами дає наступні переваги:

- здатність швидкої адаптації до предметної галузі, що практично без будь-яких перетворень дає можливість сформувати структуру ШНМ, яка відповідає цьому процесу;
- здатність до швидкого навчання; на основі моделей нейронів з відповідними порогами, вагами і передаточними функціями, при яких вже в першому наближенні будується навчена ШНМ;
- здатність працювати в умовах невизначеності, нелінійності, стохастичності та хаотичності, різного роду збурювань і завад;
- мають як універсальні апроксимуючі властивості, так і можливості нечіткого виводу.

ШНМ, що еволюціонують, одержали широке поширення для розв'язку різних завдань інтелектуального аналізу даних, ідентифікації, емуляції, прогнозування, інтелектуального управління та т. п. на кожному з шарів інтелектуальних СППР.

Незважаючи на досить успішне їхнє застосування для розв'язку широкого кола завдань інтелектуального аналізу даних, ці системи мають ряд недоліків, пов'язаних з їхнім використанням.

Серед найбільш істотних недоліків можна виділити такі:

1. Складність вибору архітектури системи. Як правило, модель, заснована на принципах обчислювального інтелекту, має фіксовану архітектуру. У контексті ШНМ це означає, що нейронна мережа має фіксовану кількість нейронів і зв'язків. У зв'язку із цим, адаптація системи до нових даних, що надходять на обробку, що мають відмінну від попередніх даних природу, може виявитися проблематичним.

2. Навчання в пакетному режимі та навчання протягом декількох епох вимагає значних часових ресурсів. Такі системи не є пристосовані для роботи в online режимі з досить високим темпом надходження нових даних на обробку.

3. Багато з існуючих систем обчислювального інтелекту не можуть визначати правила, що еволюціонують, по яких відбувається розвиток системи, а також можуть представляти результати своєї роботи в термінах природньої мови.

Таким чином, актуальним є завдання розробки нових алгоритмів навчання для ШНМ, які дозволять вирішити зазначені труднощі.

Проведений аналіз наукових досліджень [1–10] свідчить про те, що на даний час основою існуючих СППР становлять методи штучного інтелекту.

В роботі [3] проведено аналіз властивостей ШНМ, які використовувалися при прогнозуванні концентрації забруднюючих речовин повітря. В роботі акцентовувалася увага на те, що ШНМ мають низьку швидкість конвергенції та локальний мінімум. Запропоновано використання екстремальної навчальної машини для ШНМ, що забезпечує високу ефективність узагальнення при надзвичайно високій швидкості навчання. До недоліків зазначеного підходу слід віднести накопичення помилок ШНМ в ході проведення обчислень, неможливість вибору параметрів та типу функції належності.

В роботі [5] наведено оперативний підхід з просторового аналізу в морській галузі для кількісної оцінки та відображення супутніх екосистемних послуг. Такий підхід охоплює тривимірність морського середовища, розглядаючи окремо всі морські області (морська поверхня, водяний стовп та морське дно). Фактично, метод будує 3-вимірні моделі моря шляхом оцінки та картографування, що пов'язані з кожним із трьох морських доменів через прийняття репрезентативних показників. До недоліків зазначеного методу слід віднести неможливість гнучкого налаштування (адаптації) оціночних моделей при додаванні (виключенні) показників і зміні їх параметрів (сумісності та значущості показників).

В роботі [6] представлена модель машинного навчання для автоматичної ідентифікації запитів та надання інформаційних служб підтримки, що обмінюються між членами інтернет-спільноти. Зазначена модель призначена для обробки великої кількості повідомлень користувачів соціальних мереж. Недоліками зазначеної моделі є відсутність механізмів оцінки адекватності рішень, що приймаються та велика обчислювальна складність.

В роботі [7] представлено використання ШНМ для виявлення аномалії серцевого ритму та інших захворювань серця. В якості методу навчання ШНМ використовується алгоритм зворотного поширення помилки. Недоліками зазначеного підходу є його обмеженість навчанням лише синаптичних ваг, без навчання виду та параметрів функції належності.

В роботі [8] представлено використання ШНМ для виявлення сходження лавин. В якості методу навчання ШНМ використовується алгоритм зворотного поширення помилки. Недоліками зазначеного підходу є його обмеженість навчанням лише синаптичних ваг, без навчання виду та параметрів функції належності.

В роботі [9] представлено використання ШНМ для виявлення проблем виявлення аномалій в системах домашньої авторизації. В якості методу навчання ШНМ Кохонена використовується алгоритм “переможець отримує все”. Недоліками зазначеного підходу є накопичення помилки в процесі навчання, обмеженість навчанням лише синаптичних ваг, без навчання виду та параметрів функції належності.

В роботі [10] представлено використання ШНМ для виявлення проблем виявлення аномалій в енцефалограмі людини. В якості методу навчання ШНМ використовується метод тонкого налаштування параметрів ШНМ. Недоліками зазначеного підходу є накопичення помилки в процесі навчання, обмеженість навчанням лише синаптичних ваг, без навчання виду та параметрів функції належності.

В роботі [12] представлено використання методів машинного навчання, а саме ШНМ та генетичних алгоритмів. В якості методу навчання ШНМ використовується генетичний алгоритм. Недоліками зазначеного підходу є його обмеженість навчанням лише синаптичних ваг, без навчання виду та параметрів функції належності.

В роботі [13] представлено використання методів машинного навчання, а саме ШНМ та методу диференційного пошуку. В ході дослідження проведено розробку гібридного методу навчання ШНМ, що заснований на використанні алгоритму зворотного поширення помилки та диференційного пошуку. Недоліками зазначеного підходу є його обмеженість навчанням лише синаптичних ваг, без навчання виду та параметрів функції належності.

В роботі [14] проведено розробку методів навчання ШНМ з використанням комбінованої апроксимації поверхні відгуку, який забезпечує найменші похибки навчання і прогнозування. Недоліком зазначеного методу накопичення помилки в ході навчання та неможливість зміни архітектури ШНМ в ході навчання.

В роботі [15] наведено використання ШНМ для оцінки ефективності роботи агрегату, використовуючи попередній часовий ряд його продуктивності. Для навчання ШНМ використовуються моделі SBM (Stochastic Block Model) та DEA (Data Envelopment Analysis). Недоліками зазначеного підходу є обмеженість в виборі архітектури мережі, навчання тільки синаптичних ваг.

В роботі [16] наведено використання ШНМ для оцінки геомеханічних властивостей. В якості методу навчання ШНМ використовується алгоритм зворотного поширення помилки. Покращення характеристик алгоритму зворотнього поширення помилки досягається за рахунок збільшення навчальної вибірки.

Недоліками зазначеного підходу є його обмеженість навчанням лише синаптичних ваг, без навчання виду та параметрів функції належності.

В роботі [17] наведено використання ШНМ для оцінки інтенсивності дорожнього руху. В якості методу навчання ШНМ використовується алгоритм зворотного поширення помилки. Покращення характеристик алгоритму зворотного поширення помилки досягається за рахунок використання пропускових зв'язків між кожним шаром, так що кожен шар викладає лише залишкову функцію щодо результатів попереднього шару. Недоліками зазначеного підходу є його обмеженість навчанням лише синаптичних ваг, без навчання виду та параметрів функції належності.

Проведення аналізу наукових праць [1–17] показало, що відомі методи навчання штучних нейронних мереж мають наступні недоліки:

- не здатні адаптувати архітектуру штучних нейронних мереж в залежності від кількості вхідної інформації (кількості шарів, кількості скритих шарів, кількості зв'язків між нейронами у шарі та між шарами);
- не здатні адаптувати параметри функції належності в залежності від обчислювальних ресурсів;
- обмежені лише навчанням синаптичних ваг або видом функції належності;
- накопичують помилку навчання в ході навчання, що призводить до збільшення помилки навчання з часом роботи;
- вимагають великого об'єму навчальної вибірки;
- не здатні проводити навчання в режимі реального часу, а лише в пакетному режимі (з певним часовим інтервалом затримки реакції).

Проведений аналіз свідчить про те, що підвищення ефективності систем підтримки прийняття рішень можливо досягти шляхом розробки науково-методичного апарату навчання штучних нейронних мереж, як основи інтелектуальних систем підтримки.

Зазначене дозволить:

- збільшити кількість інформації, що спроможні обробити штучні нейронні мережі;
- підвищити достовірність прийняття рішення інтелектуальними системами підтримки прийняття рішень;
- прийняття швидкість адаптації архітектури та параметрів штучних нейронних мереж відповідно до завдань, що виникають;
- не допустити тупикових ситуацій під час навчання штучних нейронних мереж;
- забезпечити передбачаємість процесу навчання штучних нейронних мереж;
- забезпечити однозначність рішень, що приймаються інтелектуальними системами підтримки прийняття рішень.

3. Мета та завдання дослідження

Метою дослідження є розробка алгоритму навчання штучних нейронних мереж для інтелектуальних систем підтримки прийняття рішень, який дозволяє виконувати обробку більшої кількості інформації, при однозначності рішень, що приймаються.

Для досягнення мети були поставлені такі завдання:

- провести формалізацію завдання навчання штучних нейронних мереж;
- визначити порядок навчання штучних нейронних мереж з урахуванням недоліків існуючих підходів з подальшою розробкою алгоритму;
- оцінити розроблений алгоритм.

4. Формалізація завдання навчання штучних нейронних мереж

З метою визначення порядку роботи алгоритмів навчання штучних нейронних мереж в зазначеному розділі дослідження наведено узагальнений алгоритм навчання штучних нейронних мереж. Алгоритм навчання штучних нейронних мереж в подальшому буде удосконалено.

Архітектура, багатошарової нейро-фаззі системи, що еволюціонує, наведена на рис. 1 та складається з п'яти послідовних шарів.

На вхідний (нульовий) шар нейро-фаззі системи подається $(n \times 1)$ -мірний вектор сигналів-образів $x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T$ (тут $k = 1, 2, \dots$ – поточний дискретний час), що підлягають обробці.

Перший прихований шар містить nh функцій належності, $\mu_{li}(x_i)$, $i = 1, 2, \dots, n$; $l = 1, 2, \dots, h$. Таким чином, для кожного входу задається h функцій належності. Перший прихований шар виконує фазифікацію вхідного простору. При цьому мається на увазі, що в процесі навчання-еволюції повинні настроюватися як власне параметри цих функцій, так і їх число: на рис. 1 – кількість вузлів першого прихованого шару μ_h .

Другий прихований шар забезпечує агрегування рівнів належності, розрахованих у першому прихованому шарі, і складається з h блоків множення.

Третій прихований шар – це шар, що настроює синаптичні ваги $w_1, w_2, \dots, w_h$, які підлягають визначенню в процесі контрольованого навчання.

Четвертий прихований шар утворено двома суматорами, що обчислює суми вихідних сигналів другого та третього прихованого шарів.

І, нарешті, в п'ятому (вихідному) шарі проводиться дефазифікація, у результаті якої обчислюється вихідний сигнал NFS (neuro-fuzzy system) $\hat{y}(k)$.

Таким чином, якщо на вхід нейро-фаззі системи поданий векторний сигнал $x(k)$, елементи першого прихованого шару роблять його фазифікацію, обчислюючи рівні належності $0 < \mu_{li}(x_i(k)) \leq 1$. Звичайно в якості функцій належності використовуються традиційні гаусіани

$$\mu_{li}(x_i(k)) = \exp\left(-\frac{(x_i(k) - c_{li})^2}{2\sigma_i^2}\right), \quad (1)$$

де c_{li} – параметр центру l -ї функції належності i -го входу; σ_i – параметр ширини функції належності i -го входу.

Варто відзначити, що попереднє нормування даних на деякий інтервал, наприклад, $-1 \leq x_i(k) \leq 1$ дозволяє спростити розрахунки, оскільки параметри ширини σ_i можуть бути прийняті однаковими для всіх входів, тобто $\sigma_i = \sigma$ (зазначені показники визначаються на етапі проектування СППР).

Крім гаусіанів (1) можуть бути використані й інші ядерні функції, наприклад, В-сплайни, що відповідають умові одиначної розбивки, парні вейвлети, гнучкі функції активації-належності [18, 19] та інш.




Рис. 1. Архітектура, багатошарової нейро-фаззі системи, що еволюціонує

У другому прихованому шарі обчислюються агреговані значення $\prod_{i=1}^n \mu_{li}(x_i(k))$, при цьому для гаусіанів з однаковими параметрами ширини:

$$\prod_{i=1}^n \mu_{li}(x_i(k)) = \prod_{i=1}^n \exp\left(-\frac{(x_i(k) - c_{li})^2}{2\sigma^2}\right) = \exp\left(-\frac{\|x(k) - c_l\|^2}{2\sigma^2}\right),$$

де $c_l = (c_{l1}, c_{l2}, \dots, c_{ln})^T$.

Таким чином, сигнали на виходах блоків множення другого прихованого шару аналогічні сигналам на виходах нейронів першого прихованого шару звичайних радіально-базисних нейронних мереж (RBFN – Radial basis function networks) [20].

Виходами третього прихованого шару є значення $w_l \prod_{i=1}^n \mu_{li}(x_i(k))$, четвертого – $\sum_{l=1}^h w_l \prod_{i=1}^n \mu_{li}(x_i(k))$ і $\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k))$, нарешті, на виході системи (п'ятого вихідного шару) з'являється сигнал

$$\begin{aligned} \hat{y}(x(k)) &= \frac{\sum_{l=1}^h w_l \prod_{i=1}^n \mu_{li}(x_i(k))}{\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k))} = \sum_{l=1}^h w_l \frac{\prod_{i=1}^n \mu_{li}(x_i(k))}{\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k))} = \\ &= \sum_{l=1}^h w_l \phi_l(x(k)) = w^{hT} \phi^h(x(k)), \end{aligned}$$

де

$$\phi_l(x(k)) = \frac{\prod_{i=1}^n \mu_{li}(x_i(k))}{\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k))},$$

$$w^h = (w_1, w_2, \dots, w_h)^T,$$

$$\phi^h(x(k)) = (\phi_1(x(k)), \phi_2(x(k)), \dots, \phi_h(x(k)))^T.$$

Нескладно помітити, що розглянута система реалізує нелінійне відображення вхідного простору в скалярний вихідний сигнал $(R^n \rightarrow R^1)$ подібно нормалізованої RBFN [21], а по архітектурі (при фіксованому h) збігається з TSK-системою (Takagi, Sugeno, Kang'a) нульового порядку, тобто архітектурою Ванга–Менделя [22].

5. Порядок навчання штучних нейронних мереж з урахуванням недоліків існуючих підходів з подальшою розробкою алгоритму

На рис. 2 наведений запропонований алгоритм навчання штучної нейронної мережі. Удосконалення зазначеного алгоритму навчання полягає в додаванні дій 5, 7, 8 до відомих методів навчання штучних нейронних мереж. Тобто відбувається додатково навчання штучних нейронних мереж, що не було враховано в роботах [1–17]:

– архітектури штучних нейронних мереж в залежності від кількості вхідної інформації (кількості шарів, кількості скритих шарів, кількості зв'язків між нейронами у шарі та між шарами);

– кількості та параметрів функції належності.

Початковим етапом є введення вихідних даних, а саме початкової архітектури та параметрів штучної нейронної мережі (етап 1–4).

Етап 1. Визначення кількості шарів в штучній нейронній мережі.

Етап 2. Визначення кількості вузлів в шарі штучної нейронної мережі.

Етап 3. Визначення кількості зв'язків між шарами та вузлами штучної нейронної мережі.

Етап 4. Визначення кількості скритих шарів штучної нейронної мережі.

Етап 5. Визначення кількості та параметрів функції належності (ФН).

Етап 6. Визначення синаптичних ваг зв'язків штучної нейронної мережі.

Етап 7. Перевірка відповідності архітектури та параметрів штучної нейронної мережі вимогам, що висуваються.

Етап 8. Прийняття рішення на корегування архітектури та параметрів штучної нейронної мережі.

Розглянемо докладно етапи запропонованого алгоритму навчання.

Етап 5. Налаштування параметрів і кількості функцій належності.

Процес налаштування параметрів і кількості функцій належності відбувається в такий спосіб. Нехай на вхід системи, у якій в вихідному стані в першому прихованому шарі відсутні функції належності, надходить перше спостереження навчальної вибірки $x(1) = (x_1(1), x_2(1), \dots, x_n(1))^T$.

Це спостереження формує перший вузол першого прихованого шару μ_1 так, що $c_{1i}(1) = x_i(1)$. У такий спосіб створюється n функцій належності й формується єдина синаптична вага $w_1(0)$, що задається випадково в інтервалі $-1 \leq w_1(0) \leq 1$.

Далі для цієї функції належності μ_1 задається радіус сусідства r , обумовлений максимально можливим числом функцій належності в NFS h . Так, якщо функції належності по осях розподілені рівномірно, то

$$r = \frac{2}{h-1}. \quad (2)$$

Далі при надходженні другого спостереження $x(2)$ проводиться перевірка умови

$$\max_i |c_{1i} - x_i(2)| \leq r. \quad (3)$$

Якщо ця умова виконується, то проводиться корекція центрів функцій належності вузла μ_1 згідно із правилом

$$c_{1i}(2) = c_{1i}(1) + \eta(2)(x_i(2) - c_{1i}(1)), \quad (4)$$

де η – параметр кроку навчання.




Рис. 2. Алгоритм функціонування та навчання штучної нейронної мережі, що еволюціонує

Таким чином, при $\eta(2) = 0,5$

$$c_{1i}(2) = \frac{c_{1i}(1) + x_i(2)}{2}. \quad (5)$$

У тому випадку, якщо умова (3) не виконується, то формується другий вузол μ_2 функцій належності першого прихованого шару, центри яких

$$c_{2i}(2) = x_i(2). \quad (6)$$

Одночасно з вузлом μ_2 в NFS вводиться друга синаптична вага w_2 , що також задається випадковим чином.

Нехай до моменту надходження на вхід NFS спостереження $x(k)$ сформоване p вузлів функцій належності $\mu_1, \mu_2, \dots, \mu_p$, $p < h$, із центрами $c_{li}(k-1)$, $l = 1, 2, \dots, p$; $i = 1, 2, \dots, n$. Із надходженням $x(k)$ проводиться перевірка умови

$$\max_i |c_{li} - x_i(k)| \leq r \forall l = 1, 2, \dots, p. \quad (7)$$

Якщо ця умова виконується, то проводиться корекція центрів функцій належності, найближчих до відповідних компонентів $x(k)$ відповідно до правила

$$c_{li}(k) = c_{li}(k-1) + \eta(k)(x_i(k) - c_{li}(k-1)). \quad (8)$$

Нескладно помітити, що (8) є не що інше, як правило самонавчання Т. Кохонена “Переможець одержує все” [23] з тою лише різницею, що самонавчання карти Кохонена реалізується на гіперсфері

$$\|x(k)\|_2 = 1, \quad (9)$$

а правило (8) – на гіперкубі

$$\|x(k)\|_\infty = 1. \quad (10)$$

У тому випадку, якщо умова (7) не виконується, у системі формується $(p+1)$ вузол $(p+1 \leq h)$ із центрами функцій належності

$$c_{p+1,i}(k) = x_i(k). \quad (11)$$

Одночасно з вузлом μ_{p+1} формується синаптична вага w_{p+1} .

Як видно, зазначена процедура є гібридним алгоритмом, що еволюціонує Н. Касабова [24] та карти, що самоорганізовується Т. Кохонена [23]. При цьому процес еволюції архітектури-самонавчання функцій належності може відбуватися як безперервно, так і до досягнення числа функцій належності.

Настроювання параметрів центру й ширини функцій належності може проводитися по алгоритму із вчителем, заснованому на мінімізації цільової функції. Настроювання, як правило, задається з використанням евклідової норми та для однієї пари навчальних даних $(x(k), y(k))$ що має вид

$$E(k) = \frac{1}{2}(y(k) - \hat{y}(k))^2 = \frac{1}{2}(y(k) - w^T \phi(x(k)))^2. \quad (12)$$

При застосуванні методу найшвидшого спуска відповідні формули адаптації в загальному випадку для $(n \times 1)$ -мірного вектора вхідних сигналів приймає вид

$$c_{rj}(k+1) = c_{rj}(k) - \eta_c \frac{\partial E(k)}{\partial c_{rj}}, \quad (13)$$

$$\sigma_{rj}(k+1) = \sigma_{rj}(k) - \eta_\sigma \frac{\partial E(k)}{\partial \sigma_{rj}}, \quad (14)$$

де η_c – параметр кроку навчання для параметрів центру функції належності; η_σ – параметр кроку навчання для параметра ширини функції належності; $r = 1, 2, \dots, h$, $j = 1, 2, \dots, n$.

Для спрощення розрахунків похідних і прискорення обчислення значення функції належності формула адаптації параметра ширини може бути записана у вигляді

$$-0.5\sigma_{rj}^{-2}(k+1) = \sigma_{rj}(k) - \eta_\sigma \frac{\partial E(k)}{\partial (-0.5\sigma_{rj}^{-2})}. \quad (15)$$

При використанні в якості функцій належності традиційних гаусіанів (9) відповідні формули градієнта цільової функції (12) для однієї пари навчальних даних приймає вигляд

$$\frac{\partial E(k)}{\partial c_{rj}} = (w^T \phi(x(k)) - (x(k))) \times \sum_{l=1}^h w_l \frac{\partial \phi_l(x(k))}{\partial c_{rj}}, \quad (16)$$

$$\frac{\partial E(k)}{\partial (-0.5\sigma_{rj}^{-2})} = (w^T \phi(x(k)) - y(x(k))) \times \sum_{l=1}^h w_l \frac{\partial \phi_l(x(k))}{\partial (-0.5\sigma_{rj}^{-2})}, \quad (17)$$

де

$$\varphi_l(x(k)) = \frac{\prod_{i=1}^n \mu_{li}(x_i(k))}{\sum_{p=1}^h \prod_{i=1}^n \mu_{pi}(x_i(k))}. \quad (18)$$

Похідні

$$\frac{\partial \varphi_l(x)}{\partial c_{rj}}$$

і

$$\frac{\partial \varphi_l(x)}{\partial (-0.5\sigma_{rj}^{-2})},$$

визначені на основі (9) і (18), можна записати як

$$\frac{\partial \varphi_l(x)}{\partial c_{rj}} = \frac{\delta_{lr} m(x) - t_l(x)}{(m(x))^2} \times \prod_{i=1, i \neq j}^n \mu_{ri}(x_i) \frac{\partial \mu_{ri}(x_j)}{\partial c_{rj}}, \quad (19)$$

$$\frac{\partial \varphi_l(x)}{\partial (-0.5\sigma_{rj}^{-2})} = \frac{\delta_{lr} m(x) - t_l(x)}{(m(x))^2} \times \prod_{i=1, i \neq j}^n \mu_{ri}(x_i) \frac{\partial \mu_{ri}(x_j)}{\partial (-0.5\sigma_{rj}^{-2})}, \quad (20)$$

де δ_{lr} – дельта Кронекера,

$$t_l(x) = \prod_{i=1}^n \mu_{li}(x_i),$$

$$m(x) = \sum_{p=1}^h \prod_{i=1}^n \mu_{pi}(x_i).$$

Похідні

$$\frac{\partial \mu_{rj}(x_j)}{\partial c_{rj}}$$

та

$$\frac{\partial \mu_{rj}(x_j)}{\partial (-0.5\sigma_{rj}^{-2})},$$

визначені на основі (9), можна записати як

$$\frac{\partial \mu_{rj}(x_j)}{\partial c_{rj}} = \frac{x_j - c_{rj}}{\sigma_{rj}^2} \exp\left(-\frac{(x_j - c_{rj})^2}{2\sigma_{rj}^2}\right), \quad (21)$$

$$\frac{\partial \mu_{ri}(x_j)}{\partial (-0.5\sigma_{rj}^{-2})} = (x_j - c_{rj})^2 \exp\left(-\frac{(x_j - c_{rj})^2}{2\sigma_{rj}^2}\right). \quad (22)$$

Етап 6. Визначення синаптичних ваг зв'язків штучної нейронної мережі.

Як вже відзначалося, для настроювання синаптичних ваг нейро-фаззі системи можуть бути використані відомі алгоритми навчання-ідентифікації [26, 27]:

– експоненціально-зважений рекурентний метод найменших квадратів;

$$\left\{ \begin{aligned} w^h(k) &= w^h(k-1) + \\ &+ \frac{P^h(k-1)(y(k) - w^{hT}(k-1)\phi^h(x(k)))}{\beta + \phi^{hT}(x(k))P^h(k-1)\phi^h(x(k))} \phi^h(x(k)) = \\ &= w^h(k-1) + \frac{P^h(k-1)(y(k) - \hat{y}^h(x(k)))}{\beta + \phi^{hT}(x(k))P^h(k-1)\phi^h(x(k))} \phi^h(x(k)), \\ P^h(k) &= \frac{1}{\beta} \left(\frac{P^h(k-1) - \frac{P^h(k-1)\phi^h(x(k))\phi^{hT}(x(k))P^h(k-1)}{\beta + \phi^{hT}(x(k))P^h(k-1)\phi^h(x(k))}}{\beta + \phi^{hT}(x(k))P^h(k-1)\phi^h(x(k))} \right) = \\ &= \left(\sum_{r=1}^k \phi^h(x(\tau))\phi^{hT}x(\tau) \right)^{-1}, 0 < \beta \leq 1, \end{aligned} \right. \quad (23)$$

де $y(t)$ – зовнішній навчальний сигнал, β – параметр забування застарілої інформації;

– оптимальний по швидкодії градієнтний однокроковий алгоритм Качмажа–Уїдроу–Хоффа

$$w^h(k) = w^h(k-1) + \frac{y(k) - w^{hT}(k-1)\varphi^h(x(k))}{\|\varphi^h(x(k))\|^2} \varphi^h(x(k)); \quad (24)$$

– алгоритм навчання, що володіє як слідкуючими, так і згладжуючими властивостями [27]

$$\begin{cases} w^h(k) = w^h(k-1) + (\beta^h(k))^{-1} \times \\ \times (y(k) - w^{hT}(k-1)\varphi^h(x(k)))\varphi^h(x(k)), \\ \beta^h(k) = \beta\beta^h(k-1) + \|\varphi^h(x(k))\|^2, 0 \leq \beta \leq 1 \end{cases} \quad (25)$$

і тому подібні процедури.

Процедура (25) пов'язана з алгоритмом (23) співвідношенням

$$\beta^h(k) = TrP^h(k), \quad (26)$$

а при $\beta = 0$ отримуємо форму алгоритму (23).

Процес настроювання синаптичних ваг може відбуватися одночасно із самонавчанням-еволюцією першого прихованого шару.

Нехай до моменту надходження спостереження $x(k)$ сформовано p вузлів функцій належності $\mu_1, \mu_2, \dots, \mu_p$ й розрахований вектор синаптичних ваг $w^p(k-1)$. Нехай умова (7) не виконується, що відразу ж веде до формування вузла μ_{p+1} та завданню довільного початкового значення синаптичної ваги w_{p+1} . При цьому вихідний сигнал NFS може бути представлений у вигляді

$$\begin{aligned} \hat{y}^{p+1}(x(k)) &= (w^{p+1}(k-1))^T \varphi^{p+1}(x(k)) = \\ &= w^{pT}(k-1)\varphi^p(x(k)) + w_{p+1}\varphi_{p+1}(x(k)), \end{aligned} \quad (27)$$

а алгоритм (24) –

$$\begin{cases} w^{p+1}(k) = \left(\frac{w^p(k-1)}{w_{p+1}} \right) + (\beta^{p+1}(k))^{-1} \times \\ \times (y(k) - \hat{y}^{p+1}(x(k))) \left(\frac{\varphi(x(k))}{\varphi_{p+1}(x(k))} \right), \\ \beta^{p+1}(k) = \beta\beta^p(k-1) + \|\varphi^p(x(k))\|^2 + \varphi_{p+1}^2(x(k)). \end{cases} \quad (28)$$

Як можна бачити, процес одночасних еволюції-самонавчання-контрольованого навчання не викликає ніяких обчислювальних проблем.

Етап 7. Перевірка відповідності архітектури та параметрів штучної нейронної мережі вимогам, що висуваються.

На даному етапі відбувається перевірка відповідності архітектури та параметрів штучної нейронної мережі вимогам. Зазначені вимоги до функціонування штучної нейронної мережі висуваються на етапі проектування систем підтримки прийняття рішень та залежать від типу та обсягів завдань, що виконуються системами підтримки прийняття рішень.

Етап 8. Прийнятті рішення на корегування архітектури та параметрів штучної нейронної мережі.

На підставі порівняльної оцінки вимог, що висуваються до функціонування ШНМ, та реальної їх ефективності приймається рішення на корегування параметрів ШНМ, а саме (дія 6–8 на схемі рис. 2):

- виду та параметрів функції належності;
- синаптичних ваг між зв'язками.

У разі неможливості забезпечити необхідні вимоги, що висуваються до ШНМ, приймається рішення на зміну архітектури ШНМ та визначенні початкових параметрів ШНМ (дія 1–5 на схемі рис. 2).

6. Обговорення результатів з розробки алгоритму навчання штучних нейронних мереж для інтелектуальних систем підтримки прийняття рішень

Запропоновано алгоритм навчання штучних нейронних мереж для інтелектуальних систем підтримки прийняття рішень.

Ефективність запропонованої багатошарової нейро-фазі системи, що еволюціонує, з гібридним навчанням була продемонстрована при оцінці системи радіозв'язку з псевдовипадковою перестройкою робочої частоти (ППРЧ) при впливі навмисних шумових завад.

Моделювання проводилися при наступних параметрах:

– засоби радіозв'язку з ППРЧ: діапазон частот – 30–512 МГц; потужність передавача – 10 Вт; ширина смуги частот, що випромінюється – 12,5 кГц, кількість чутливості приймача – 110 дБ; кількість ЗРЗ в мережі – 4; кількість частотних каналів для пере налаштування – 10000; кількість перестроювання – 333, 5 стрибків/сек;

– комплексу радіоелектронного подавлення (РЕП): діапазон частот – 30–2000 МГц; потужність передавача – 2000 Вт; максимальна смуга частот, що може бути подавлена – 80 МГц; кількість радіоліній з ППРЧ, що може бути подавлена одночасно – 4, тип завади – шумова загороджувальна завада з частотною маніпуляцією, як одна з найбільш поширених та вплив якої добре відомий; стратегія комплексу РЕП-динамічна.

Проведено практичну перевірку ефективності розробленої методики, шляхом розробки програмного забезпечення Python 3.6 (Jupyter-notebook). Зазначене програмне забезпечення було встановлене на ПЕОМ, до якого підключено 4 програмовані приймопередавачі LimeSDR з програмним забезпеченням

GNU Radio та підключено до генератора шуму RIGOL DG5252, що імітував роботу комплексу РЕП.

Для порівняння ефективності запропонованого алгоритму з відомими були використані методи навчання штучних нейронних мереж, що використовуються в системах підтримки прийняття рішень.

Для оцінки впливу навмисних шумових завад на засоби радіозв'язку з ППРЧ використовувалася нейро-фаззі система з кількістю входів $n = 5$.

Навчання системи проводилося на основі вибірки, з керуючими сигналами:

$$f(x_1, x_2, x_4, x_5) = \frac{x_1 x_2 x_4 x_5 (x_3 - 1) + x_4}{1 + x_3^2 + x_2^2}. \quad (29)$$

Кількість ітерацій оцінювання стану системи радіозв'язку з ППРЧ становить 10.

Для перевірки ефективності запропонованого алгоритму припустимо, що час роботи програмованого засобу радіозв'язку з ППРЧ на одній частоті є однаковим з комплексом РЕП.

Коротко проведемо опис графічних відношень, що отримані на рис. 3. Рис. 3, 4 були отримані шляхом усереднення відношення сигнал/шум на частотних підканалах. Зазначена перевага обумовлена більшою точністю оцінювання відношення сигнал/шум в частотних підканалах за рахунок швидкого налаштування параметрів штучної нейронної мережі до типу та інтенсивності даних, що надходять на її вхід. Разом з тим, хотілося в окремо акцентувати увагу на те, що при оцінюванні за допомогою запропонованого алгоритму помилка оцінювання не зростає під час роботи штучної нейронної мережі на відміну від інших підходів (рис. 3, 4).

На рис. 4 наведено графік залежності ймовірності бітової помилки від відношення сигнал/шум (для випадку шумової завади в частині смуги з частотною маніпуляцією $\rho=0,5$).

Оцінка обчислювальної складності реалізації розробленого алгоритму показала, що для заданих вихідних даних та при використанні процесора ADSP-21261 оцінка стану каналу системи радіозв'язку може здійснюватися в реальному масштабі часу. При цьому враховується затримка, необхідна для передачі інформації про ці значення по службовому каналу зворотного зв'язку.

Дослідження розробленого алгоритму показало, що зазначений алгоритм навчання забезпечує в середньому на 16–23 % більшу високу ефективність навчання штучних нейронних мереж та не накопичує помилок в ході навчання. Зазначена ефективність наведена на рис. 3 та рис. 4, тобто порівняльна оцінка між методикою [7] та запропонованим алгоритмом при зазначених умовах функціонування (6 дБ та 2 дБ на останній ітерації навчання).

Виграш в діапазоні 16–23 % був отриманий в ході оперативного контролю поточного стану і завадової обстановки в каналах, зайнятих під передачу, за час, порівняний із тривалістю циклу обміну інформацією. Неоднозначність визначення стану каналів викликано різними параметрами сигналу, що приймається, в зв'язку з різними траєкторіями проходження сигналу та рівнями сигнал/шум в підканалах.




Рис. 3. Залежність ймовірності біткової помилки від відношення сигнал/шум Q_0^2 при для різних методик при впливі флуктуаційного шуму і шумової загороджувальної завади з коефіцієнтом перекриття $\rho=1$ при 10 ітераціях оцінювання штучної нейронної мережі

Основними перевагами запропонованого алгоритму навчання є:

- не накопичує помилки навчання в ході навчання штучних нейронних мереж за рахунок корегування параметрів та архітектури штучної нейронної мережі;
- однозначність отриманої результатів;
- широка сфера використання (системи підтримки та прийняття рішень);
- простота математичних розрахунків;
- можливість адаптації системи в ході роботи;
- можливість синтезу оптимальної структури системи підтримки та прийняття рішення.




Рис. 4. Графік залежності ймовірності бітової помилки від відношення сигнал/шум Q_0^2 (для випадку шумової завади в частині смуги з частотною маніпуляцією з коефіцієнтом перекриття $\rho=0.5$) при 10 ітераціях оцінювання штучної нейронної мережі

До недоліків запропонованого алгоритму слід віднести:

- втрата інформативності при оцінюванні (прогнозуванні) за рахунок побудови функції належності при проведенні процедур фазифікації/дефазифікації вхідних параметрів (переході з чіткого до нечіткого оцінювання та навпаки). Зазначена втрата інформативності може бути зменшена за рахунок вибору типу функції належності та її параметрів при практичній реалізація запропонованого алгоритму в системах підтримки та прийняття рішень. Вибір типу функції належності залежить від обчислювальних ресурсів конкретного електронно-обчислювального засобу.

- менша точність оцінювання по окремо взятому параметру оцінки стану;
- втрата точності результатів за час перестройки архітектури штучної нейронної мережі.

Зазначений алгоритм дозволить:

- проводити навчання штучних нейронних мереж;
- визначити ефективні заходи для підвищення ефективності функціонування штучних нейронних мереж;
- підвищити ефективність функціонування штучних нейронних мереж за рахунок навчання параметрів та архітектури мереж;
- зменшити використання обчислювальних ресурсів систем підтримки та прийняття рішень;
- виробити заходи, що спрямовані на підвищення ефективності навчання штучних нейронних мереж;
- підвищити оперативність обробки інформації в штучних нейронних мережах.

Зазначене дослідження є подальшим розвитком досліджень проведеними авторами, що спрямовані на розробку теоретичних основ підвищення ефективності систем штучного інтелекту, що опубліковані вже раніше [1, 2, 29, 30].

Напрямки подальших досліджень слід спрямувати на зменшення обчислювальних витрат при обробці різнотипних даних в системах спеціального призначення.

7. Висновки

1. Проведено формалізацію завдання навчання штучних нейронних мереж. В ході формалізації визначено порядок роботи алгоритмів навчання штучних нейронних мереж. Приведений узагальнений алгоритм навчання штучних нейронних мереж. На базі наведеного алгоритму було проведено розробку удосконаленого алгоритму навчання штучних нейронних мереж.

2. Запропоновано алгоритм навчання штучних нейронних мереж для інтелектуальних систем підтримки прийняття рішень реалізує наступне:

- проводить навчання не тільки синаптичних ваг штучної нейронної мережі, але й виду та параметрів функції належності;
- в разі неможливості забезпечити задану якість функціонування штучних нейронних мереж за рахунок навчання параметрів відбувається навчання архітектури штучних нейронних мереж;
- вибір архітектури, виду та параметрів функції належності відбувається з врахуванням обчислювальних ресурсів засобу та з врахуванням типу та кількості інформації, що надходить на вхід штучної нейронної мережі;
- не відбувається накопичення помилки навчання штучних нейронних мереж в результаті обробки інформації, що надходить на вхід штучних нейронних мереж.

3. Дослідження розробленого алгоритму показало, що зазначений алгоритм навчання забезпечує в середньому на 16–23 % більшу високу ефективність навчання штучних нейронних мереж та не накопичує помилок в ході навчання.

Подяки

Авторський колектив висловлює подяку за надання допомоги:

доктору технічних наук, професору Кувшинову Олексію Вікторовичу – заступнику начальника навчально-наукового інституту Національного університету оборони України імені Івана Черняхівського.

доктору технічних наук, старшому науковому співробітнику Журавському Юрію Володимировичу – провідному науковому співробітнику наукового центру Житомирського військового інституту імені С. П. Корольова.

Кандидату технічних наук, доценту Башкирову Олександр Миколайовичу – провідному науковому співробітнику Центрального науково-дослідного інституту озброєння та військової техніки Збройних Сил України.

Література

1. Kalantaievska, S., Pievtsov, H., Kuvshynov, O., Shyshatskyi, A., Yarosh, S., Gatsenko, S. et. al. (2018). Method of integral estimation of channel state in the multiantenna radio communication systems. *Eastern-European Journal of Enterprise Technologies*, 5(9 (95)), 60–76. doi: <https://doi.org/10.15587/1729-4061.2018.144085>
2. Kuchuk, N., Mohammed, A. S., Shyshatskyi, A., Nalapko, O. (2019). The method of improving the efficiency of routes selection in networks of connection with the possibility of self-organization. *International Journal of Advanced Trends in Computer Science and Engineering*, 8 (1.2), 1–6. URL: <http://www.warse.org/IJATCSE/static/pdf/file/ijatcse01812sl2019.pdf>
3. Zhang, J., Ding, W. (2017). Prediction of Air Pollutants Concentration Based on an Extreme Learning Machine: The Case of Hong Kong. *International Journal of Environmental Research and Public Health*, 14 (2), 114. doi: <https://doi.org/10.3390/ijerph14020114>
4. Katranzhy, L., Podskrebko, O., Krasko, V. (2018). Modelling the dynamics of the adequacy of bank's regulatory capital. *Baltic Journal of Economic Studies*, 4 (1), 188–194. doi: <https://doi.org/10.30525/2256-0742/2018-4-1-188-194>
5. Manea, E., Di Carlo, D., Depellegrin, D., Agardy, T., Gissi, E. (2019). Multidimensional assessment of supporting ecosystem services for marine spatial planning of the Adriatic Sea. *Ecological Indicators*, 101, 821–837. doi: <https://doi.org/10.1016/j.ecolind.2018.12.017>
6. Çavdar, A. B., Ferhatosmanoğlu, N. (2018). Airline customer lifetime value estimation using data analytics supported by social network information. *Journal of Air Transport Management*, 67, 19–33. doi: <https://doi.org/10.1016/j.jairtraman.2017.10.007>
7. Kachayeva, G. I., Mustafayev, A. G. (2018). The use of neural networks for the automatic analysis of electrocardiograms in diagnosis of cardiovascular diseases. *Herald of Dagestan State Technical University. Technical Sciences*, 45 (2), 114–124. doi: <https://doi.org/10.21822/2073-6185-2018-45-2-114-124>
8. Zhdanov, V. V. (2016). Experimental method to predict avalanches based on neural networks. *Ice and Snow*, 56 (4), 502–510. doi: <https://doi.org/10.15356/2076-6734-2016-4-502-510>
9. Kanev, A., Nasteka, A., Bessonova, C., Nevmerzhitsky, D., Silaev, A., Efremov, A., Nikiforova, K. (2017). Anomaly detection in wireless sensor network of

the “smart home” system. 2017 20th Conference of Open Innovations Association (FRUCT). doi: <https://doi.org/10.23919/fruct.2017.8071301>

10. Sreeshakthy, M., Preethi, J. (2016). Classification of human emotion from deap EEG signal using hybrid improved neural networks with Cuckoo search. *Brain: Broad Research in Artificial Intelligence and Neuroscience*, 6 (3-4), 60–73.

11. Chica, J., Zaputt, S., Encalada, J., Salamea, C., Montalvo, M. (2019). Objective assessment of skin repigmentation using a multilayer perceptron. *Journal of Medical Signals & Sensors*, 9 (2), 88. doi: https://doi.org/10.4103/jmss.jmss_52_18

12. Massel, L. V., Gerget, O. M., Massel, A. G., Mamedov, T. G. (2019). The Use of Machine Learning in Situational Management in Relation to the Tasks of the Power Industry. *EPJ Web of Conferences*, 217, 01010. doi: <https://doi.org/10.1051/epjconf/201921701010>

13. Abaci, K., Yamacli, V. (2019). Hybrid Artificial Neural Network by Using Differential Search Algorithm for Solving Power Flow Problem. *Advances in Electrical and Computer Engineering*, 19 (4), 57–64. doi: <https://doi.org/10.4316/aece.2019.04007>

14. Mishchuk, O. S., Vitynskyi, P. B. (2018). Neural Network with Combined Approximation of the Surface of the Response. *Research Bulletin of the National Technical University of Ukraine “Kyiv Politechnic Institute”*, 2, 18–24. doi: <https://doi.org/10.20535/1810-0546.2018.2.129022>

15. Kazemi, M., Faezrad, M. (2018). Efficiency Estimation using Nonlinear Influences of Time Lags in DEA Using Artificial Neural Networks. *Industrial Management Journal*, 10 (1), 17–34. doi: <http://doi.org/10.22059/imj.2018.129192.1006898>

16. Parapuram, G., Mokhtari, M., Ben Hmida, J. (2018). An Artificially Intelligent Technique to Generate Synthetic Geomechanical Well Logs for the Bakken Formation. *Energies*, 11 (3), 680. doi: <https://doi.org/10.3390/en11030680>

17. Prokoptsev, N. G., Alekseenko, A. E., Kholodov, Y. A. (2018). Traffic flow speed prediction on transportation graph with convolutional neural networks. *Computer Research and Modeling*, 10 (3), 359–367. doi: <https://doi.org/10.20537/2076-7633-2018-10-3-359-367>

18. Bodyanskiy, Y., Pliss, I., Vynokurova, O. (2013). Flexible Neo-fuzzy Neuron and Neuro-fuzzy Network for Monitoring Time Series Properties. *Information Technology and Management Science*, 16 (1). doi: <https://doi.org/10.2478/itms-2013-0007>

19. Bodyanskiy, Ye., Pliss, I., Vynokurova, O. (2013). Flexible wavelet-neuro-fuzzy neuron in dynamic data mining tasks. *Oil and Gas Power Engineering*, 2 (20), 158–162.

20. Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Prentice Hall, 842.

21. Nelles, O. (2001). *Nonlinear System Identification*. Springer. doi: <https://doi.org/10.1007/978-3-662-04323-3>

22. Wang, L.-X., Mendel, J. M. (1992). Fuzzy basis functions, universal approximation, and orthogonal least-squares learning. *IEEE Transactions on Neural Networks*, 3 (5), 807–814. doi: <https://doi.org/10.1109/72.159070>

23. Kohonen, T. (1995). Self-Organizing Maps. Springer. doi: <https://doi.org/10.1007/978-3-642-97610-0>
24. Kasabov, N. (2003). Evolving Connectionist Systems. Springer. doi: <https://doi.org/10.1007/978-1-4471-3740-5>
25. Sugeno, M., Kang, G. T. (1988). Structure identification of fuzzy model. Fuzzy Sets and Systems, 28 (1), 15–33. doi: [https://doi.org/10.1016/0165-0114\(88\)90113-3](https://doi.org/10.1016/0165-0114(88)90113-3)
26. Ljung, L. (1987). System Identification: Theory for the User. Prentice Hall, 432.
27. Otto, P., Bodyanskiy, Y., Kolodyazhniy, V. (2003). A new learning algorithm for a forecasting neuro-fuzzy network. Integrated Computer-Aided Engineering, 10 (4), 399–409. doi: <https://doi.org/10.3233/ica-2003-10409>
28. Narendra, K. S., Parthasarathy, K. (1990). Identification and control of dynamical systems using neural networks. IEEE Transactions on Neural Networks, 1 (1), 4–27. doi: <https://doi.org/10.1109/72.80202>
29. I. Alieinykov, K. A. Thamer, Y. Zhuravskyi, O. Sova, N. Smirnova, R. Zhyvotovskiy et. al. (2019). Development of a method of fuzzy evaluation of information and analytical support of strategic management. Eastern-European Journal of Enterprise Technologies, 6 (2 (102)), 16–27. doi: <https://doi.org/10.15587/1729-4061.2019.184394>
30. Koshlan, A., Salnikova, O., Chekhovska, M., Zhyvotovskiy, R., Prokopenko, Y., Hurskyi, T. et. al. (2019). Development of an algorithm for complex processing of geospatial data in the special-purpose geoinformation system in conditions of diversity and uncertainty of data. Eastern-European Journal of Enterprise Technologies, 5 (9 (101)), 35–45. doi: <https://doi.org/10.15587/1729-4061.2019.180197>