
Наука і сучасні технології

УДК 681.5: 658.01

DOI: 10.31471/1993-9868-2018-1(29)-50-55

ІНТЕЛЕКТУАЛЬНА СИСТЕМА ДЛЯ РОЗПІЗНАВАННЯ ОБ'ЄКТІВ НА ОПТИЧНИХ ЗОБРАЖЕННЯХ З ВИКОРИСТАННЯМ КАСКАДНИХ НЕЙРОННИХ МЕРЕЖ

М.В. Шавранський, О.В. Кучмистенко

*ІФНТУНГ; 76019, м. Івано-Франківськ, вул. Карпатська, 15, тел. (0342) 727167,
e-mail: kafatp@ukr.net*

Робота присвячена підвищенню точності класифікації об'єктів на оптичних зображеннях шляхом розробки структури, моделі та методу навчання комбінованої нейронної мережі та створення на її основі інтелектуальної системи розпізнавання образів для завдань нафтогазової промисловості – діагностики, прогнозування нештатних ситуацій технологічних об'єктів.

Ключові слова: інтелектуальна система, розпізнавання об'єктів, оптичні зображення, каскадні нейронні мережі, модель.

Работа посвящена повышению точности классификации объектов на оптических изображениях путем разработки структуры, модели и метода обучения комбинированной нейронной сети и создание на ее основе интеллектуальной системы распознавания образов для задач нефтегазовой промышленности - диагностики, прогнозирования нештатных ситуаций технологических объектов.

Ключевые слова: интеллектуальная система, распознавание объектов, оптические изображения, каскадные нейронные сети, модель.

The paper is devoted to increasing the accuracy of the classification of objects on optical images by developing a structure, model and method of teaching the combined neural network and creating on its basis an intelligent image recognition system for tasks of the oil and gas industry - diagnostics, forecasting of emergency situations of technological objects.

Key words: intelligent system, object recognition, optical images, cascade neural networks, model.

Постановка проблеми. Розпізнавання об'єктів на оптичних зображеннях на сьогодні є однією з найбільш актуальних сфер застосування систем штучного інтелекту.

Проведення експрес-аналізу оптичних зображень має на меті розпізнавання в режимі "онлайн" об'єктів, які отримують при проведенні медичних оглядів, при дистанційному зондуванні землі, з метою виявлення вуглеводнів, у військовій справі тощо. З використанням складних пристроїв (мультиспектральних електрооптичних систем) кількість інформації, яку необхідно обробити, збільшується, що призводить до підвищення складності розв'язуваних задач, а також рівня завад на оптичних зображеннях. У зв'язку з цим існує необхідність у використанні нових інтелектуальних інформаційних технологій для ефективної обробки зображень та їх аналізу.

До таких технологій належать нейронні мережі та системи з нечіткою логікою. За останні роки було створено різні типи нейронних мереж, які можуть бути використані для задач розпізнавання та класифікації. Однак визначення найбільш ефективного класу мереж для задач розпізнавання об'єктів на оптичних зображеннях у т.ч. і для використання в нафтогазовій промисловості є дещо проблематичним. Каскадні нейронні мережі є перспективним напрямком в теорії нейронних мереж – вони швидко навчаються, здатні до самоорганізації, зберігають побудовану структуру при зміні тренувальної вибірки.

Для вирішення поставлених наукових завдань були вибрані такі напрямки досліджень:

- дослідження методів перетворення даних з метою формування вхідних даних;

- дослідження різних класів нейронних мереж;
- дослідження алгоритмів сегментації;
- дослідження принципів побудови інтелектуальних систем.

Аналіз останніх досліджень і публікацій.

За останні роки було створено різні типи нейронних мереж, які можуть бути використані для задач розпізнавання та класифікації. Визначення найбільш ефективного класу мереж для задач розпізнавання об'єктів на оптичних зображеннях у т.ч. і для використання в нафтогазовій промисловості стикається з певними труднощами.

Каскадні нейронні мережі є перспективним напрямком в теорії нейронних мереж; вони швидко навчаються, здатні до самоорганізації, зберігають побудовану структуру при зміні тренувальної вибірки. Дослідженням каскадних нейромереж займаються такі науковці, як С. Фальман, Я.Сей, М. Нечиба, К. Лебьер, Ю. Зайченко С. Бодянський. В їх роботах, здебільшого, досліджується класичний алгоритм каскадної нейронної мережі, але майже відсутні комбіновані алгоритми, тому розробка нових моделей нейронних мереж та методів їх навчання визначає актуальність дослідження.

Мета й завдання дослідження. Підвищення точності класифікації об'єктів на оптичних зображеннях шляхом розроблення структури, моделі та методу навчання комбінованої нейронної мережі та створення на її основі інтелектуальної системи розпізнавання образів для задач нафтогазової промисловості – діагностики, прогнозування і т.д. нештатних ситуацій.

Об'єкт дослідження: процес розпізнавання об'єктів на оптичних зображеннях, отриманих за допомогою мультиспектральних систем в оптичному діапазоні.

Предмет дослідження: моделі і методи навчання різних класів нейронних мереж в задачах обробки даних та класифікації об'єктів.

Методи дослідження: методи статистичної обробки експериментальних даних та методи обробки зображень використані для попередньої підготовки даних, теорія штучних нейронних мереж, методи сегментації та методи нечіткої логіки застосовані для розв'язання задачі розпізнавання об'єктів на оптичних зображеннях.

Основні результати дослідження. На основі проведеного аналізу існуючих систем [1-4] можна зробити висновок про успішне застосування нейронних мереж для вирішення проблеми нафтогазової промисловості. Для задач обробки оптичних зображень органів найчастіше використовуються радіально-базисні нейронні мережі і багатощаровий перцептрон.

В результаті аналізу [5-7] виявлені методи, що дозволяють виконувати ефективну обробку більшості текстур. Показано, що існуючі методи не розроблялися для формування вихідних даних для оцінки стану об'єктів автоматизації нафтогазової промисловості.

У зв'язку з цим необхідно виконати дослідження вибраних методів і на їх основі розробити метод перетворення інформації для прийняття рішень в інтелектуальній системі обробки зображень об'єктів.

Алгоритм роботи удосконаленої каскадної нейронної мережі, полягає в тому, що процес знаходження оптимальних значень параметрів каскадної радіально-базисної нейронної мережі розбивається на 2 етапи, на першому з яких оптимізуються нелінійні параметри радіально-базисних функцій, а на другому – ваги зв'язків нейронної мережі, завдяки чому знижується загальна розмірність задачі оптимізації і прискорюється робота алгоритму навчання. Модель каскадної радіально-базисної нейронної мережі (КРБНМ), можна подати в такому вигляді (рис. 1).

1-й каскад.

Виходи радикально-базисної функції (РБФ) нейрона першого каскаду:

$$z_k = \prod_{j=1}^n \phi_{kj}(x_j) = \exp \left\{ - \sum_{j=1}^n \frac{(x_j - c_{kj})^2}{2r_k^2} \right\}, \quad (1)$$

де x – входи,
 c – центри та r – радіуси РБФ функцій ϕ ,
 n – кількість входів, $k=1, N$.

Виходи нейронної мережі першого каскаду:

$$y_1^{(1)} = \sum_{k=1}^N z_k^{(1)} w_{k1}^{(1)} = Z^T W_1 ;$$

$$y_i^{(1)} = \sum_{k=1}^N z_k^{(1)} w_{ki}^{(1)} = Z^T W_i, \quad i = \overline{1, N} .$$

Вектор виходів:

$$y^{(1)} = [y_i^{(1)}] = W^{(1)} Z ,$$

$$W^{(1)} = \left\| w_{ik}^{(1)} \right\|_{i=1, N}^{k=1, N} .$$

2-й каскад:

$$z_1^{(2)} = \exp \left[- \left\{ \sum_{j=1}^n \frac{(x_j - c_{1j}^{(2)})^2}{2} \right\} + \sum_{i=1}^n \frac{(z_i^{(1)} - c_{1i}^{(1)})^2}{2r_{21}^2} \right],$$

$$z_k^{(2)} = \exp \left[- \left\{ \sum_{j=1}^n \frac{(x_j - c_{kj}^{(2)})^2}{2r_j^2} \right\} + \sum_{i=1}^n \frac{(z_i^{(1)} - c_{ik}^{(1)})^2}{2r_{2k}^2} \right],$$

$$y_k^{(2)} = y_k^{(1)} + \sum_{i=1}^N z_i^{(2)} w_{ik}^{(2)} .$$

К-й каскад.

Виходи k-го каскаду:

$$\phi_j^{(k)}(x_j) = \exp \left\{ - \frac{(x_j - c_j^{(k)})^2}{2r_{jk}^2} \right\}, \quad j = \overline{1, n} .$$

Входи з виходів попередніх каскадів:

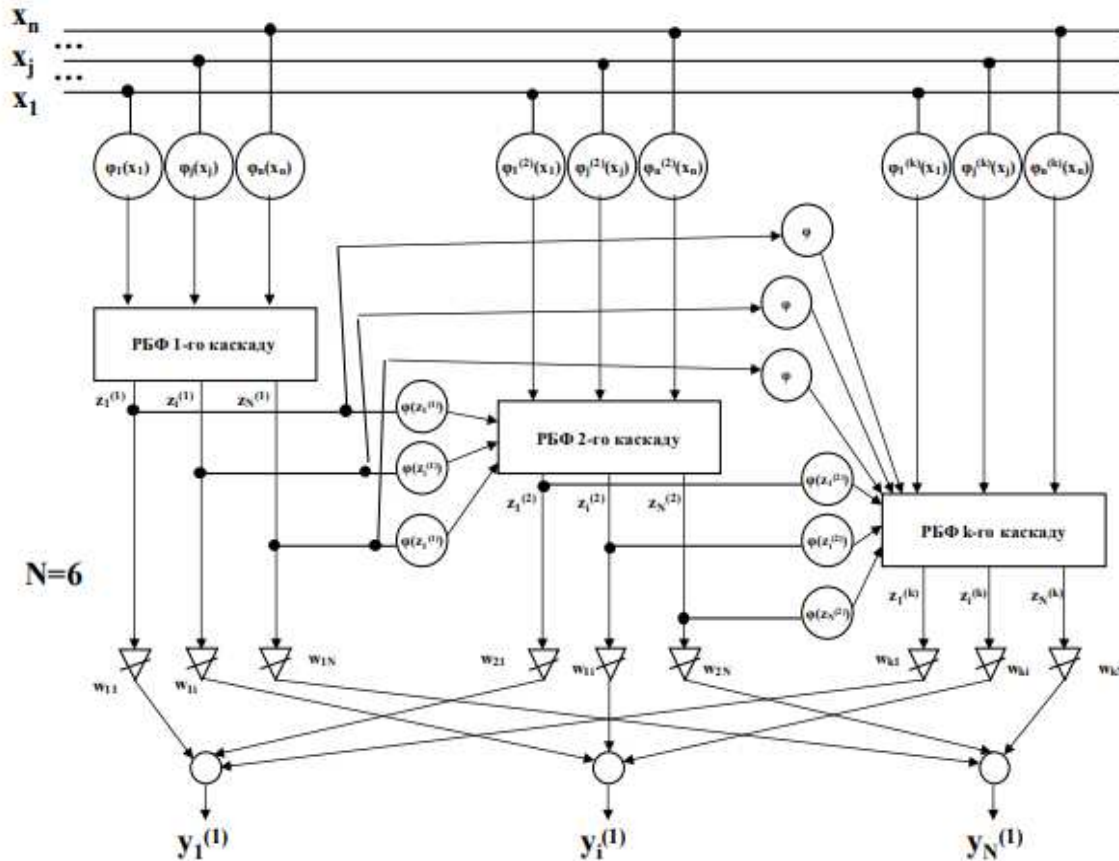


Рисунок 1 – Загальна структура комбінованої каскадної радіально-базисної нейронної мережі

$$\phi_j^{(k)}(z_i^{(k)}) = \exp \left\{ - \frac{(z_i^{(k)} - c_j^{(k)})^2}{2r_k^2} \right\},$$

$$j = \overline{1, N}, \quad k = \overline{1, K-1},$$

i -ий вихід K -го каскаду (проміжний):

$$z_i^k = \prod_{j=1}^n \phi_j^k(x_j) \prod_{k=1}^{K-1} \phi(z_k) =$$

$$= \exp \left\{ - \sum_{j=1}^n \frac{(x_j - c_j^{(k)})^2}{2r_j^2} - \sum_{k=1}^{K-1} \frac{(z_i^{(k)} - c_i^{(k)})^2}{2r_{ik}^2} \right\}.$$

Загальний вихід після K каскадів:

$$y_1^{(K)} = \sum_{k=1}^K \sum_{l=1}^N z_l^{(k)} w_{l1}^{(k)} = y_1^{(K-1)} + \sum_{l=1}^N z_l^{(K)} w_{l1}^{(K)},$$

загальний вихід:

$$y_i^{(K)} = \sum_{k=1}^K \sum_{l=1}^N z_l^{(k)} w_{li}^{(k)} = y_i^{(K-1)} + \sum_{l=1}^N z_l^{(K)} w_{li}^{(K)},$$

Або в матричному вигляді:

$$Y_1^{(k)} = W_1^k Z^{(k)}, \quad Y_i^{(k)} = W_i^k Z^{(k)}, \quad i = \overline{1, N}.$$

Загальний критерій навчання виглядає так: знайти такі матриці ваг $W_k = \|W_{il}^{(k)}\|$, $i = \overline{1, N}$, $l = \overline{1, N}$, $k = \overline{1, K}$; а також параметри РБ-функцій $\{c_{ij}^{(k)}\}$ та $\{r_{ij}^{(k)}\}$ для яких

$$E = \sum_{t=1}^T \sum_{i=1}^N \left(y_{it}^{target} - \hat{y}_{it}^{(k)}(W, C, R) \right)^2 \rightarrow \min_{W, C, R}$$

де y_{it}^{target} - необхідний бажаний вихід i -го класу,

$\hat{y}_{it}^{(k)}(W, C, R)$ - вихід моделі i -го класу для взірця t ,

T - загальний обсяг навчальної вибірки.

Загальний алгоритм складається з послідовності ітерацій. Навчання проходить послідовно, починаючи з першого каскаду (рис.2).

Алгоритм навчання каскаду 1. Використовується гібридний алгоритм, що складається з послідовності двох етапів: навчання ваг зв'язків

$W_{il}^{(1)}$ (етап 1) та налаштування параметрів

РБ-функцій $\{r_{ij}, c_{ij}^{(k)}\}$ (етап 2).

Етап 1.

Спочатку вибираються початкові значення параметрів РБФ $c_{ij}^{(1)}(0)$ і $r_{ij}^2(0)$, їх можна ініціалізувати випадково або розрахувати так:

$$c_{ij}(0) = \frac{1}{n_i} \sum_{t \in V_i} x_{jt} \quad \text{та}$$

$$r_{ij}^2(0) = \frac{1}{n_i - 1} \sum_{t \in V_i} (x_{jt} - c_{ij}(0))^2,$$

де t - номер взірця,

V_i - підмножина взірців класу i ($i = \overline{1, N}$),

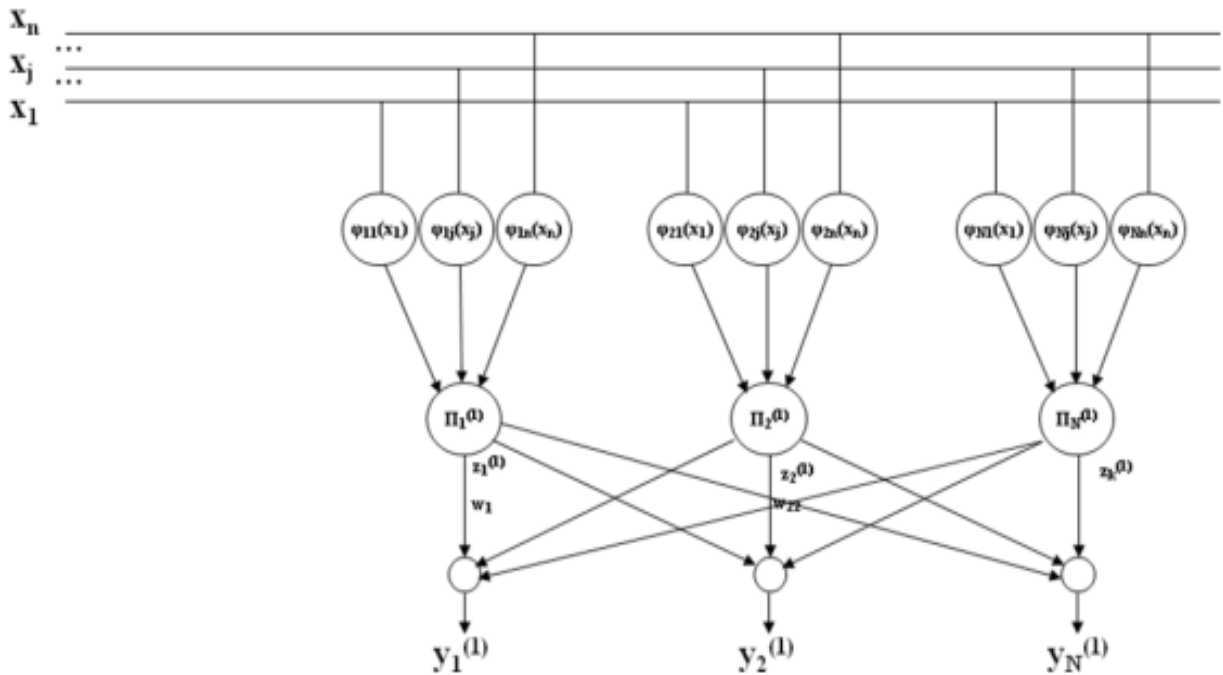


Рисунок 2 – Структура одного каскаду каскадної радіально-базисної нейронної мережі

n_i – число взірців класу V_i в навчальній виборці,
 x_{jt} – значення входу j взірця t .

2. Далі визначаються $\{\phi_{ij}^{(1)}(x_{jt})\}, t \in T$ і знаходимо $z_{it}^{(1)}$. Позначимо для зручності $[z_{it}^{(1)}]_{t \in V_i} = z_i^{(1)}$. Таким чином,
 $y_{it}^{(1)} = \sum_{i=1}^N z_{it}^{(1)} w_{it}^{(1)}$, $y_{Nt}^{(1)} = \sum_{i=1}^N z_{it}^{(1)} w_{it}^{(1)}$ – виходи 1-го каскаду.

Оскільки класифікація відбувається за критерієм max виходу, то вирішальне правило класифікації $X_t = [x_{jt}]$, $j = \overline{1, N}$ відноситься до класу V_i , якщо

$$y_{it}^{(1)} = \sum_{l=1}^N z_{lt}^{(1)} w_{li}^{(1)} = \max_k y_{kt}^{(1)} = \max_k \sum_{l=1}^N z_{lt}^{(1)} w_{lk}^{(1)}.$$

Бажане значення i -го виходу (класу) $y_{t \text{ arg et } i}^t = y_{\max}$ зразків з класу V_i , а для всіх зразків з інших класів V_i через $y_{t \text{ arg et } i}^t = y_{\min}$. Відповідні нерівності для i -го виходу першого каскаду:

$$y_{it} = z^{(1)} w^{(1)} = \sum_{l=1}^N z_{lt}^{(1)} w_{li}^{(1)} \geq y_{t \text{ arg et } i}^t = y_{\max}, \quad (2)$$

$$\leq y_{t \text{ arg et } i}^t = y_{\max}, \quad t \notin V_i \quad (3)$$

Тоді можна записати наступну задачу лінійного програмування:

$$\min \sum_{t \in V_i} \varepsilon_t, \text{ де } \varepsilon_t \geq 0 \quad (4)$$

при таких обмеженнях:

$$\sum_{l=1}^N z_{lt}^{(1)} w_{li}^{(1)} - \varepsilon_t = y_{\max}, \quad t \in V_i, \quad i = \overline{1, N} \text{ та}$$

$$\sum_{l=1}^N z_{lt}^{(1)} w_{li}^{(1)} + \varepsilon_t = y_{\min}, \quad t \notin V_i, \quad i = \overline{1, N} \quad (5)$$

Розв'язується задача лінійного програмування (4) – (5) симплекс методом і якщо вона має розв'язки, то кінець навчання 1 каскаду, інакше, якщо вона виявилася нерозв'язною за відповідною ознакою симплекс-методу, то переходимо до наступної допоміжної задачі

$$\min \sum_{t=1}^T \varepsilon_t^2, \quad (6)$$

при обмеженнях (5). Це задача квадратичного програмування, яка вирішується стандартним методом. Повторюється її розв'язання для всіх

початкових значень ваг $\|W_{il}^{(1)}\|_{l=1, N}^{i=1, N}$. Перехід

до другого етапу, на якому оптимізується значення параметрів РБ-функцій $c_{ij}^{(1)}$ і $r_{ij}^{(1)}$.

Етап 2. Оптимізований критерій має наступний вигляд:

$$E = \frac{1}{T} \sum_{i=1}^N \sum_{t \in V_i} (y_{it}^{\text{arg et } i} - \hat{y}_{it}^{(k)}(c, r))^2 \rightarrow \min,$$

де $y_{it}^{\text{arg et } i} = \begin{cases} y_{\max}, & \text{if } t \in V_i \\ y_{\min}, & \text{if } t \notin V_i \end{cases}$ – задане значення

для зразку t і-го виходу, V_i – множина взірців i -го класу навчальної вибірки,

\hat{y}_{it} – i -й вихід для t -го зразку КРБН-мережі. Для оптимізації параметрів застосовується градієнтний метод або метод навчання

Відрой-Хоффа. Знайдемо значення $\frac{\partial E}{\partial c_{ij}^{(1)}}$ для градієнту:

$$\frac{\partial E}{\partial c_{ij}^{(1)}} = \frac{1}{T} \sum_{t=1}^T \left(y_{it}^{arg et} - \hat{y}_{it}^{(k)}(c, r) \right) \frac{\partial \hat{y}_{it}}{\partial c_{ij}^{(1)}}. \quad (7)$$

Враховуючи те, що:

$$\begin{aligned} \hat{y}_{it} &= \sum_{l=1}^N z_{lt}^{(1)} w_{li}^{(1)} = \sum_{l=1}^N \prod_{j=1}^n \phi(x_{jt}^l) w_{li}^{(1)} = \\ &= \sum_{l=1}^N \exp \left\{ - \sum_{j=1}^n \frac{(x_{jt} - c_{lj}^{(1)})^2}{2r_j^2} \right\} w_{li}^{(1)} \end{aligned} \quad (8)$$

$j = \overline{1, n}, \quad l = \overline{1, N};$

$$\frac{\partial E}{\partial c_{ij}^{(1)}} = w_{ji} \exp \left\{ - \sum_{j=1}^n \frac{(x_{jt} - c_{lj}^{(1)})^2}{2r_j^2} \right\} \frac{(x_{jt} - c_{lj}^{(1)})}{2r_j^2}; \quad (9)$$

$$\frac{\partial E}{\partial r_j^{(1)}} = w_{ji} \exp \left\{ - \sum_{j=1}^n \frac{(x_{jt} - c_{lj}^{(1)})^2}{2r_j^2} \right\} \frac{(x_{jt} - c_{lj}^{(1)})^2}{2r_j^3}. \quad (10)$$

Далі реалізуємо градієнтний алгоритм спуску і знаходимо рекурентно:

$$c_{ij}^{(1)}(m+1) = c_{ij}^{(1)}(m) - \gamma_m \frac{\partial E(m)}{\partial c_{ij}^{(1)}}, \quad m = 1, 2, \dots; \quad (11)$$

$$r_{ij}^{(1)}(m+1) = r_{ij}^{(1)}(m) - \gamma_m \frac{\partial E(m)}{\partial r_{ij}^{(1)}}, \quad m = 1, 2, \dots; \quad (12)$$

Умови збіжності:

$$\gamma_m \rightarrow 0; \quad m \rightarrow \infty(a); \quad \sum_{m=0}^{\infty} \gamma_m = \infty(b); \quad \sum_{m=0}^{\infty} \gamma_m^2 < \infty(v).$$

Ітерації градієнтного спуску повторюються до тих пір, поки значення $c_{ij}^{(1)}$ та $r_{ij}^{(1)}$ не будуть стабілізовані. В результаті знаходяться $c_{ij}^{(1) new} = c_{ij}^{(1)}(1)$ та $r_{ij}^{(1) new} = r_{ij}^{(1)}(1)$. Перехід до етапу 2 і розв'язується (6) при обмеженнях (5) з новими значеннями параметрів РБ-функції $c_{ij}^{(1) new}$ і $r_{ij}^{(1) new}$. Послідовність етапів 1 і 2 повторюється до тих пір, поки значення параметрів $c_{ij}^{(1)}$ і $r_{ij}^{(1)}$ та ваги $\|w_{il}^{(1)}\|_{l=1, N}^{i=1, N}$ не стабілізуються. На цьому навчання параметрів першого каскаду закінчується.

Оскільки число ітерацій градієнтного методу залежить нелінійно від розмірності (числа варійованих параметрів), то розбиття пропонованого алгоритму оптимізації на 2 окремих етапи істотно скорочує розмірність задачі. Завдяки цьому загальне число ітерацій запропонованого алгоритму значно менше, ніж у класичного градієнтного методу, а його швидкість збіжності вища.

Метод навчання каскаду 2 складається з наступних кроків. Перехід до оптимізації параметрів навчання другого каскаду ($k = 2$), зафіксувавши параметри РБФ і виходи каскаду $1(y_1^{(1)}, \dots, y_N^{(1)})$. Для цього використовується такий самий гібридний алгоритм, що й раніше (для каскаду 1). При цьому на етапі 1 для і-го виходу каскаду 2 маємо:

$$y_{it}^{(2)} = \sum_{l=1}^N z_{lt}^{(2)} w_{li}^{(2)} + \sum_{l=1}^N z_{lt}^{(1)} w_{li}^{(1)} = \sum_{l=1}^N z_{lt}^{(2)} w_{li}^{(2)} + y_{it}^{(1)}. \quad (13)$$

Вирішується задача квадратичного програмування для і-го виходу: $\min \sum_{t \in V_i} \varepsilon_t^2$, при

умовах: $\sum_{l=1}^N z_{lt}^{(1)} w_{li}^{(1)} - \varepsilon_t = y_{\max}$, $t \in V_i$, та

$\sum_{l=1}^N z_{lt}^{(1)} w_{li}^{(1)} + \varepsilon_t = y_{\min}$, $t \notin V_i$. В результаті зна-

ходимо початкові ваги $\|w_{li}^{(2)}\|_{l=1, N}^{i=1, N}$, потім пе-

реходимо до другого етапу. На другому етапі градієнтним методом або методом спряженого градієнта обчислюються значення параметрів РБ-функцій другого каскаду за формулами, аналогічними (11), (12). Повторивши багаторазово 2 етапи, визначаються параметри РБ-функцій і ваги $[w_{li}^{(2)}]$ другого каскаду. Позначимо через E_2 значення загального критерію після 2-го каскаду. Перевірка умови зупину: якщо а) $|E_2 - E_1| < \varepsilon$ або б) $E_2 > E_1$, то stop; синтез структури закінчується. В іншому випадку, перехід до синтезу 3-го каскаду. Послідовність ітерацій зупиняється на каскаді k , коли $E_{k+1} > E_k$, або $|E_{k+1} - E_k| < \varepsilon$ де ε – задана точність.

Задача класифікації даних в даний час є однією з найбільш актуальних сфер докладання систем штучного інтелекту. Для її вирішення були запропоновані різні підходи та напрямки, серед яких популярними є такі, що поєднують нейронні мережі та нечіткі системи логічного висновку. Одним з таких рішень є система NEFClass (Neuro-Fuzzy CLASSifier) (рис.3), заснована на узагальненій архітектурі нечіткого перцептрона [8].




Рисунок 3 – Структура мережі NEFClass

Модель NEFClass використовується для отримання нечітких правил з множини даних, які можна поділити на різні класи. Нечіткі правила описують дані у формі “R: якщо має функцію приналежності

$X_1 - \mu_1, X_2 - \mu_2, \dots, X_n - \mu_n$ ”, то зразок (x_1, x_2, \dots, x_n) належить класу i , де (μ_1, \dots, μ_n) – нечіткі множини. Завдання NEFClass полягає в тому, щоб визначити приналежність до класу $C \subset R^n$ вхідного зразка $x = (x_1, \dots, x_n) \in R^n$. Мається на увазі, що перетин двох різних множин є порожнім.

Система NEFClass має тришарову послідовну архітектуру. Перший шар U_1 містить вхідні нейрони, в яких представляються вхідні зразки. Активація a_x нейрона $x \in U_1$ зазвичай не змінює вхідне значення. Прихований шар U_2 містить нечіткі правила, і третій шар U_3 складається з вихідних нейронів кожного класу. Активація для нейронів правил $R \in U_2$ та для нейронів вихідного шару $c \in U_3$ із зразком p обчислюється так:

$$a_R^{(p)} = \min_{x \in U_1} \{W(x, R)(a_x^{(p)})\},$$

$$a_c^{(p)} = \sum_{R \in U_2} W(c, R)a_R^{(p)}, \quad \text{або альтернативно}$$

$a_c^{(p)} = \max_{R \in U_2} \{a_R^{(p)}\}$, де $W(x, R)$ – нечітка вага з'єднання вхідного нейрона x з нейроном правила R , а $W(R, c)$ – нечітка вага з'єднання нейрона правила R з нейроном вихідного шару c . Замість застосування операцій взяття максимуму і мінімуму можна використовувати інші функції t -норми і t -конорми відповідно.

База правил є апроксимацією невідомої функції $\phi: R^n \rightarrow \{0, 1\}^m$ і описує класифікаційну задачу, де $\phi(x) = (c_1, \dots, c_m)$ така, що $c_i = 1$, $c_j = 0$ ($j \in \{1, \dots, m\}$, $j \neq i$) та x належить класу C_i . Нечіткі множини та лінгвістичні правила представляють апроксимацію і визначають результат системи NEFClass. Вони виходять з множини вибірок шляхом навчання. Повинно виконуватися правило, що для кожного лінгвістичного значення може існувати тільки одне подання нечіткої множини. Функції належності, які використовуються: трикутні, трапецевидні або гаусові.

Висновки

В роботі вирішено важливу науково-практичну задачу – створення інтелектуальної системи на основі нової каскадної мережі для розпізнавання об'єктів на оптичних зображеннях.

Проведено аналіз існуючих методів для розпізнавання об'єктів на оптичних зображеннях та виявлено недоліки існуючих систем, внаслідок чого розроблено нову архітектуру та метод навчання каскадної радіально-базисної нейронної мережі, який полягає у тому, що процес знаходження оптимальних значень па-

раметрів КРБНМ розбивається на два етапи. На першому етапі оптимізуються нелінійні параметри РБ функцій, а на другому – ваги зв'язків нейронної мережі, завдяки чому знижується загальна вимірність задачі оптимізації та прискорюється робота алгоритму навчання.

На основі запропонованих моделей і методів, розробляється інтелектуальна комп'ютерна система для розпізнавання передаварійних ситуацій та ускладнень в процесі буріння нафтогазових свердловин, яка буде використовуватись для задач прогнозування та запобігання виникненню нештатних ситуацій в нафтогазовій промисловості.

Література

- 1 Julesz B. Visual pattern discrimination // IRE Trans. Inform. Theory. – 1962. Vol. IT-8. – P. 84-92.
- 2 Hayes K.C., Jr., Shah A.N., Rosenfeld A., Texture coarseness: Further experiments // IEEE Trans. Systems, Man, and Cybernetics (correspondence). – 1974. – SMC-4, 5. – P. 467-472.
- 3 Laws K. I. Rapid texture identification // Proc. SPIE. – 1980. – Vol. 238. – P. 376-380.
- 4 Kato Z., Zeroubia J., Berthod M. Unsupervised parallel image classification using Markovian models // Pattern Recognition. – 1999. – Vol. 32. – P. 591-604.
- 5 Уоссермен, Ф. Нейрокомпьютерная техника: Теория и практика. – М.: Изд. дом Мир, 1992. – 240 с.
- 6 Kononenko I., Bratko I. and Riskar E. Experiments in Automatic Learning of medical Diagnostic rules. – Ljubljana: Jozef Stefan Institute. – 1984. – 241p.
- 7 Broomhead, D. S.; Lowe, David (1988). Radial basis functions, multi-variable functional interpolation and adaptive networks (Technical report). RSRE. 4148.
- 8 Nauck, Detlef. A fuzzy perceptron as a generic model for neuro-fuzzy approaches / Proc. Fuzzy-Systeme'94, Munich, October 1994.

Стаття надійшла до редакційної колегії 07.06.18

Рекомендована до друку професором **Юрчишиним В.М.** (ІФНТУНГ, м. Івано-Франківськ) канд. техн. наук **Воциньским В.С.** (ТЗОВ СКБ ЗА, м. Івано-Франківськ)