

НЕЙРОМЕРЕЖЕВЕ РОЗПІЗНАВАННЯ ОПТИЧНИХ ОБРАЗІВ У СИСТЕМАХ СПЕЦІАЛЬНОГО ПРИЗНАЧЕННЯ

Проаналізовано математичний апарат розпізнавання оптичних образів; встановлено пріоритетний напрямок теоретичних досліджень у цьому науковому напрямкові – надання математичному апаратові розпізнавання “творчої” здатності, тобто можливості працювати за межами знань експерта та вміння самонавчатись. Запропоновано застосовувати для розпізнавання оптичних образів спеціальних систем – нейронні мережі. Розглянуто типові алгоритми розпізнавання образів: сприйняття образу (технічне вимірювання); попереднє опрацювання отриманого сигналу (фільтрація); виділення потрібних характеристик (індексація); класифікація образу (прийняття рішення). Синтезовано нейромережеву структуру та перевірено на адекватність відповідний багатoshаровий персептрон. З метою оптимізації нейронної мережі, корегування вагових коефіцієнтів (синапсів), використано генетичний алгоритм. Отримано достатню ефективність нейромережі. Синтезовано відповідний скриптинг на мові C++, який можна застосовувати у спеціальних системах реального часу.

Оптичний образ, нейронна мережа, перенавчання, адекватність, генетичний алгоритм, оптимізація.

Актуальність дослідження. Теорія і методи розпізнавання оптичних образів (картин) знайшли широке застосування у військовій справі. Предметом теорії є поняття “схожість” предметів і кількісна міра “схожості” [1]. У цій теорії немає аксіоматики і логічних схем. Замість цього використовуються прецеденти. До основних понять відносяться: навчальна множина (набір відомих прецедентів), множина реального часу (набір об’єктів чи явищ, які порівнюються з вже відомими прецедентами), ознаки (якісні та кількісні характеристики навчальної множини), вирішальне правило (алгоритм, що дозволяє віднести екзаменований об’єкт до одного з класів) і навчання (процедура, яка веде до формулювання вирішального правила). Розрізняють логічне розпізнавання, де обробка інформації виконується згідно чітко визначеним алгоритмом з метою виділення цінної інформації, і інтуїтивне розпізнавання, коли відбувається генерація цінної інформації [2]. Питання про те, якою мірою мислення людини зводиться до розпізнавання образів, у даний час є відкритим. Відзначимо лише, що вихід за межі професійного навчальної множини сприймається як акт творчості. Для систем спеціального призначення це особливо важливо, оскільки експертно встановити всю множину можливих ситуацій фактично неможливо. Саме тому вбачається доцільним застосування нейронних мереж, як математичного інструментарію здатного самонавчатися та отримувати нові знання у процесі свого штатного функціонування.

Мета досліджень. Обґрунтувати перспективність використання нейронних мереж для розпізнавання оптичних образів у системах спеціального призначення.

Основні матеріали досліджень. Розпізнавання образів включає у себе ряд кроків:

1. Сприйняття образу (технічне вимірювання).
2. Попереднє опрацювання отриманого сигналу (фільтрація).
3. Виділення потрібних характеристик (індексація).
4. Класифікація образу (прийняття рішення).

Стосовно першого кроку, то для розпізнавання оптичних образів, у якості сприймаючих елементів будуть тепловізори, радарні комплекси, камери зовнішнього спостереження тощо.

Для попереднього опрацювання (фільтрації) вхідних образів доцільно використати Вейвлет-аналіз, який базується на використанні вейвлетів, що являють собою математичні функції та дозволяють аналізувати різні частотні компоненти. У загальному випадку такий аналіз відбувається в площині: вейвлет коефіцієнт – час – рівень. Самі вейвлет коефіцієнти

визначаються інтегральним перетворенням сигналу. Отримані вейвлет-спектрограми принципово відрізняються від рядів Фур'є тим, що дають чітку прив'язку спектра особливостей сигналу до часу. Така функціональність нас влаштовує.

Третій та четвертий кроки розпізнавання образів, як правило, об'єднуються у системі розпізнавання образів (СРО), яка і є головним елементом такого інтелектуального комплексу. Алгоритм синтезу СРО є достатньо відпрацьованим:

1. Отримання тренувальної вибірки.
2. Вибір способу представлення даних та значимих характеристик.
3. Розробка класифікуючого критерію.
4. Навчання СРО.
5. Перевірка якості роботи із можливістю повернення до кроку 2 (або навіть і 1).
6. Оптимізація СРО.

Як відомо, протягом дослідження проблем розпізнавання образів виокремились два основні підходи – детерміністичний та статистичний. Перший включає в себе математичні формалізовані емпіричні і евристичні методи, другий базується на фундаментальних результатах математичної статистики. Однак, під час практичної реалізації відповідних інтелектуальних систем строго розподіли їх досить складно, а інколи і неможливо.

До проміжного класу СРО можна віднести і нейронні мережі (НМ). Традиційна для такого підходу щодо вирішення задач розпізнавання образів нейромережева архітектура – багат шаровий персептрон. Враховуючи налагодженість програмних засобів та здатність до адаптивного підлаштування в умовах динамічної розмитості технологічної інформації, саме цей математичний апарат і використаємо для створення СРО.

Навчання, продемонстроване на прикладі двошарового персептрона (рис. 1), зводиться до формування вагів зв'язків між першим і другим шарами відповідно до наступного алгоритму [3].

Крок 1. Проініціалізувати елементи вагової матриці (звичайно невеликими випадковими значеннями).

Крок 2. Подати на входи один з вхідних векторів, які мережа повинна навчитися розрізняти, і обчислити її вихід.

Крок 3. Якщо вихід правильний, перейти до кроку 4.

Інакше – обчислити різницю між ідеальним d і отриманим Y значеннями виходу:

$$\delta = d - Y. \quad (1)$$

Модифікувати вагу відповідно до формули:

$$w_{ij}(t+1) = w_{ij}(t) + \eta \delta x_i, \quad (2)$$

де: t і $(t+1)$ – номери відповідно поточної і наступної ітерації;

η – коефіцієнт швидкості навчання, $0 < \eta < 1$;

i - номер входу;

j - номер нейрона в шарі.

Очевидно, що якщо $d > Y$, то вагові коефіцієнти будуть збільшені і, тим самим, зменшать помилку. Інакше вони будуть зменшені, і Y теж зменшиться, наближаючись до d .

Крок 4. Цикл з кроку 2 продовжується, поки мережа не перестане помилятися.

На другому кроці на різних ітераціях по черзі у випадковому порядку пред'являються всі можливі вхідні вектори. На жаль, не можна наперед визначити число ітерацій, які потрібно виконати, а в деяких випадках і гарантувати повний успіх.

Збіжність розглянутої процедури встановлюється теоремами [4], стверджуючими, що для будь-якої класифікації навчальної послідовності можна підібрати такий набір (з нескінченного набору) елементарних нейронів, у якому буде здійснено розділення навчальної послідовності за допомогою лінійного вирішального правила, і якщо відносно задуманої класифікації можна знайти набір елементів, в якому існує рішення, то в рамках цього набору воно буде досягнуте в кінцевий проміжок часу.




Рис. 1. Двошаровий персептрон

У процесі синтезу та дослідження відповідних НМ застосуємо функціонального блоку оптимізації архітектури нейромоделей, який використовує лінійні підходи та метод “відпалювання” на основі розподілу ймовірностей Гіббса:

$$P(\bar{x}^* \rightarrow \bar{x}_{i+1} | \bar{x}_i) = \begin{cases} 1, F(\bar{x}^*) - F(\bar{x}_i) < 0 \\ \exp\left(-\frac{F(\bar{x}^*) - F(\bar{x}_i)}{Q_i}\right), F(\bar{x}^*) - F(\bar{x}_i) \geq 0 \end{cases}. \quad (3)$$

де $Q_i > 0$ – елементи довільно спадаючої до нуля послідовності.

У якості вхідних даних використаємо набори картинок. Умовно розділимо їх на дві групи (у випадку використання у якості сприймаючого елемента тепловізора): “образ людини” та “не образ людини”. Критерій – насиченість червоного кольору (або іншого кольору, який відображає тепло випромінювання). Очевидно, що у випадку реального розпізнавання однакових картинок ніколи не отримаємо. Ситуація ускладнюється тим, що майже завжди надходитиме зображення із шумами. Тобто обов’язково потрібна фільтрація сигналу.

Для спрощення апробації математичного апарату НМ прийемо, що отримуванні зображення матимуть розширення 5×5 та глибину кольору 1 біт. Можливі значення всередині пікселів прийемо фіксованими: 0, 0,5, 1. Картинки представимо в одній двовірній таблиці, застосувавши просте розвертання: кожному зображенню відповідає одне спостереження – рядок у таблиці даних; елементи рядка – значення відповідних пікселів в отримуваному із сприймаючого елемента сигналі (рис. 2). Останній стовпець – експертне визначення образу людини.

Під час навчання задали 5 прикладів “образ людини” та 5 прикладів “не образ людини”. Тобто отримали таблицю з 26 стовпцями $((5 \times 5) + 1 = 26)$ та 10 рядками.

Тип задачі – класифікацію. Значення пікселів задали неперервними змінними, що матиме місце у реальних умовах. Експертне визначення стиглості помідора – категоріальна змінна.

Данные: Obrazy_tren.sta* (26v * 10c)										
	18 NewVar8	19 NewVar9	20 NewVar10	21 NewVar11	22 NewVar12	23 NewVar13	24 NewVar14	25 NewVar15	26 Var10	
1	0,5	1	1	1	1	1	1	0,5	1	
2	1	1	1	1	1	0,5	0,5	1	1	
3	1	1	1	1	1	1	1	1	1	
4	1	1	1	1	0,5	0,5	1	1	1	
5	0	0	0	0	0	0	0	0	0	
6	0	0	0	0	0	0	0	0	0	
7	0	0	0,5	0,5	0,5	0	0	0	0	
8	0	0,5	0	0	0	0	0	0	0	
9	1	1	0,5	0,5	0,5	0	0	0	0	
10	1	1	1	1	1	1	1	1	1	

Рис. 2. Фрагмент тренувальної таблиці

Тип НМ, який використали для розпізнавання – чотирьохшаровий персептрон (ЧП).

Для ефективного моделювання вхідні дані розбили на три блоки: навчальний, контрольні, тестові. Наявність трьох блоків не є обов'язковою, однак тестовий блок покращує якість подальшої роботи, оскільки дає можливість впевнитись, що не відбулося “перенавчання” (overfitting) мережі.

Найкращий результат продемонстрував ЧП 5:5-8-8-1:1 (рис. 3). Він забезпечив продуктивність на всіх вибірках 1,0 – тобто максимальну, та вірно класифікував всі 10 образів.

На особливу увагу заслуговує те, що у процесі навчання модуль відбору входів, для заданого навчального набору даних, визначив як “значимі” лише 5 входів із початкових 25. Оптимізація конфігурації НМ реалізована на основі апарату генетичного алгоритму.

Задавши 5 наборів даних, на яких мережа не навчалась, було отримано 80% ефективність функціонування – вірно класифіковано 4 образи.




Рис. 3. Архітектура оптимального НМ-класифікатора

Якість роботи НМ не достатня, тому із врахуванням того, що експерименти по навчанню нейронних мереж показали, що відомі методи локальної та глобальної оптимізації (градієнтні, стохастичні, Ньютона, Гессе тощо) потребують значну кількість кроків навчання, чутливі до точності розрахунків, потребують значну кількість додаткових змінних, тому актуальною задачею є пошук та розробка нових методів навчання нейронних мереж [5].

Отже, виникає необхідність у застосуванні таких підходів, які б не мали зазначених недоліків. Серед оптимізаційних математичних апаратів у контексті поставленої задачі виділяється генетичний алгоритм (ГА).

Відзначимо основні відмінності ГА від стандартних алгоритмів оптимізації [6]:

- пошук субоптимального рішення, що базується на оптимізації випадково заданої множини рішень, а не одного рішення, що дозволяє одночасно аналізувати кілька шляхів наближення до екстремуму; оцінка таких рішень на кожному кроці дозволяє синтезувати нові рішення на основі старих, тобто відбувається еволюційний розвиток оптимальних рішень;

- рішення розглядаються як деякі закодовані структури, а не як сукупність параметрів, що дозволяє в деяких випадках значно зменшити час перетворення даних, тобто збільшити швидкість пошуку оптимальних рішень;

- для оцінки “придатності” рішення для подальшого еволюційного розвитку поряд з використанням цільової функції додатково моделюються “Правила виживання”, які підвищують різноманітність множини рішень і визначають еволюційний розвиток;

- при ініціалізації, перетворенні та інших видах операцій з рішеннями використовуються імовірнісні, а не детерміновані правила, які вносять генетичний пошук елементи випадковості; тим самим вирішується проблема виходу з локальних оптимумів;

- відсутня необхідність розрахунку похідних від цільової функції (як в градієнтних методах) або матриці похідних другого порядку (як в квазіньютонівських);

- некритичність до кількості компонентів вектора допустимого рішення.

Із застосуванням ГА було проведено визначення оптимальних вагових коефіцієнтів нейронної мережі типу багатошаровий персептрон (див. рис. 3) за допомогою генетичного алгоритму з наступними параметрами: кількість хромосом в популяції – 10; кількість популяцій – від 20 до 100; оператор схрещування – одно точковий кросинговер; процент генної мутації – 0,001; відбір – елітний. На рисунку 4 зображена ймовірність знаходження екстремумів функції від заданої кількості популяцій.

З отриманих результатів видно, що швидкість наближення до екстремуму висока і зростає із збільшенням кількості популяцій. Також можна зробити висновок про низький відсоток експериментів, в яких було отримано точне значення мінімуму, в залежності від загальної кількості запусків генетичного алгоритму, тобто від кількості популяцій.




Рис. 4. Ймовірність знаходження екстремумів функції при заданій кількості популяцій

Задавши наступні перевіряльні набори отримали якість класифікації – 100%.

Завершальним кроком стало генерування програмного коду на мові “C++”, для можливого практичного використання синтезованої та оптимізованої НМ у системах реального часу (рис. 5).

```
/* Initialise hidden unit activation to zero */
101Acts[5+u] = 0.0;
/* Accumulate weighted sum from inputs */
for (i=0; i < 5; ++i)
    101Acts[5+u] += *w++ * 101Acts[0+i];
/* Subtract threshold */
101Acts[5+u] -= *t++;

/* Now apply the hyperbolic activation function, ( e^x - e^-x ) / ( e^x + e^-x ).
 * Deal with overflow and underflow
 */
if ( 101Acts[5+u] > 100.0 )
    101Acts[5+u] = 1.0;
else if ( 101Acts[5+u] < -100.0 )
    101Acts[5+u] = -1.0;
else
{
    double e1 = exp( 101Acts[5+u] ), e2 = exp( -101Acts[5+u] );
    101Acts[5+u] = ( e1 - e2 ) / ( e1 + e2 );
}
```

Рис. 5. Фрагмент скриптіngu на мові “C++” синтезованого та оптимізованого НМ-класифікатора образів

Висновок. Враховуючи встановлену достатню якість функціонування НМ-класифікатора оптичних образів, при оптимізації мережі із використанням генетичного алгоритму, та можливість генерування відповідного програмного коду на мові “C++” для використання у системах реального часу, апарат нейронних мереж, а саме багатошаровий перцептрон, доцільно використовувати для встановлення (класифікації) оптичних образів у системах спеціального призначення.

ЛІТЕРАТУРА:

1. Бабаков М.Ф. Методы машинного моделирования в проектировании электронной аппаратуры / М.Ф. Бабаков, А.В. Попов. – Х.: НАЭКУ “ХАИ”, 2002. – 89 с.
2. Фукунава К. Автоматическое распознавание образов / К. Фукунава. – М.: Наука, 1979. – 367 с.
3. Лисенко В.П. Ймовірнісна (Байєсівська) нейронна мережа класифікації температурних образів / В.П. Лисенко, В.М. Штепа, А.О. Дудник // Вісник аграрної науки. – К.: НААН. – 2011. – № 4. – С. 53-56.
4. Лисенко В.П. Застосування теорії статистичних рішень та ймовірнісної нейронної мережі для класифікації температурних образів / В.П. Лисенко, В.М. Штепа, Б.Л. Головінський, А.О. Дудник, Н.А. Засць // Тези доповідей міжнародної науково-практичної конференції “Інтелектуальні системи прийняття рішень і проблеми обчислювального інтелекту”. – Херсон: ХНТУ. – 2011. – С. 274 – 278.
5. Рідкокаша А.А. Основи систем штучного інтелекту. Навчальний посібник / А.А. Рідкокаша, К.К. Голдер. – Черкаси: “ВІДЛУННЯ-ПЛЮС”, 2002. – 240 с.
6. Круглов В.В. Искусственные нейронные сети. Теория и практика / В.В. Круглов. – М.: Горячая линия – Телеком, 2002. – 382 с.

Рецензент: д.т.н., проф. Лєнков С.В., начальник науково-дослідного центру Військового інституту Київського національного університету імені Тараса Шевченка

д.т.н., проф. Шворов С.А., Штепа В.М., Заец Н.А.
**НЕЙРОСЕТЕВОЕ РАСПОЗНАВАНИЕ ОПТИЧЕСКИХ ОБРАЗОВ В СИСТЕМАХ
СПЕЦИАЛЬНОГО НАЗНАЧЕНИЯ**

Проанализирован математический аппарат распознавания оптических образов; установлено приоритетное направление теоретических исследований в этом научном направлении - предоставление математическому аппарату распознавания "творческой" способности, т.е. возможности работать за пределами знаний эксперта и умение самообучаться. Предложено применять для распознавания оптических образов специальных систем - нейронные сети. Рассмотрены типичные алгоритмы распознавания образов: восприятие образа (техническое измерение); предварительную обработку полученного сигнала (фильтрация); выделения нужных характеристик (индексация; классификация образа (принятия решения). Синтезирована нейросетевая структура и проверено на адекватность соответствующий многослойный перцептрон. С целью оптимизации нейронной сети, корректировки весовых коэффициентов (синапсов), использовано генетический алгоритм. Получена достаточная эффективность нейросети. Синтезированы соответствующий скриптинг на языке C ++, который можно применять в специальных системах реального времени.

Ключевые слова: оптический образ, нейронная сеть, переобучение, адекватность, генетический алгоритм, оптимизация.

S. Shvorum, V. Shtepa, N. Zaiets

NEURAL NETWORK OPTICAL PATTERN RECOGNITION IN SYSTEMS SPECIAL

Analysis of the mathematical apparatus of recognition optical images; set priority area of theoretical research in this scientific direction - providing mathematical device recognition "creative" ability, ie the opportunity to work outside expert knowledge and skills learns. Offered to apply for recognition of optical images of specific systems - neural network. Typical pattern recognition algorithms: the perception of the image (the technical measure); pre- processing of the received signal (filtering); selection of appropriate (indexation); image classification (decision). Neural network structure were synthesized and tested for adequacy suitable multilayer perceptron. In order to optimize the neural network weights adjustment coefficients (synapses), genetic algorithms . Sufficient performance neural network. Synthesized corresponding scripting in C ++, which can be applied to specific real-time systems .

Keywords: optical image, neural network, conversion, adequacy, genetic algorithm optimization.