

УДК 004.8

ОПТИМІЗАЦІЯ НАВЧАННЯ НЕЙРОННОЇ МЕРЕЖІ ЗА ДОПОМОГОЮ ГЕНЕТИЧНОГО АЛГОРИТМУ

В. А. Панчук, Д. Ю. Лебедев, канд. техн. наук, доц.

Національний технічний університет України «Київський політехнічний інститут»

victor.panchuk@gmail.com

Проаналізовано існуючі методи, використовувані для обробки зображень. На основі даних, отриманих зі знімків магнітно-резонансної томографії можна створити автоматичну систему діагностики захворювань. У процесі моделювання в програмному пакеті MatLab v R2007b було досліджено швидкість навчання мережі від кількості нейронів у прихованому шарі для звичайного методу зворотного поширення помилки та оптимізованого — в поєднанні з генетичним алгоритмом. У результаті дослідження підтвердилась перевага об'єднаного методу для задачі класифікації зображень. Даний метод удвічі зменшує кількість навчальних впливів та потребує меншої кількості нейронів у прихованому шарі, що значно полегшує архітектуру мережі і зменшує кількість обчислювальних витрат.

Ключові слова: нейронна мережа, перцептрон, зворотне поширення помилки, генетичний алгоритм.

It analyzes the existing methods for image processing. These solutions allow you to create an automated system for diagnosing diseases based on data obtained from images of magnetic resonance imaging. Satisfy the requirements of the system diagnostic neural network based on three - layer perceptron. The architecture of the network with 25 input neurons needed to improve the reliability and flexibility of making diagnostic system. In the process simulation software package MatLab v R2007b, were investigated speed of network training on the number of neurons in the hidden layer for the conventional method of back propagation and optimized - combined with genetic algorithm. A study confirmed the advantage of the combined method for image classification task. This method halves the number of training effects and requires fewer neurons in the hidden layer, which facilitates network architecture and reduces computational cost.

Keywords: neural network, perceptron, back propagation algorithm, genetic algorithm.

Вступ

Магнітно-резонансна томографія (МРТ) — один із перспективних методів сучасної нейро-рентгенології. За останнє десятиліття він став рутинним діагностичним методом. Спираючись на останні досягнення електроніки, криогенної техніки і новітні інформаційні технології, МРТ дає змогу отримати зображення, які можна порівняти за якістю з гістологічними зрізами, а час повної діагностики пацієнта можна знизити до декількох хвилин.

Постановка проблеми

З метою забезпечення можливості постійного вдосконалення діагностичної системи в ній може застосуватися блок самонавчання. Цей блок може бути реалізований із застосуванням різних методів штучного інтелекту — від кластерного аналізу до систем продукції і нейронних мереж. Його завдання за скоригованими лікарем остаточними діагнозами накопичувати інформацію задля розширення можливостей підсистеми, формування висновків і підвищення точності функціонування системи загалом.

У пропонованій статті досліджено архітектуру розробленої нейронної мережі на основі перцептрону з одним прихованим шаром, описаним в праці [1], який успішно зарекомендував себе

під час розв'язання задачі розпізнавання образів. Вхідні дані (МРТ знімки пацієнтів в архівах даних) постійно доповнюються та оновлюються, тому нейронна мережа потребує регулярного навчання. Залежно від архітектури мережі та кількості таких даних, процес навчання навіть на сучасних комп'ютерах займає від декількох хвилин до днів, тому потребує оптимізації.

Аналіз досліджень та публікацій

Залежно від способу навчання мережі (навчання з учителем, без вчителя, з підкріпленням) застосовують відповідні методи подальшої оптимізації [1], [2].

Мета більшості з них — мінімізація значення деякої цільової функції. Найчастіше роль цієї функції виконує зміна значення сумарно-квадратичної помилки (SSE — *sum squared error*) [3]. Наведемо приклади основних алгоритмів:

Зворотне поширення помилки — найбільш широко використовуваний метод навчання з учителем для багатшарових нейронних мереж [4].

Квазіньютонівські методи — методи оптимізації, засновані на накопиченні інформації про кривизну цільової функції за спостереженнями за зміною градієнта, чим принципово відрізняються від ньютонівських методів. Клас квазіньютонівських методів виключає явне формування

матриці Гессе, замінюючи її деяким наближенням [5].

Метод сполучених градієнтів — метод знаходження локального мінімуму функції на основі інформації про її значення та її градієнт [6].

Генетичний алгоритм — евристичний алгоритм пошуку, що використовується для вирішення завдань оптимізації та моделювання. Є різновидом еволюційних обчислень, за допомогою яких розв'язуються оптимізаційні задачі з використанням методів природної еволюції, таких як успадкування, мутації, відбір і кросинговер [6].

Для застосування у нейронних мережах існує багато модифікацій генетичного алгоритму, а саме: генетичний адаптивний алгоритм для навчання нейронних мереж (*The genetic adaptive neural network training GANTT*) [7], [8]; генетичний алгоритм з вейвлет перетворенням [9]; гібридний алгоритм (*A Hybrid Memetic Algorithm (Genetic Algorithm and Great Deluge Local Search)*) [10] та об'єднаний метод зворотного поширення помилки з генетичним алгоритмом [11].

Розробка архітектури нейронної мережі та вибір методу навчання

Як об'єкт дослідження обрано нейронну мережу з прямим поширенням сигналу на основі «класичного» перцептрон з одним прихованим шаром.

Під час аналізу текстури зображення вхідні дані являють собою матриці значень яскравості пікселів у вікні певного розміру, які також подаються у вигляді матриць, як вхідні зразки і навчальні впливи для моделі застосовані бітові матриці.

Розмір аналізованої матриці був обраний рівним 5×5 , зразків побудовано $N = 25$, таким чином, в аналізованих нейронних мережах є 25 входів (за розміром матриці) і $C = 25$ виходів (за кількістю класів) (рис. 1).

З урахуванням обраного методу навчання нейронної мережі (а це метод зворотного поширення помилки) вибираються типи активаційних функцій нейронів.

Оскільки вибраний метод навчання використовує градієнтний метод оптимізації, як активаційні функції нейронів обрані гладкі функції типу сигмоїд.

З метою забезпечення максимальної швидкості навчання першочерговим завданням є вибір оптимальної кількості нейронів у прихованому шарі. Для цього проводилося навчання нейронної мережі з такими параметрами:




Рис. 1. Досліджуваний перцептрон з прямими зв'язками:

$X_1 - X_{25}$ — вхідні нейрони; $Y_1 - Y_{25}$ — вихідні нейрони; Δw — зміна вагових коефіцієнтів; δ — локальний градієнт; M — кількість прихованих нейронів

1. Кількість нейронів у прихованому шарі 5, 10, 15 і 20(M).

2. Тип норми помилки вагових коефіцієнтів синаптичних зв'язків — сумарно-квадратична помилка (SSE — *sumsquarederror*).

3. Значення норми помилки розраховується за формулою (4.42), взятою з праці [1]:

$$E_{av}(n) = \frac{1}{2N} \sum_{n=1}^N \sum_{j \in C} e_j^2(n), \quad (1)$$

де e_j — різниця між бажаним та поточним сигналом на вихідному нейроні.

Згідно з результатами експериментів у працях [8] та [9] візьмемо $E_{av}(n) = 0,1$. Крім того, надмірна кількість впливів призводить до перенавчання мережі, а це є негативним явищем [1].

4. Кількість класифікованих класів — 25.

5. Умова припинення процесу навчання — досягнення значення унормованої помилки нижче заданого, або перевищення максимального числа поданих вхідних впливів (5000).

Моделювання та аналіз моделей класифікуючих нейронних мереж

Для проведення експериментів з текстурною сегментацією та оптимізацією навчання були побудовані моделі, які відображають основні параметри і залежності.

Як інструмент при побудові та дослідженні моделей обрано пакет фірми *Math Works Inc. MatLabvR2007b*.

Моделі нейронних мереж будувалися за допомогою блоку *Neural Network Toolbox*. Мережа з прямими зв'язками (*feed-forward*) створюється за допомогою вбудованої функції *newff*. Як активаційні функції нейронів ставиться сигмоїд-тansig [12].

Експеримент № 1. Метод оптимізації для алгоритму зворотного поширення помилки — градієнтний *traingdx*. Для першого експерименту отримані результати, відображені на рис. 2.

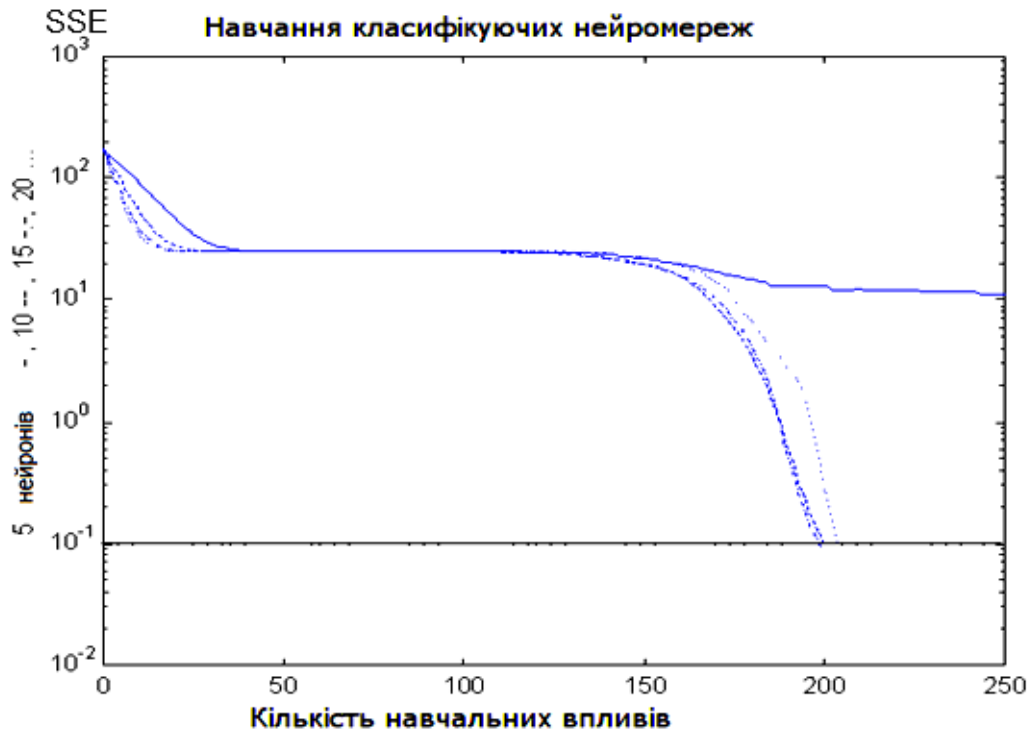


Рис. 2. Залежність швидкості навчання нейронних мереж від кількості нейронів у прихованому шарі для мережі (метод оптимізації — градієнтний зворотного поширення помилки)

Як видно з графіка на рис. 2, за числа нейронів, що дорівнює 5 — нейронна мережа навчається дуже повільно. В окремих випадках потребується більше 5000 навчальних впливів для досягнення заданого значення норми помилки ваг синаптичних зв'язків. У разі збільшення чис-

ла нейронів до 10 швидкість навчання стрімко зростає. При 15 прихованих нейронах швидкість у даному експерименті досягає максимуму. За подальшого збільшення числа нейронів, швидкість навчання починає повільно знижуватися. Всі дані цього експерименту зведені в таблицю.

Залежність необхідного числа навчальних впливів від числа нейронів у прихованому шарі при (SSE = 0,1)

Число нейронів у прихованому шарі	Число навчальних впливів (тільки градієнтний метод)	Число навчальних впливів (комбінований метод)
5	2866	124
10	200	74
15	199	75
20	204	78
25	223	89

Під час тестування мережі виявилось, що при використанні в ролі функції активації нейронів вихідного шару сигмоїдальної функції, мережа дуже часто потрапляє в локальний мінімум і досягти необхідного значення норми помилки не вдається.

Для виходу з такої ситуації довелося замінити сигмоїдальні функції активації нейронів вихідного шару на лінійні (*purelin*). Після заміни функцій активації мережа перестала зациклюватися на локальних мінімумах.

Експеримент № 2. Комбінований метод оптимізації на основі генетичного алгоритму та зворотного поширення помилки.

Цей метод виконується в два етапи. Спочатку використовується генетичний алгоритм для пошуку області з глобальним мінімумом. В експерименті кожна хромосома являє собою розподіл вагових коефіцієнтів мережі. Таким чином, популяція хромосом це сукупність наборів різноманітних вагових коефіцієнтів синаптичних зв'язків усіх мереж.

Використовуючи стандартні операції кросингвер (схрещення) та мутації, на кожній ітерації відбираються кращі хромосоми з найменшим значенням цільової функції $E_{av}(n)$. Більш детально даний алгоритм описано в праці [2].

Перевагою генетичного методу є швидке зменшення цільової функції на початковій фазі процесу оптимізації. Проте вже знаходячись в області точки мінімуму, швидкість знаходження оптимального розв'язку спадає по експоненті. Тому початкова популяція не повинна бути надто чисельною, у нашому експерименті було використано 50 хромосом.

Для практичної реалізації генетичного алгоритму використано псевдокод із праці [13]. Пошук відбувається до досягнення певного значення цільової функції $E_{av}(n)$.

Далі в дію вступає градієнтний метод оптимізації, для детального пошуку глобального мінімуму.

Проаналізувавши результати першого експерименту, видно, що при досягненні $E_{av}(n) = 0,7$ градієнтний метод стає ефективним, оскільки крива навчання має найбільший нахил.

Результати другого експерименту відображено на рис. 3.

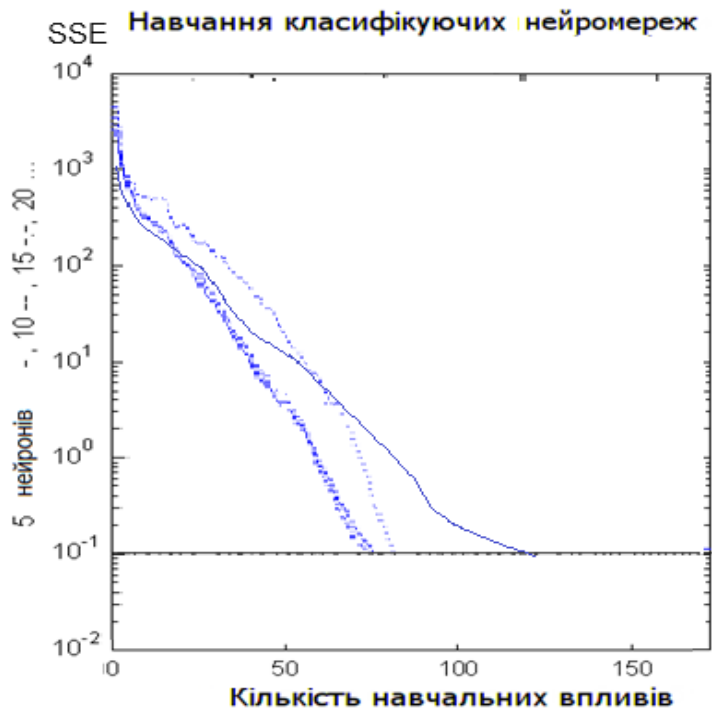


Рис. 3. Залежність швидкості навчання нейронних мереж від кількості нейронів у прихованому шарі для мережі (метод оптимізації — комбінований генетичний алгоритм та градієнтний метод)

Як видно з графіка на рис. 3, комбінований метод майже вдвічі зменшує кількість навчальних впливів для всіх зразків мережі. Отже, помітно, що на стадії дії генетичного алгоритму (до $SSE = 0,7$) кращу динаміку показують мережі з меншою кількістю прихованих нейронів.

Усі дані другого та першого експериментів зведено в таблицю, наведену вище. Як видно з таблиці і графіків, при застосуванні нейронних мереж для текстурної сегментації МРТ знімків, найбільш доцільним є вибір мережі з прямими зв'язками, що має 10 нейронів у прихованому шарі та використання комбінованого методу оптимізації навчання, оскільки при цьому досягається мінімізація кількості навчальних впливів, необхідних для досягнення необхідної норми помилки вагових коефіцієнтів синаптичних зв'язків.

Висновки

У роботі було досліджено методи розв'язання задачі текстурної сегментації зображення за допомогою нейронних мереж. Проаналізувавши існуючі розв'язки вирішено використовувати багатошаровий перцептрон з прямими синаптичними зв'язками та одним прихованим шаром. Серед багатьох методів навчання обрано метод зворотного поширення помилки, модифікований для навчання багатошарових нейронних мереж та оптимізованого методу на основі комбінації генетичного алгоритму з градієнтним. Перевагою методу зворотного поширення помилки є його простота, але при його застосуванні процес навчання може зациклитися на деякому значенні локального мінімуму, оскільки використовується градієнтна процедура оптимізації.

Щоб уникнути даної проблеми, можна використати комбінований метод — генетичний алгоритм для початкового пошуку області з глобальним мінімумом і більш точного знаходження значення цього мінімуму за допомогою градієнтного методу. Крім того при застосуванні комбінованого методу можна більше ніж удвічі скоротити кількість навчальних впливів на мережу та зменшити її час навчання.

Подальший вектор досліджень спрямований на оптимізацію методів навчання нейронних мереж за допомогою квазіньютонівських методів оптимізації, сучасних модифікованих методів на основі генетичного алгоритму. Також дані методи можна застосувати для зменшення кількості помилок розпізнавання зображень із шумом та артефактами, попередньо використовуючи апроксимацію та фільтрацію зображень.

ЛІТЕРАТУРА

1. Хайкин С. Нейронные сети: полный курс / С. Хайкин. — 2-е изд. : пер. с англ. — М. : Издательский дом «Вильямс», 2006. — 1104 с.
2. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы: пер. с польск. И. Д. Рудинского / Д. Рутковская, М. Пилиньский, Л. Рутковский. — М. : Горячая линия-Телеком, 2006. — 452 с.
3. Zhen-Guo Che. Feed-forward neural networks training: a comparison between genetic algorithm and back-propagation learning algorithm / Che Zhen-Guo, Chiang Tzu-An and Che Zhen-Hua // International Journal of Innovative Computing, Information and Control Volume 7, Number 10, October 2011.
4. Randall S. Sexton. Toward global optimization of neural networks: a comparison of the genetic algorithm and back propagation /. Sexton Randall S, Dorsey Robert E., and John D. Johnson // Songnian et al. BMC Neuroscience 2010
5. Ahmed Kharat. A Hybrid Approach for Automatic Classification of Brain MRI Using Genetic Algorithm and Support Vector Machine/ Kharat Ahmed, GasmiKarim // Leonardo Journal of Sciences July-December 2010. — С. 71–82.
6. Randall S. Sexton and Robert E. Dorsey. Reliability Classification Using Neural Networks: A Genetic Algorithm and Backpropagation Comparison.
7. Dorsey RE. The genetic adaptive neural network training (GANNT) for generic feed-forward artificial neural systems / RE Dorsey, JD Johnson, WJ Mayer // School of Business Administration, University of Mississippi, University.
8. Sexton RS. Optimization of neural networks: a comparative analysis of the genetic algorithm and simulated annealing / RS Sexton, RE Dorsey, JD Johnson // European Journal of Operational Research 1999; 114:589±601.
9. Ahmed Kharat. Automated Classification of Magnetic Resonance Brain Images Using Wavelet Genetic Algorithm and Support Vector Machine / Kharat Ahmed, Gasmi Karim, Abid Mohamed // Leonardo Journal of Sciences July-December 2011. — P. 369–374.
10. Usama A. Badawi. A Hybrid Memetic Algorithm (Genetic Algorithm and Great Deluge Local Search) With Back-Propagation Classifier for Fish Recognition / Badawi Usama A., Khalil Mutasem, Alsmadi Sari // IJCSI International Journal of Computer Science Issues, Vol. 10, Issue 2, No 1, March, 2013.
11. Hiroaki Kitano. Empirical Studies on the Speed of Convergence of Neural Network Training using Genetic Algorithms / Kitano Hiroaki // From: AAI-90 Proceedings. Copyright ©1999.
12. JIRI STASTNY*, VLADISLAV SKORPIL*. Genetic Algorithm and Neural Network // Proceedings of the 7th WSEAS International Conference on Applied Informatics and Communications, Athens, Greece, August 24–26, 2007.
13. Дьяконов В. П. MATLAB 6.5 SP1/7/7 SP1/7 SP2 + Simulink 5/6. Инструменты искусственного интеллекта и биоинформатики/ В. П. Дьяконов, В. В. Круглов. — М. : СОЛОН-ПРЕСС, 2006. — 456 с.

Стаття надійшла до редакції 06.06.2013