

ЗАСТОСУВАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ТЕКСТУРНОЇ СЕГМЕНТАЦІЇ МРТ - ЗНІМКІВ

Кафедра конструювання електронно-обчислювальної апаратури
Національний технічний університет України "КПІ"

Проведено аналіз існуючих методів для обробки зображень. Дані рішення дозволяють створити автоматичну систему діагностики захворювань на основі даних, отриманих із знімків магнітно-резонансної томографії. Вимогам системи діагностики задовольняють нейронні мережі на основі трьох - шарового перцептронів з каскадною або звичайною топологією. У процесі моделювання в програмному пакеті MatLab v R2007b, були досліджені швидкість навчання мережі від кількості нейронів у схованому шарі і значення відсотку похибки розпізнавання даних мереж в залежності від шуму зображення. У результаті дослідження з'ясувалося, що найбільш швидко навчалась мережа з прямими зв'язками - 199 навчальних впливів при кількості нейронів у прихованому шарі 15. Проте перцептрон з зворотними зв'язками є більш стійкішим до шуму.

Вступ

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

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

У пропонованій статті описана архітектура розробленої нейронної мережі на основі перцептронів з одним прихованим шаром описаного в [1], який успішно зарекомендував себе при вирішенні задачі розпізнавання образів. Також були досліджені залежність швидкості навчання мережі від

кількості нейронів у схованому шарі та значення похибки розпізнавання даних мереж в залежності від шуму зображення та структури зв'язків між нейронами.

Методи обробки МРТ – знімків

Сучасне МРТ обладнання дозволяє отримувати двовимірне та тривимірне зображення внутрішніх органів. Проте, яким би не було досконалим діагностичне обладнання, завжди будуть існувати чинники, що знижують достовірність і цінність переданої інформації. Помилки оператора, рухи пацієнта та інші зовнішні впливи призводять до небажаних спотворень і шумів на зображеннях при МРТ діагностиці внутрішніх органів. Також серйозно впливає на якість зображення неоднорідність середовища. У зв'язку з цим у діагностичних системах виникає потреба в попередній обробці отриманих діагностичних даних.

Для оптимізації двовимірних цифрових зображень використовують лінійні та нелінійні фільтри в просторовій та частотній області описані в [2]. Особливої уваги заслуговують фільтри для виділення границь однорідних областей на зображенні, наприклад фільтри Прюїта (*Prewitt*) та Собеля (*Sobel*) [2].

Для відновлення тривимірних зображень використовують ітеративний алгоритм апроксимації Кронекерового добутку матриць, описаного в [3]. Добуток Кронекера

ра також використовують для ефективного перетворення вихідних зображень в бітові матриці даних, що використовуються в нейронних мережах [4].

Для автоматичної класифікації та сегментації МРТ – знімків відомо багато методів та технологій. Можна виділити два основні напрямки досліджень. Перший напрямок - використання методу опорних векторів (англ. *Support vector machine SVM*) в поєднанні з генетичним алгоритмом [5] та вейвлет перетворенням [6]. Інший - використання нейронних мереж на основі самоорганізаційної карти Кохонена (англ. *Self-organizing map – SOM*) [7], [8] та багатошарового перцептрону з класифікатором нечітких множин (*Neuro-fuzzy classifier*) [9], [10].

Розробка архітектури нейронної мережі та вибір методу навчання

В якості об'єктів дослідження обрані нейронні мережі з прямими і з каскадними зв'язками на основі «класичного» перцептрону з одним прихованим шаром. Так, як при аналізі текстури зображення, вхідні дані являють собою матриці значень яскравості пікселів у вікні певного розміру, які також подаються у вигляді матриць, в якості вхідних зразків і навчальних впливів для моделі застосовані бітові матриці. Розмір аналізованої матриці був обраний рівним 5x5, зразків побудовано $N = 25$, таким чином, в аналізованих нейронних мережах є 25 входів (за розміром матриці) і $C = 25$ виходів (по кількості класів) (рис. 1, 2).

З урахуванням обраного методу навчання нейронної мережі - а це метод зворотного поширення помилки - вибираються типи активаційних функцій нейронів. Так як вибраний метод навчання використовує градієнтний метод оптимізації, в якості активаційних функцій нейронів обрані гладкі функції типу сигмоїд.

Першочерговим завданням є вибір оптимальної кількості нейронів у прихованому шарі, з метою забезпечення максимальної швидкості навчання. Для цього проводилося навчання нейронних мереж з наступними параметрами:

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 – sum squared error*).
3. Значення норми помилки вираховується з формули 4.42 взятої з [1]:

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

де e_j – різниця між бажаним та поточним сигналом на вихідному нейроні. Згідно результатів експериментів в [1] та [10] прийmemo $E_{av}(n) = 0.1$ Також надмірна кількість впливів призводить до перенавчання мережі – що 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).




Рис. 1. Досліджуваний перцептрон (мережа 1) з прямими зв'язками




Рис. 2. Досліджуваний перцептрон (мережа 2) з каскадними (зворотними) зв'язками

де $X_1 - X_{25}$ - вхідні нейрони, $Y_1 - Y_{25}$ - вихідні нейрони, Δw – зміна вагових коефіцієнтів, δ – локальний градієнт, M – кількість прихованих нейронів.

Моделювання та аналіз моделей класифікуючих нейронних мереж

Для проведення експериментів з текстурною сегментацією і класифікації зображень із застосуванням нейронних

мереж були побудовані моделі, які відображають основні параметри і залежності. В якості інструменту при побудові та дослідженні моделей був обраний пакет фірми MathWorksInc. MatLab v R2007b

Моделі нейронних мереж будувалися за допомогою блоку Neural Network Toolbox [11].

Мережа з прямими зв'язками (feed-forward) створюється за допомогою вбудованої функції newff, каскадна мережа

- за допомогою функції newscf. В якості активаційних функцій нейронів ставиться сигмоид - tansig. Метод оптимізації для алгоритму зворотного поширення помилки - градієнтний traingdx.

Для мережі з прямими зв'язками були отримані наступні результати, відображені на рисунку 3.

Для мережі з каскадними зв'язками залежність кількості прихованих нейронів від кількості навчальних впливів представлена на рис.4.




Рис. 3. Залежність швидкості навчання нейронних мереж від кількості нейронів у прихованому шарі для мережі з прямими зв'язками




Рис. 4. Залежність швидкості навчання нейронних мереж від кількості нейронів у прихованому шарі для мережі з каскадними зв'язками

Як видно з графіка на рис. 3, при числі нейронів, рівному 5 - нейронна мережа

навчається дуже повільно. В окремих випадках вимагається більше 5000 навчаль-

них впливів для досягнення заданого значення норми помилки ваг синаптичних зв'язків. При збільшенні числа нейронів до 10 швидкість навчання різко зростає. При 15 прихованих нейронах швидкість в да-

ному експерименті досягає максимуму. При подальшому збільшенні числа нейронів, швидкість навчання починає повільно знижуватися. Всі дані цього експерименту зведені в таблицю 1, наведену нижче.

Таблиця 1. Залежність необхідного числа навчальних впливів від числа нейронів у прихованому шарі при $SSE=0.1$:

Число нейронів в прихованому шарі	Число навчальних впливів (<i>feed-forward network</i>)	Число навчальних впливів (<i>cascadenetwork</i>)
5	2866	966
10	200	500
15	199	669
20	204	366
25	223	441

Як видно з таблиці і графіків, найбільш доцільним є вибір мережі з прямими зв'язками, що має 15 нейронів у прихованому шарі, так як при цьому досягається мінімізація кількості навчальних впливів, необхідних для досягнення необхідної норми помилки вагових коефіцієнтів синаптичних зв'язків.

Виходячи з тих же міркувань, що і для нейронної мережі з прямими зв'язками, можна вибрати число нейронів у прихованому шарі для каскадної мережі. Найбільша продуктивність при навчанні досягається для мережі з каскадними зв'язками, при 20-ти нейронах у прихованому шарі.

При тестуванні мережі з каскадними зв'язками виявилось, що при використанні в якості 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. Однак з'ясувалося, що для нейронної мережі з каскад-

ними зв'язками потрібна більша кількість навчальних впливів в порівнянні з мережею з прямими зв'язками, щоб досягти тієї ж норми помилки вагових коефіцієнтів.

Для з'ясування поведінки нейронних мереж при розпізнаванні вхідних зашумлених зразків, кожна мережа піддавалася 10 проходкам навчання з шумом рівня до 0.2 від умовної потужності сигналу (для значень 0 і 1 це становить 0.2). Для зберігання за мережами можливості розпізнавання незашумлених зразків, кожна нейрона мережа піддавалася після навчання з шумом, по одному проходу з оригінальною вибіркою.

При навчанні з шумом параметри залишилися такими ж, крім норми помилки і максимального числа підданих впливів.

1. Норма помилки (SSE) 0.6 (так як навчання з розпізнаванням зашумлених зразків)
2. Максимальне число впливів - 300

Візуально функціонування нейронних мереж при розпізнаванні зашумлених зразків показано на рисунку 5.

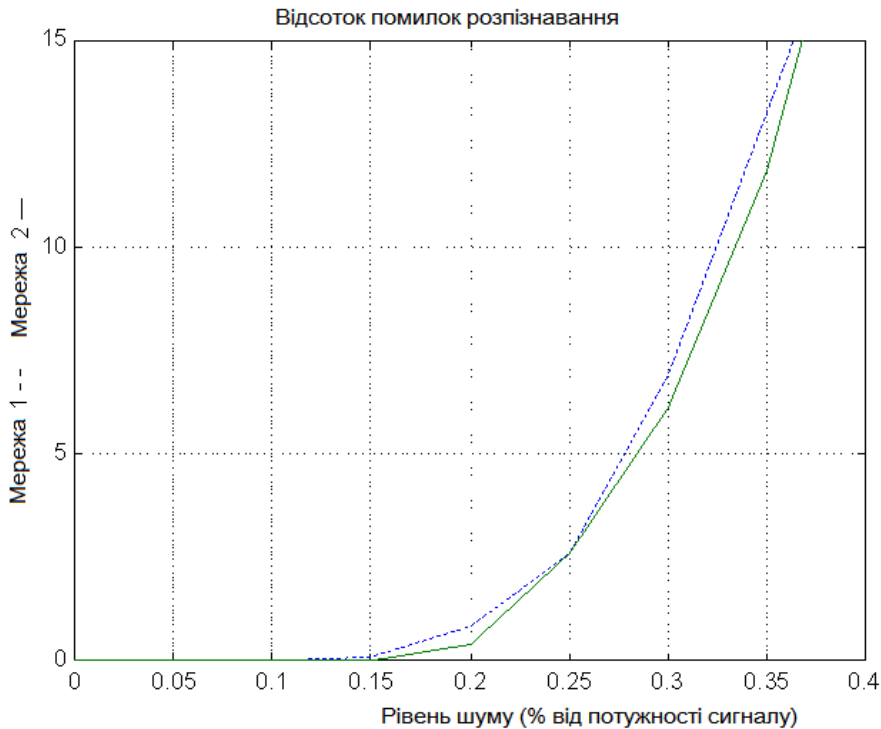


Рис.5 – Відсоток помилок при класифікації зашумлених зразків нейронними мережами

Як видно з графіка на малюнку 5, нейронна мережа з каскадними зв'язками дає дещо кращі результати при класифікації зразків з шумом. Але, якщо 1-2 відсотки помилок не будуть критичними при функціонуванні блоку побудови текстурних моделей, то рекомендується все ж застосовувати нейронну мережу з прямими зв'язками.

Висновки

У роботі досліджено методи розв'язання задачі текстурної сегментації зображення за допомогою нейронних мереж. Проаналізувавши існуючі рішення, було вирішено використовувати топологію мереж з прямими і каскадними зв'язками. Серед багатьох методів навчання, було обрано метод зворотного поширення помилки, модифікований для навчання багат шарових нейронних мереж. Даний метод, звичайно ж, не ідеальний. Так як використовується градієнтна процедура оптимізації, то процес навчання може зациклитися на якомусь значенні локального мінімуму. Але цей недолік легко усувається вибором іншої початкової точки або зміною активаційної функції нейронів. Мережа з прямими зв'язками потребує

вдвічі менше навчальних епох, але каскадна топологія менше піддається впливу шуму. Ефективність навчання максимальна для 15 -20 нейронів в прихованому шарі, при кількості інформаційних входів 25.

Подальший вектор досліджень спрямований на оптимізацію методів навчання нейронних мереж за допомогою математичних методів оптимізації – генетичного алгоритму, квазіньютонівських методів оптимізації. Також дані методи можна використати для зменшення кількості помилок розпізнавання зображень з шумом та артефактами, попередньо використовуючи апроксимацію та фільтрацію зображень

Список літератури

1. Хайкин, Саймон. Нейронные сети: полный курс, 2е издание. : Пер. с англ. М. Издательский дом "Вильямс", 2006. 1104 с. : ил. Парал. тит. англ.
2. Rafael C. Gonzalez, Richard E. Woods. Digital Image Processing. Second Edition. Prentice Hall, 2002. – 812 p.
3. James G. Nagy and Misha E. Kilmer. Kronecker Product Approximation for Preconditioning in Three-Dimensional Imaging // IEEE Transaction on image pro-

cessing, Vol. 15, No. 3, March 2006 p. 604-613

4. Zhao Songnian¹, Zou Qi, Jin Zhen, Yao Guozheng, Yao Li. Neural computation of visual imaging based on Kronecker product in the primary visual cortex // Songnian et al. BMC Neuroscience 2010

5. Ahmed Kharat, Karim Gasmi. A Hybrid Approach for Automatic Classification of Brain MRI Using Genetic Algorithm and Support Vector Machine // Leonardo Journal of Sciences July-December 2010 p. 71-82

6. Ahmed Kharat, Karim Gasmi, Mohamed Abid. Automated Classification of Magnetic Resonance Brain Images Using Wavelet Genetic Algorithm and Support Vector Machine // Leonardo Journal of Sciences July-December 2011 p. 369-374

7. A. Ortiz, J. M. Gorriz, J. Ramirez, and D. Salas-Gonzalez. Unsupervised Neural Techniques Applied to MR Brain Image Segmentation // Hindawi Publishing Corpo-

ration Advances in Artificial Neural Systems Volume 2012, Article ID 457590, 7 pages

8. Amir Maleki Anvar, Alireza Mohammadi, Abdolhamid Pilevar. SOM Neural Network as a Method in Image Color Reduction // IJCSNS International Journal of Computer Science and Network Security, VOL.13 No.2, February 2013 p. 64-68

9. J. Jiang, P. Trundle* , J. Ren. Medical image analysis with artificial neural networks // Computerized Medical Imaging and Graphics 34 (2010) 617–631

10. D. Jude Hemanth, C.Kezi Selva Vijila* and J.Anitha*. Application of Neuro-Fuzzy Model for MR Brain Tumor Image Classification // Biomedical Soft Computing and Human Sciences, Vol.16,No.1, 2010 pp.95-102

11. Дьяконов В.П., Круглов В.В. MATLAB 6.5 SP1/7/7 SP1/7 SP2 + Simulink5/6. Инструменты искусственного интеллекта и биоинформатики. – М.: СОЛОН-ПРЕСС, 2006. – 456 с.