

УДК 004.654: 004.852

Т.М. Булана, О.С. Коричковська

ОБРОБКА ДАНИХ МЕТОДОМ ІМОВІРНІСНИХ НЕЙРОННИХ МЕРЕЖ

Анотація. Розглянуто нейромережеві технології для вирішення задач класифікації, зокрема діагностування за медичними даними. Проаналізовано існуючі алгоритми вирішення даної задачі. Для детального аналізу серед них було обрано багат шаровий перцептрон MultiPlayer Perceptron (MLP), ймовірна нейронна мережа Probabilistic Neural Networks (PNN), узагальнено-регресійна нейронна мережа General Regression Neural Networks (GRNN). Виходячи з концепції гібридних мереж розроблено гібрид який поєднує PNN та MLP. Проведено порівняння нейромереж, виявлено складності реалізації, особливості застосування та налагодження.

Актуальність. На сучасному етапі нейронні мережі мають значне застосування та великі перспективи у розв'язанні найрізноманітніших задач. Зокрема завдання медицини та біології є ідеальним полем для їх застосування, і саме в цій області спостерігається найбільш яскравий практичний успіх нейроінформаційних методів. Головною задачею обробки медичних даних є вірна постановка діагнозу, або інакше кажучи класифікація пацієнтів за наявністю певного типу захворювання.

Аналіз відомих реалізацій. Використання нейромереж в медицині, як правило, пов'язано з системами для діагностики та диференціальної діагностики захворювань. При цьому для прийняття рішень можуть використовуватися найрізноманітніші дані: анамнез, клінічний огляд (створюються експертні системи діагностики, обмежуються тільки цим набором), результати лабораторних тестів і складних функціональних методів. Проте навчена нейромережа не тільки вмє розпізнавати приклади, але і зберігає досить важливу інформацію. Важливим фактором застосування є можливість обробки багатовимірних даних, що дозволяє робити діагностику більш комплексною.

Прикладом програми діагностики служить пакет кардіодіагностики, розроблений фірмою RES Informatica спільно з

© Булана Т.М., Коричковська О.С., 2009

Центром кардіологічних досліджень в Мілані. Програма дозволяє здійснювати неінвазивну кардіодіагностику на основі розпізнавання спектрів тахограмм. Так чи інакше, уже зараз можна констатувати, що нейронні мережі перетворюються в інструмент кардіодіагностики - в Англії, наприклад, вони використовуються в чотирьох госпіталях для попередження інфаркту міокарда. Зрозуміло, що це лише дуже незначна частина всіх прикладів вдалих застосувань нейронних мереж, і такий список може бути дуже довгим. Але не зважаючи на свої позитивні якості, все існуючі нейромережеві продукти мають і деякі мінуси, а саме: значна ціна, що може стати головним бар'єром у запровадження технологій та програмних продуктів у некомерційні галузі. В одних випадках такі продукти є занадто громіздкими та надлишково функціональними, а у інших, налаштовані на вирішення занадто вузького кола задач. Інтерфейс та налаштування мережі можуть бути інтуїтивно незрозумілими, та занадто складними, за умови відсутності, або незрозумілості супроводжуючої документації. Все це, звісно, ускладнює запровадження та використання, адже користувач не завжди є спеціалістом у галузі інформаційних технологій, і зокрема нейромережевих систем.

Постановка задачі. Таким чином, існує гостра необхідність у гнучкому програмному комплексі для вирішення різноманітних задач класифікації, який буде: вирішувати саме задачі класифікації, містити нейромережеві алгоритми які реалізують модель класифікатора, матиме зручний і інтуїтивно зрозумілий інтерфейс, повну візуалізацію отриманих результатів, що дозволить користувачеві мінімізувати час на навчання та роботу, бути зручним у налаштуванні, адаптуватися для конкретної предметної області, мультиплатформним.

Основна частина. Для реалізації поставленої задачі було проведено детальний аналіз нейромережевих алгоритмів, серед них виявлено ті, що найкраще вирішують задачу класифікації та легкі в налаштуванні. До таких було віднесено: двошаровий перцептрон (класична нейронна мережа, що вирішує дуже широкий спектр завдань), PNN (ймовірнісна нейронна мережа, орієнтована на вирішення саме задач класифікації), GRNN (вихід цієї мережі може розглядатися як очікуване значення моделі в даній точці простору

входів, це значення пов'язано з щільністю ймовірності спільного розподілу вхідних та вихідних даних).

Новим напрямом в розвитку нейротехнологій є розробка так званих гібридних нейронних мереж. Сутність таких мереж полягає у використанні переваг одразу декількох нейронних структур для покращення результату та зменшення швидкості навчання. Гібридна мережа може бути більш ефективною, бо задача поділяється на два незалежних етапи. В якості дослідження гібридних мереж було поєднано PNN та MLP з метою отримання кращих результатів. Розглянемо детально кожен з вище згаданих мереж.

Архітектура перцептрона MLP була розроблена на початку 1970-х років декількома незалежними авторами: Вербор (Werbor); Паркер (Parker); Румельгарт (Rumelhart), Хінтон (Hinton) та Вільямс (Williams). На даний час, парадигма BackPropagation найбільш популярна, ефективна та легка модель навчання для складних, багатосарових мереж. Вона використовується у різних типах застосувань і породила великий клас нейромереж з різними структурами та методами навчання.

Типова мережа BackPropagation [1] має вхідний прошарок, вихідний прошарок та принаймні один прихований прошарок. Теоретично, обмежень відносно числа прихованих прошарків не існує, але практично застосовують один або два. Задавши певну структуру нейронної мережі, яка відповідає задачі, що досліджується, необхідно провести навчання. Подаючи на входи перцептрона будь-який об'єкт навчальної вибірки, на виході кожного нейрону вихідного шару одержуємо значення деякої функції $F(x_1, x_2, \dots, x_M)$, яке є відповіддю (реакцією). Очевидно, що відповідь мережі залежить як від вхідного сигналу, так і від значень її вагових коефіцієнтів. Точний вид цієї функції для кожного з нейронів вихідного шару має вигляд

$$y_r = F_r(x_1, x_2, \dots, x_M) = f\left(\sum_{l=1}^L w_{lr} f\left(\sum_{j=1}^M w_{jl} x_j + w_{0l} x_0\right) + w_{0r} x_0\right), \quad r = \overline{1, R},$$

де M – розмірність вхідного сигналу $\{x_j, j = \overline{1, M}\}$, R – розмірність вихідного сигналу, f – функція активації, w_{ij} – ваговий коефіцієнт синаптичного зв'язку, який йде від i -того нейрону до j -го, $w_{0l} x_0$ та $w_{0r} x'_0$ – значення зсуву, відповідно на схованому та вихідному шарах (зазвичай $x_0 = x'_0 = 1$). Отже, метою навчання нейронної мережі є

знаходження такого набору вагових коефіцієнтів, який забезпечує розв'язок даної конкретної проблеми.

Відповідно до методу найменших квадратів, цільовою функцією помилки при поданні \mathbf{w} -того образу, що треба мінімізувати, є величина:

$$E_k(\mathbf{w}) = \frac{1}{2} \sum_{r=1}^R (y_r - d_r)^2, \quad k = \overline{1, K},$$

де y_r – реальний вихідний стан нейрона r , $r = \overline{1, R}$ вихідного шару, d_r – потрібний вихідний стан цього нейрона. Мінімізація похибки ведеться методом градієнтного спуску, що визначає підстроювання вагових коефіцієнтів[2].

Імовірнісна нейронна мережа PNN була розроблена Дональдом Спехтом (Donald Specht). Ця мережна архітектура була вперше представлена у двох статтях: "Імовірнісні нейронні мережі для класифікації" (Probabilistic Neural Networks for Classification, 1988), "Відображення або асоціативна пам'ять та імовірнісні нейронні мережі" (Mapping or Associative Memory and Probabilistic Neural Networks, 1990). Імовірнісна мережа вчиться оцінювати функцію густини ймовірності, її вихід розглядається як очікуване значення моделі в даній точці простору входів. Це значення пов'язане з густиною ймовірності спільного розподілу вхідних і вихідних даних. При рішенні задач класифікації можна оцінити густину ймовірності для кожного класу, порівняти між собою ймовірності приналежності до різних класів і обрати модель з параметрами, при яких густина ймовірності буде найбільшою. Імовірнісна мережа має чотири прошарки: вхідний, радіальний, конкуруючий та вихідний. Кожному класу відповідає один вихідний елемент. Вихідний елемент з'єднаний лише з радіальними елементами, що відносяться до його класу і підсумовує виходи всіх елементів, що належать до його класу. Значення вихідних сигналів утворюються пропорційно ядерних оцінок ймовірності приналежності відповідним класам [3]. Навчання імовірнісної нейронної мережі є набагато простішим, ніж BackPropagation. Істотним недоліком мережі є її розмір, оскільки вона фактично вміщує в собі всі навчальні дані, потребує багато пам'яті і може повільно працювати.

Процедура Побудова PNN

1. Ініціалізація початкових значень:

- a. визначається кількість нейронів у радіальному шарі – вона дорівнює кількості елементів навчальної вибірки;
- b. в кожен нейрон радіального шару поміщається гаусівська функція
- c. кількість нейронів конкуруючого шару дорівнює кількості класів
- d. матриця вагових коефіцієнтів мережі $W = \{w_{ij}\}$ заповнюється даними навчальної вибірки
- e. коефіцієнт гаусівської функції ε встановлюється на рівні 0.1;
- f. останній шар має один нейрон, який визначає найкращий відгук у нейронів конкуруючого шару

2. З навчальної вибірки Ω_{k-1} випадковим чином обирається об'єкт $\omega_k \in \Omega_{k-1}$ та подається на вхід мережі.

3. Обчислюється похибка частка невірно класифікованих, до загальної кількості тестової вибірки.

Мережа GRNN за своєю структурою подібна до мережі PNN, різниця відображається у третьому шарі – конкуруючий шар відсутній, а замість нього рахується середнє зважене. Вважається, що кожне спостереження свідчить про деякої впевненості в тому, що поверхня відгуку в цій точці має певну висоту, і ця впевненість зменшується при відході в сторону від точки. GRNN-мережа копіює всередину себе всі навчальні спостереження та використовує їх для оцінки відгуку в довільній точці. Остаточна вихідна оцінка мережі виходить як зважене середнє виходів за всіма навчальним спостереженнями, де величини ваг відображають відстань від цих спостережень до тієї точки, в якій проводиться оцінювання [4].

Процедура Побудова GRNN

1. Ініціалізація початкових значень:

- a. визначається кількість нейронів у радіальному шарі – вона дорівнює кількості елементів навчальної вибірки;
- b. в кожен нейрон радіального шару поміщається гаусівська функція
- c. матриця вагових коефіцієнтів мережі $W = \{w_{ij}\}$ заповнюється даними навчальної вибірки
- d. коефіцієнт гаусівської функції ε встановлюється на рівні 0.1;

2. Останній шар має один нейрон, в якому рахується середнє зважене за даними радіального шару

3. О навчальної вибірки Ω_{k-1} випадковим чином обирається об'єкт $\omega_k \in \Omega_{k-1}$ та подається на вхід мережі.

Істотним недоліком мережі є її розмір, оскільки вона фактично вміщує в собі всі навчальні дані, потребує багато пам'яті і може повільно працювати.

Новим напрямом в розвитку нейротехнологій є розробка так званих гібридних нейронних мереж. Сутність таких мереж полягає у використанні переваг одразу декількох нейронних структур для покращення результату та зменшення швидкості навчання. Гібридна мережа може бути більш ефективною, бо задача поділяється на два незалежних етапи. Для задач класифікації розглянемо поєднання мереж PNN та MLP.

Структура такої мережі може бути відображена на рис 3.

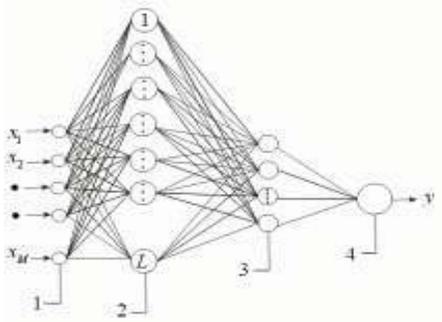


Рисунок 1 - Нейрона мережа PNN (1 – вхідний шар; 2 – радіальний базисний шар; 3 – конкуруючий шар; 4 – вихідний шар)

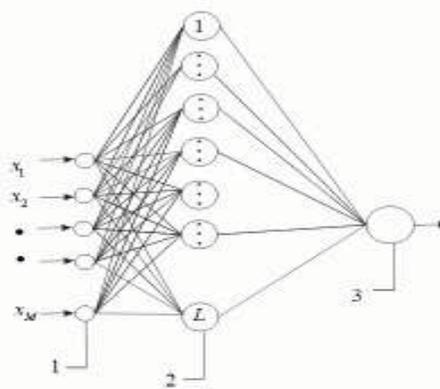


Рисунок 2 - Нейрона мережа GRNN (1 – вхідний шар; 2 – радіальний базисний шар; 3 – вихідний шар)

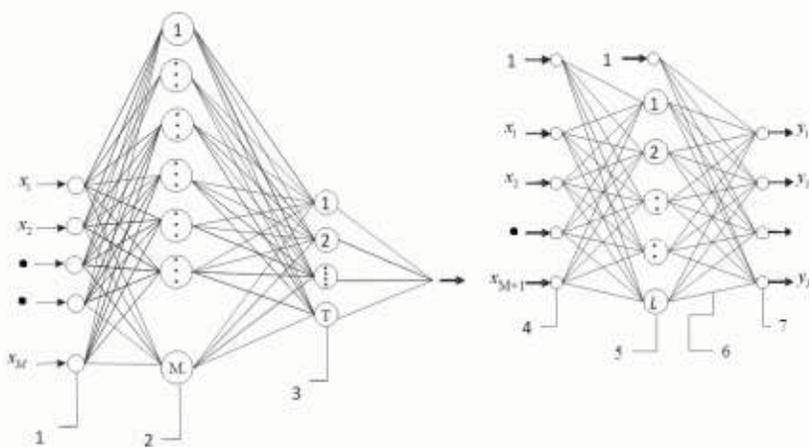


Рисунок 3 - Нейрона мережа гібридного типу: (1 – вхідний шар; 2 – радіальний шар PNN; 3 – конкуруючий шар; 4 – вхідний шар MLP; 5 – схований шар; 6 – синаптичні зв'язки; 7 – вихідний шар)

Процедура. Навчання гібридної мережі

1. Ініціалізація початкових значень:

- a. визначається кількість нейронів у радіальному шарі – вона дорівнює кількості елементів навчальної вибірки;
- b. в кожен нейрон радіального шару поміщається гаусівська функція;
- c. кількість нейронів конкуруючого шару дорівнює кількості класів;
- d. матриця вагових коефіцієнтів мережі $W = \{w_{ij}\}$ заповнюється навчальними даними;
- e. коефіцієнт гаусівської функції ε встановлюється на рівні 0.1;
- f. останній шар має один нейрон, який визначає найкращий відгук у нейронів конкуруючого шару;
- g. визначення кількості нейронів у схованому шарі персептрону, матриця вагових коефіцієнтів мережі $W = \{w_{ij}\}$ заповнюється випадковими значеннями, що рівномірно розподілені на проміжку $[-0,5;0,5]$;
- h. $x_0 = y_0 = 1$
- i. $\Delta w_{ij} = 0$;
- j. коефіцієнт інерційності μ встановлюється на рівні 0,03;
- k. коефіцієнт швидкості навчання η встановлюється на рівні 0,9;
- l. задається кількість епох K_E ;
- m. шаг зменшення швидкості навчання $h_\eta = \eta / K_E$;
- n. «лічильник» похибок $C_E = 0$.

2. Якщо кількість епох досягла заданої K_E , то обчислюється оцінка повної ймовірності помилкової класифікації C_E / K_E . Навчання закінчено.

3. З розгляду випадковим чином вилучається один з векторів навчальної вибірки $\varpi_k^* \in \Omega_K$, тим самим формується навчальна вибірка Ω_{K-1} .

4. З навчальної вибірки Ω_{K-1} випадковим чином обирається об'єкт $\omega_k \in \Omega_{K-1}$ та подається на вхід мережі.

5. Обчислюється загальна похибка $E_k(w) = \frac{1}{2} \sum_{r=1}^R (y_r - d_r)^2$,

6. Для кожного нейрону вихідного шару обчислюється похибка $\delta_r = (y_r - d_r)(1 - y_r)y_r$, $r = \overline{1, R}$

7. Для всіх нейронів схованого шару обчислюється похибка $\delta_l = \left(\sum_{r=1}^R w_{lr} \delta_r \right) (1 - y_l)y_l$, $l = \overline{1, L}$

8. Обчислюється величина зміни ваг вихідного шару $\Delta w_{lr} = -\eta(\mu \Delta w_{lr} + (1 - \mu)\delta_r y_l)$, $l = \overline{0, L}, r = \overline{1, R}$

9. З урахуванням зсуву обчислюється величина зміни ваг схованого шару $\Delta w_{lr} = -\eta(\mu \Delta w_{lr} + (1 - \mu)\delta_r y_l)$, $l = \overline{0, L}, r = \overline{1, R}$

10. Для всіх ваг всіх шарів обчислюються нові значення ваг $w_{ij} = w_{ij} + \Delta w_{ij}$

11. Якщо кількість ітерацій становить $K - 1$ (тобто епоху закінчено), то перейти на пункт 12, інакше на пункт 4.

12. Подати на вхід мережі вектор ω_k^* . У разі невірної класифікації $C_E = C_E + 1$.

13. Зменшення швидкості навчання $\eta = \eta - h_\eta$. Перехід до пункту 2.

Таким чином, розроблена процедура навчання гібридної мережі дозволяє навчити двошаровий персептрон й оцінити в процесі навчання повну ймовірність помилкової класифікації. У випадку малорозмірної або неякісної навчальної вибірки навіть найкращий алгоритм не дасть задовільного результату, оскільки без повноцінного набору даних нейромережа принципово не здатна навчитися.

Були проведені дослідження залежності якості класифікації від параметрів алгоритму навчання й структури нейронних мереж. Вхідні дані для досліджень були надані Антигіпертензивним центром клінічної лікарні №11 м. Дніпропетровськ, які містили дані комплексного обстеження, відомості про діагнози. Надана вибірка, на якій проведені дослідження й апробована робота системи, є високо репрезентативна. Усього внесено даних по 690 хворим з серцево-судинними захворюваннями (артеріальна гіпертензія, артеріальна гіпертензія у сполученні ішемічною хворобою серця, артеріальна гіпертензія у сполученні із захворюванням нирок) та по 96 здоровим - контрольна група[5]. Результати досліджень показали, що якість класифікації MLP – 95%, PNN - 96,4% та розроблена гібридна

мережа яка поєднує PNN та MLP дала якість класифікації 98,6%, що свідчить про доцільність використання нейромережі.

Висновки. Було проведено детальне ознайомлення з різноманітними типами нейронних мереж. Серед всього їх різноманіття було обрано мережі MLP, PNN та GRNN.

Мережі PNN та GRNN мають недоліки: громіздка структура може вплинути на швидкість навчання, для правильної роботи співвідношення даних кожного класу у тестових та навчальних вибірках має бути однаковим. Дані мережі можуть ефективно працювати навіть на надзвичайно малій навчальній вибірці, у разі потрапляння до цієї вибірки центроїда кожного класу. Коли навчальна вибірка є досить великою, мережі розростається та можуть працювати повільно. З іншого боку, ці мережі не потребують навчання, що економить час та спрощує їх налаштування.

Мережа MLP є досить гнучкою до вхідних даних, і майже гарантовано дає добрий результат. Мінусом її є велика кількість параметрів, яку в багатьох випадках потрібно підбирати експериментальним шляхом для отримання найкращого результату.

Ознайомившись з концепцією гібридних мереж, розроблено алгоритм мережі гібрида PNN та MLP. Проведено порівняльний аналіз нейромереж, в ході якого виявлено, що найкращі результати зі всіх дає гібридна мережа.

ЛІТЕРАТУРА

1. Осовский С. Нейронные сети для обработки информации М.: Финансы и статистика, 2004. 344 с.
2. Хачапурідзе Т.М. Інформаційне нейромережеве забезпечення діагностики серцево-судинної системи по функціям інтенсивності // Актуальні проблеми автоматизації та інформаційні технології. 2005. Т.9. С. 34–49.
3. http://www.victoria.lviv.ua/html/oio/html/theme7_1.htm
4. Солдатова О.П., Семенов В.В. Применение нейронных сетей для решения задач прогнозирования // Электронный научный журнал «Исследовано в России» 1270 (<http://zhurnal.ape.relarn.ru/articles/2006/136.pdf>)
5. Буланая Т.М., Колесник Т.В. Автоматизированная система комплексного индивидуального анализа при диагностике сердечно-сосудистых заболеваний.// Математичне та програмне забезпечення інтелектуальних систем: міжн. наук.-практ. конф.: тези доп. – Дніпропетровськ, 2006.– С. 81.