УДК 004.032.26

Тесленко Н. О.

ЕВОЛЮЦІЙНА КАСКАДНА РАДІАЛЬНО-БАЗИСНА НЕЙРОННА МЕРЕЖА НА ОСНОВІ БАГАТОВИМІРНИХ ЯДЕР ЄПАНЕЧНИКОВА

Запропоновано архітектуру еволюційної каскадної радіально-базисної нейронної мережі, що побудована об'єднанням методу групового урахування аргументів і каскадних мереж. Така мережа не схильна до прокляття розмірності, здатна обробляти інформацію в режимі реального часу, адаптуючи при цьому свої параметри і структуру до умов задачі. У якості активаційних функцій було використано багатовимірні ядра Єпанечникова, що дозволило ввести чисельно прості алгоритми навчання, що характеризуються високою швидкодією.

Ключові слова: *еволюційна нейронна мережа, каскадні мережі, радіально-базисна нейронна мережа, метод групового урахування аргументів, багатовимірні ядра Єпанечникова.*

Предложена архитектура эволюционной каскадной радиально базисной нейронной сети, которая построена объединением метода группового учета аргументов и каскадных сетей. Такая сеть не склонна к проклятию размерности, способна обрабатывать информацию в режиме реального времени, адаптируя при этом свои параметры и структуру к условиям задачи. В качестве активационных функций были использованы многомерные ядра Епанечникова, что позволило ввести численно простые алгоритмы обучения, которые характеризуются высоким быстродействием.

Ключевые слова: *эволюционная нейронная сеть, каскадные сети, радиально-базисная нейронная сеть, метод группового учета аргументов, многомерные ядра Епанечникова.*

The architecture of evolving Radial-Basis Neural Netwok is proposed. This network combines Group Method of Data Handling and cascade networks and isn't inclined to the «curse of dimensionality», is able to real time mode information processing by adapting its parameters and structure to problem conditions. The multidimensional Epanechnikov kernels were used as activation functions, that allowed to introduce numerically simple learning algorithms, which are characterized by high speed.

Key words: *evolving neural network, cascade networks, radial-basis neural network, Group Method of Data Handling, multidimensional Epanechnikov kernels.*

Вступ

Штучні нейронні мережі в цей час набули широкого розповсюдження для вирішення широкого класу задач ідентифікації, емуляції, інтелектуального керування, прогнозування часових послідовностей тощо, завдяки універсальним апроксимуючим можливостям то здатності до навчання. Оскільки при вирішенні низки практичних задач, коли об'єм навчальної вибірки обмежений, на перший план виходить фактор швидкості навчання, при цьому далеко не всі нейронні мережі здатні подолати виникаючы проблеми і, перш за все, з, так званим «перенавчанням». В якості одних з найбільш швидкодіючих мереж, що навчаються на основі оптимізаційних процедур другого порядку з високою швидкістю збіжності, можна назвати радіально-базисні нейронні мережі (РБНМ), вихідний сигнал яких лінійно залежить від синаптичних ваг, що настроюються. Разом з тим ці мережі схильні до, так званого «прокляття розмірності», коли кількість радіально-базисних нейронів прихованого шару (R-нейронів) експоненціально зростає із зростанням розмірності вхідного простору сигналів (образів).

Подолати проблему можна, розбиваючи тим або іншим чином первинну задачу на низку підзадач низької розмірності та об'єднуючи далі отримані рішення для досягнення необхідного результату. З обчислювальної точки зору вельми привабливим в цій ситуації є метод групового урахування аргументів (МГУА) [1-4], що продемонстрував свою ефективність при вирішенні широкого класу реальних задач.

У [5] була розглянута багатошарова МГУА-нейронна мережа, вузлами якої є двовходові N-адаліни, а вихід кожного з вузлів є квадратична функція вхідних сигналів. При цьому синаптичні ваги кожного з нейронів визначаються у пакетному режимі за допомогою стандартного методу найменших квадратів. Для забезпечення необхідної якості апроксимації може бути потрібна більша кількість прихованих шарів, при цьому навчання в on-line режимі повністю унеможливлюється.

У роботі пропонується гібридна архітектура штучної нейронної мережі, в основі якої лежать ідеї методу групового урахування аргументів і послідовної побудови каскадних нейронних мереж [6], а в якості вузлів використовуються складені R-нейрони з активаційними функціями типу багатовимірних ядер Єпанечникова [7-9], що мають велике число мір свободи, а, отже, і покращені апроксимуючі властивості в порівнянні з традиційними гауссіанами.

Складений R-нейрон з багатовимірними ядрами єпанечникова та алгоритм його навчання

Введемо в розгляд структуру складеного R-нейрона, приведену на рис. 1 і співпадаючу по суті із спрощеною архітектурою звичайної радіально-базисної нейронної мережі з двома входами x_i і x_j, $i, j = 1, 2, ..., n$, де n – розмірність вхідного простору. Складений R-нейрон містить p активаційних функцій (традиційно в РБНМ використовуються багатовимірні гауссіани або інші дзвонуваті функції) $\varphi_h^{ij}(x^{ij}, c_h^{ij}, \Sigma_h^{ij})$, $p + 1$ синаптичних ваг, об'єднаних у вектор $w_i^{ij} = (w_{l0}^{ij}, w_{l1}^{ij}, ..., w_{lp}^{ij})$, p – двовимірних векторів центрів $c_h^{ij}(c_h^i, c_h^j)^T$, $p\,(2 \times 2)$ – матриць рецепторних полів активаційних функції Σ_h^{ij}, двовимірний вектор входів $x^{ij} = (x_i, x_j)^T$, один вихід $\hat{y}_l$; $p = 1, 2, ..., p$; $k = 1, 2, ..., N$ – номер спостереження в оброблюваній вибірці або індекс поточного дискретного часу.

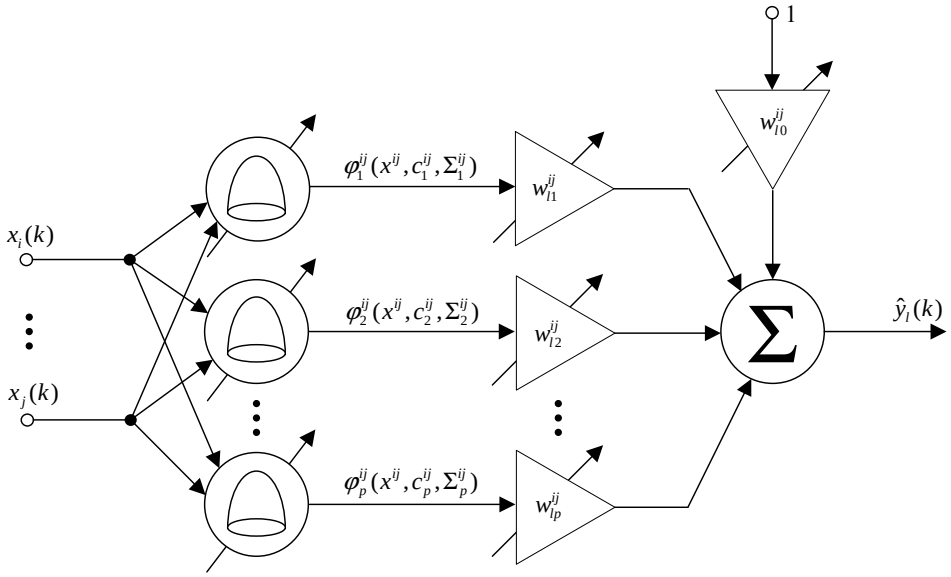

Рис. 1. Складений R-нейрон

В якості активаційної функції $\varphi_h^{ij}(x^{ij}, c_h^{ij}, \Sigma_h^{ij})$ використовуються багатовимірні ядра Єпанечникова у вигляді

$$\varphi_h^{ij}(x^{ij}, c_h^{ij}, \Sigma_h^{ij}) = 1 - \left\| x^{ij} - c_h^{ij} \right\|^2_{\left(\Sigma_h^{ij}\right)^{-1}}, \tag{1}$$

що мають дзвонувату форму при позитивно визначеній матриці рецепторного поля Σ_h^{ij}. Перевага активаційної функції (1) в порівнянні з традиційними полягає в лінійності її похідних по всіх параметрах, що дозволяє досить просто настроювати на тільки синаптичні ваги нейрона, але і центри з рецепторними полями.

При цьому перетворення, що реалізується складеним R-нейроном має вигляд

$$\hat{y}_l = w_{l0}^{ij} + \sum_{h=1}^{p} w_{lh}^{ij} \varphi_h^{ij}(x^{ij}, c_h^{ij}, \Sigma_h^{ij}) = w_{l0}^{ij} + \sum_{h=1}^{p} w_{lh}^{ij} \left(1 - \left\| x^{ij} - c_h^{ij} \right\|^2_{\left(\Sigma_h^{ij}\right)^{-1}} \right).$$

Зазвичай навчання радіально-базисних нейронних мереж зводиться до настроювання синаптичних ваг w_{lh}^{ij}, а центри та характеристики рецепторних полів задаються або визначаються апріорі. При цьому для двовимірного випадку досить просто розташувати центри у вузлах регулярних решіток, а рецепторні поля задати у формі кругів. Сам процес навчання полягає у визначенні вектора синаптичних ваг w_l^{ij} по навчальній вибірці, що містить N спостережень $x^{ij}(k) = (x_i(k), x_j(k))^T$, $y(k)$, $k = 1, 2, ..., N$, де $y(k)$ – зовнішній навчаючий сигнал.

Вводячи в розгляд $(p+1)\times 1$ – вектор активаційних функцій

$$\varphi^{ij}(k)=\left(1,\ \varphi_1^{ij}\left(x^{ij}(k),\ c_1^{ij},\ \Sigma_1^{ij}\right),\ ...,\ \varphi_p^{ij}\left(x^{ij}(k),\ c_p^{ij},\ \Sigma_p^{ij}\right)\right)^T$$

та критерій навчання

$$E_1^N=\sum_{k=1}^{N}\left(y(k)-\hat{y}_l(k)\right)^2=\sum_{k=1}^{N}e_l^2(k)=\sum_{k=1}^{N}\left(y(k)-(w_l^{ij})^T\varphi^{ij}(k)\right)^2, \tag{2}$$

за допомогою стандартного методу найменших квадратів нескладно отримати шукане рішення у вигляді

$$w_l^{ij}=\left(\sum_{k=1}^{N}\varphi^{ij}(k)\left(\varphi^{ij}(k)\right)^T\right)^+\sum_{k=1}^{N}\varphi^{ij}(k)y(k), \tag{3}$$

де $(\bullet)^+$– символ обернення за Муром-Пенроузом.

Якщо ж дані на обробку надходять послідовно в on-line режимі, замість (3) може бути використаний рекурентний варіант у формі

$$\begin{cases} w_l^{ij}(k)=w_l^{ij}(k-1)+\dfrac{P_{ij}(k-1)\left(y(k)-\left(w_l^{ij}(k-1)\right)^T\varphi^{ij}(k)\right)}{1+\left(\varphi^{ij}(k)\right)^T P_{ij}(k-1)\varphi^{ij}(k)}\varphi^{ij}(k); \\ P_{ij}(k)=P_{ij}(k-1)-\dfrac{P_{ij}(k-1)\varphi^{ij}(k)\left(\varphi^{ij}(k)\right)^T P_{ij}(k-1)}{1+\left(\varphi^{ij}(k)\right)^T P_{ij}(k-1)\varphi^{ij}(k)};\ P_{ij}(0)=\gamma I;\ \gamma>>0. \end{cases} \tag{4}$$

Алгоритми (3), (4) ефективні тільки в ситуаціях, коли шукане рішення є стандартним, тобто оптимальні значення синаптичних ваг не змінюються в часі. Оскільки в багатьох практичних задачах це не так, наприклад, адаптивна ідентифікація нестаціонарних об'єктів або прогнозування нестаціонарних часових послідовностей, то може бути використаний швидкодіючий адаптивний алгоритм навчання, що має слідкуючі та фільтруючі властивості [10]:

$$\begin{cases} w_l^{ij}(k)=w_l^{ij}(k-1)+\eta_w(k)\left(y(k)-\left(w_l^{ij}(k-1)\right)^T\varphi^{ij}(k)\right)\varphi^{ij}(k)=w_l^{ij}(k-1)+\eta_w(k)e_1(k)\varphi^{ij}(k); \\ \eta_w^{-1}(k)=r_w(k)=\alpha r_w(k-1)+\|\varphi^{ij}(k)\|^2,\ 0\le\alpha\le 1, \end{cases}$$

де α – параметр згладжування, що задає компроміс між фільтруючими та слідкуючими властивостями.

З метою поліпшення апроксимуючих властивостей складеного R-нейрона можна настроювати не тільки синаптичні ваги, але і центри з рецепторними полями. При цьому, завдяки використанню ядер Єпанечникова, алгоритми навчання мають достатньо простий вигляд.

Використовуючи градієнтну процедуру мінімізації критерію (2) та техніку її оптимізації за швидкодією [11], приходимо до алгоритму навчання складеного R-нейрона у формі

$$\begin{cases} w_l^{ij}(k)=w_l^{ij}(k-1)+\eta_w(k)e_l(k)\varphi^{ij}(k); \\ \eta_w^{-1}(k)=r_w(k)=\alpha r_w(k-1)+\|\varphi^{ij}(k)\|^2; \\ c_h^{ij}(k)=c_h^{ij}(k-1)+\eta_c(k)e_l(k)w_l^{ij}(k)\left(\sum\nolimits_h^{ij}(k-1)\right)^{-1}\left(x^{ij}(k)-c_h^{ij}(k-1)\right)=c_h^{ij}(k-1)+\eta_c(k)e_l(k)g_h(k); \\ \eta_c^{-1}(k)=r_c(k)=\alpha r_c(k-1)+\|g_h(k)\|^2; \\ \left(\sum\nolimits_h^{ij}(k)\right)^{-1}=\left(\sum\nolimits_h^{ij}(k-1)\right)^{-1}-\eta_\Sigma(k)e_l(k)w_l^{ij}(k)\left(x^{ij}(k)-c_h^{ij}(k)\right)\left(x^{ij}(k)-c_h^{ij}(k)\right)^T=\left(\sum\nolimits_h^{ij}(k-1)\right)^{-1}-\eta_\Sigma(k)e_l(k)G_h(k); \\ \eta_\Sigma^{-1}(k)=\Gamma_\Sigma(k)=\alpha\Gamma_\Sigma(k-1)+Tr\left(G_h(k)G_h^T(k)\right). \end{cases}$$

Еволюційна каскадна нейронна мережа

Поєднання ідей МГУА та каскадних нейронних мереж веде до архітектури, наведеної на рис. 2.

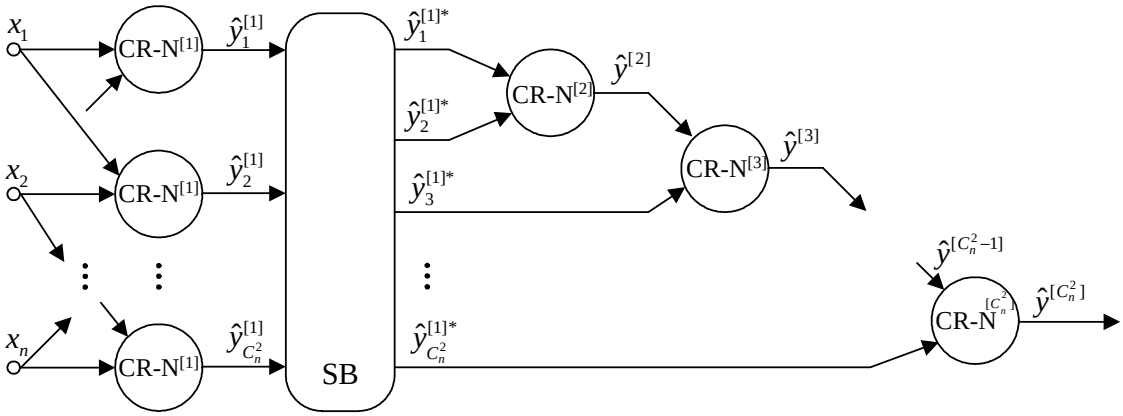

Рис. 2. Еволюційна каскадна нейронна мережа

Перший прихований шар мережі формується аналогічно першому шару МГУА-нейронної мережі [5] та містить число нейронів рівне кількості поєднань з n по 2, тобто C_n^2. Блок селекції SB проводить упорядковування по точності, наприклад, у сенсі дисперсії, всіх вихідних сигналів $\hat{y}_l^{[1]}$ так, що найточнішим є сигнал $\hat{y}_1^{[1]*}$, далі йде $\hat{y}_2^{[1]*}$, а найгірший – $\hat{y}_{C_n^2}^{[1]*}$. Виходи SB $\hat{y}_1^{[1]*}$ і $\hat{y}_2^{[1]*}$ далі надходять на єдиний нейрон другого шару-каскаду CR-N[2], що обчислює сигнал $\hat{y}^{[2]}$, який далі в третьому каскаді об'єднується з $\hat{y}_3^{[1]*}$. Процес нарощування каскадів триває до досягнення необхідної точності, при цьому максимальна кількість нейронів такої мережі обмежена величиною $2C_n^2 - 1$. Таким чином нейронна мережа здатна обробляти інформацію, що надходить в реальному часі, переналаштовуючі як свої параметри так і архітектуру в часі [12] і адаптуючись до умов задачі, що вирішується.

Висновок

Запропоновано архітектуру еволюційної каскадної радіально-базисної нейронної мережі, що побудована на ідеї об'єднання методу групового урахування аргументів і каскадних мереж. Також мережа не схильна до прокляття розмірності і здібна до обробки інформації в режимі реального часу, адаптуючи свої параметри і структуру до умов задачі, що вирішується. Використання багатовимірних ядер Єпанечникова у якості активаційних функцій дозволило ввести чисельно прості алгоритми навчання, що характеризуються високою швидкодією.

ЛІТЕРАТУРА

1. Ивахненко А. Г. Самообучающиеся системы распознавания и автоматического управления. – Киев : Техника, 1969. – 392 с.
2. Ивахненко А. Г. Долгосрочное прогнозирование и управление сложными системами. – Киев : техника, 1975. – 311 с.
3. Ивахненко А. Г. Помехоустойчивость моделирования / А. Г. Ивахненко, В. С. Степашко. – Киев : Наукова думка, 1975. – 216 с.
4. Ivakhnenko A. G. Inductive Learning Algorithms for Complex Systems Modeling / A. G. Ivakhnenko, H. R. Madala. – London ; Tokio : CRC Press, 1994.
5. Pham D. J. Neural Networks for Identification, Prediction and Control / D. J. Pham, X. Liu. – London : Springer-Verlag, 1995.– 238 p.
6. Аведьян Э. Д. Каскадные нейронные сети / Э. Д. Аведьян, Г. В. Баркан, И. К. Левин // Автоматика и телемеханика. – 1999. – № 3. – С. 38–55.
7. Епанечников В. А. Непараметрическая оценка многомерной плотности вероятности // Теория вероятности и её применение. – 1969. – 14. – № 1. – С. 156–161.
8. Friedman J. The Elements of Statistical Learning. Data Mining, Inference and Prediction / J. Friedman, T. Hastie, R. Tibshirani.– Berlin : Springer, 2003. – 552 p.
9. Bodyanskiy Ye. Adaptive quadratic radial basis function network for time series forecasting / Ye. Bodyanskiy, O. Chaplanov, V. Kolodyazhniy, P. Otto // Proc. East West Fuzzy Coll. 2002.– Zittau/Gorlitz : HS, 2002. – P. 164–172.
10. Bodyanskiy Ye. An adaptive learning algorithm for a neuro-fuzzy network / Ye. Bodyanskiy, V. Kolodyazhniy, A. Stephan ; [ed. by B. Reusch] // Computational Intelligence. Theory and Applications». – Berlin ; Heidelberg ; New York : Springer, 2001. – P. 68–75.
11. Otto P. A new learning algorithm for forecasting neuro-fuzzy network / P. Otto, Ye. Bodyanskiy, V. Kolodyazhniy // Integrated Computer-Aided Engineering. – 2003. – 10. – № 4. – P. 399–409.
12. Kasabov N. Evolving Connectionist Systems: Methods and Applications in Bioinformatics. – London : Springer-Verlag, 2003. – 307 p.

Рецензенти: Казарєзов А. Я., д.т.н., професор;
Кондратенко Ю. П., д.т.н., професор

© Тесленко Н. О., 2010

Стаття надійшла до редколегії 21.10.2010 р.