

УДК 004.032.26

ЕВОЛЮЦІЙНА КАСКАДНА МГУА-НЕЙРО-ФАЗЗІ МЕРЕЖА НА БАЗІ ФАЗЗІ-ВЕЙВЛЕТ-НЕЙРОНА ТИПУ-2

О.А. Винокурова

*Проблемна науково-дослідна лабораторія АСУ,
Харківський національний університет радіоелектроніки*

vinokurova@kture.kharkov.ua

У статті запропоновано гібридну еволюційну каскадну МГУА-нейро-фаззі мережу. Як вузол такої мережі використовується фаззі-вейвлет-нейрон типу-2. Також запропоновано алгоритм навчання фаззі-вейвлет-нейрона типу-2 та метод редукції моделі у реальному часі, що відрізняє підхід від існуючих. Експериментальне моделювання підтверджує доцільність підходу, що розвивається.

Ключові слова: еволюційні каскадні нейронні мережі, гібридна МГУА-нейро-фаззі мережа, фаззі-вейвлет-нейрон типу-2, прогнозування, ідентифікація

In the paper the hybrid evolutionary cascade GMDH-neuro-fuzzy network is proposed. The type-2 fuzzy wavelet neuron is used as the node of such network. Also the type-2 fuzzy wavelet neuron learning algorithm and reduction model method in on-line mode are proposed. The computational experiments confirm the effectiveness of developed approach.

Keywords: evolution cascade neural networks, hybrid GMDH-neuro-fuzzy network, type-2 fuzzy wavelet neuron, forecasting, identification

В статье предложена гибридная эволюционная каскадная МГУА-нейро-фаззи сеть. В качестве узла такой сети используется фаззи-вейвлет-нейрон типа-2. Также предложены алгоритм обучения фаззи-вейвлет-нейрона типа-2 и метод редукции модели в реальном времени, что отличает подход от существующих. Компьютерное экспериментальное моделирование подтверждает целесообразность развиваемого подхода.

Ключевые слова: эволюционные каскадные нейронные сети, гибридная МГУА-нейро-фаззи сеть, фаззи-вейвлет-нейрон типа-2, прогнозирование, идентификация

Вступ

В цей час системи обчислювального інтелекту, і в першу чергу, нейронні мережі, завдяки своїм апроксимуючим властивостям та здатності навчання, надбали розповсюдження для вирішення широкого кола задач, а саме ідентифікації, емуляції, інтелектуального керування, прогнозування часових рядів тощо. В той же самий час не всі нейронні мережі (і насамперед найбільш популярний багат шаровий перцептрон з алгоритмом зворотного поширення похибки) задовольняють умовам роботи в реальному часі із-за низької швидкості навчання або можливості ефекту перенавчання. Ще однією проблемою є швидкий ріст кількості параметрів, що навчаються, в залежності від розмірності вхідного сигналу.

Одним з шляхів подолання вище наведених проблем є розділення багатовимірних задач на підзадачі з меншою розмірністю, а потім подальшого об'єднання результатів їх вирішення. З обчислювальної точки зору найбільш

адекватним є Метод Групового Урахування Аргументів (МГУА) [1,2], що продемонстрував свою ефективність при вирішенні великої кількості практичних задач.

Таким чином, актуальним є об'єднання ідей МГУА та обчислювального інтелекту для отримання якісно нових результатів в інтелектуальному аналізі даних, інтелектуальному керуванні та в інших наукових галузях.

Звичайна МГУА-нейронна мережа, або її ще називають поліноміальною мережею, містить в собі у якості часткових описів N-Adalines, синаптичні ваги яких настроюються за допомогою стандартного метода найменших квадратів та забезпечують квадратичне наближення сигналів [3]. З іншої сторони, якщо є необхідність досягнення високої точності, то така мережа потребує значного числа шарів, що ускладнює вирішення задачі та не дозволяє вирішувати задачі реального часу.

Для підвищення точності аналізу даних нами були запропоновані гібридні багаторядні МГУА-нейронні мережі, в вузлах яких використовуються Q-нейрони, багатовимірні адаптивні вейвлони, вейвлет-нейрони [4, 5, 6]. В роботі О.Г. Івахненко [7] була запропонована ідея нейронної мережі з активними нейронами, що дозволяє в кожному вузлі МГУА-нейронної мережі мати різні активаційні функції. Але такі мережі хоча і дозволяють суттєво підвищити точність, але все одно не працюють в реальному часі.

Для підвищення якості вирішення задач та можливості використання підходу в реальному часі, актуальним є об'єднання підходів нейро-фаззі мереж типу-2, каскадних нейронних мереж та ідеї МГУА. Таким чином у статті запропоновано гібридну еволюційну каскадну МГУА-нейро-фаззі-мережу, в якості вузла якої використовується фаззі-вейвлет-нейрон типу-2 для вирішення задач Data Mining.

1. Еволюційна багаторядна МГУА-нейро-фаззі-мережа

Введемо до розгляду архітектуру еволюційної багаторядної МГУА-нейронної мережі, що наведено на Рис.1.

На нульовий (рецепторний) шар мережі надходить $(n \times 1)$ -вимірний вектор вхідних сигналів $x = (x_1, x_2, \dots, x_n)^T$, який далі надходить на перший прихований шар, що має $n_1 = c_n^2$ складених нейронів, на виході яких формуються сигнали $\hat{y}_l^{[1]}$, $l = 1, 2, \dots, 0.5n(n-1)$. Ці сигнали надходять на блок селекції першого прихованого шару $SB^{[1]}$, що відбирає з множини $\hat{y}_l^{[1]}$ $n_1^* < n_1$ найкращих в сенсі дисперсії $\sigma_{\hat{y}_l^{[1]}}^2$, з яких формується $n_2 = c_{n_1}^2$ (зазвичай $n \leq n_2 \leq 2n$) сполучень $\hat{y}_i^{[1]}$, $\hat{y}_j^{[1]}$, що подаються на другий прихований шар, який утворюється нейронами $CR - N^{[2]}$. З вихідних сигналів цього шару $\hat{y}_l^{[2]}$ блок селекції $SB^{[2]}$ відбирає тільки ті, що перевершують по точності найкращий

сигнал першого прихованого шару $\hat{y}_i^{[1]*}$. Третій прихований шар формує сигнали, що перевершують найкращий сигнал $\hat{y}_i^{[2]*}$ і т.д.




Рис. 1. Еволюційна багаторядна МГУА-нейронна мережа

Процес еволюції мережі проходить до тих пір, поки блок селекції $SB^{[s-1]}$ не сформує на своєму виході усього два сигнали $\hat{y}_1^{[s-1]}$ і $\hat{y}_2^{[s-1]}$. Саме ці два сигнали надходять на вихідний нейрон $CR - N^{[s]}$, що обчислює вихідний сигнал мережі в цілому $\hat{y}^{[s]}$, при цьому автоматично виконується умова $\sigma_{\hat{y}_1^{[s]}}^2 < \sigma_{\hat{y}_1^{[s-1]*}}^2 < \dots < \sigma_{\hat{y}_1^{[1]*}}^2$.

У такій мережі в якості вузлів запропоновано використовувати гібридні нейрони, а саме Q-нейрони [4], адаптивні багатовимірні вейвлони [5], вейвлет-нейрони [6], що дозволяють підвищити якість вирішення задач інтелектуального аналізу даних, але недоліком такої системи є неможливість вирішення задач в реальному часі.

2. Еволюційна каскадна МГУА-нейронна мережа

Чисельна громіздкість та неможливість навчання в реальному часі багаторядної МГУА-нейронної мережі змушують шукати альтернативний варіант, що об'єднував би переваги нейронних мереж та МГУА. В якості вирішення такої проблеми була запропонована гібридна еволюційна каскадна МГУА-нейронна мережа, архітектуру якої наведено на Рис. 2.

Перший прихований шар такої мережі подібний першому шару мережі, що наведено на Рис. 1, з тією різницею, що блок селекції SB проводить упорядкування усіх сигналів $\hat{y}_i^{[1]}$ так, що $\sigma_{\hat{y}_1^{[1]*}}^2 < \sigma_{\hat{y}_2^{[1]*}}^2 < \dots < \sigma_{\hat{y}_m^{[1]*}}^2$.

Виходи першого шару (каскаду) $\hat{y}_1^{[1]*}$ та $\hat{y}_2^{[1]*}$ далі надходять на єдиний нейрон другого каскаду $CR - N^{[2]}$, що формує сигнал $\hat{y}^{[2]}$, який далі надходить з сигналом $\hat{y}_3^{[1]*}$ на третій каскад. Процес нарощування каскадів продовжується

до отримання необхідної точності, при цьому загальне число нейронів такої мережі визначається значенням $2n_1 - 1$. У випадку, якщо точність незадовільна, можна підвищити її, налаштовуючи не тільки синаптичні ваги, але і центри та ширини гібридних нейронів, що знаходяться у вузлах.

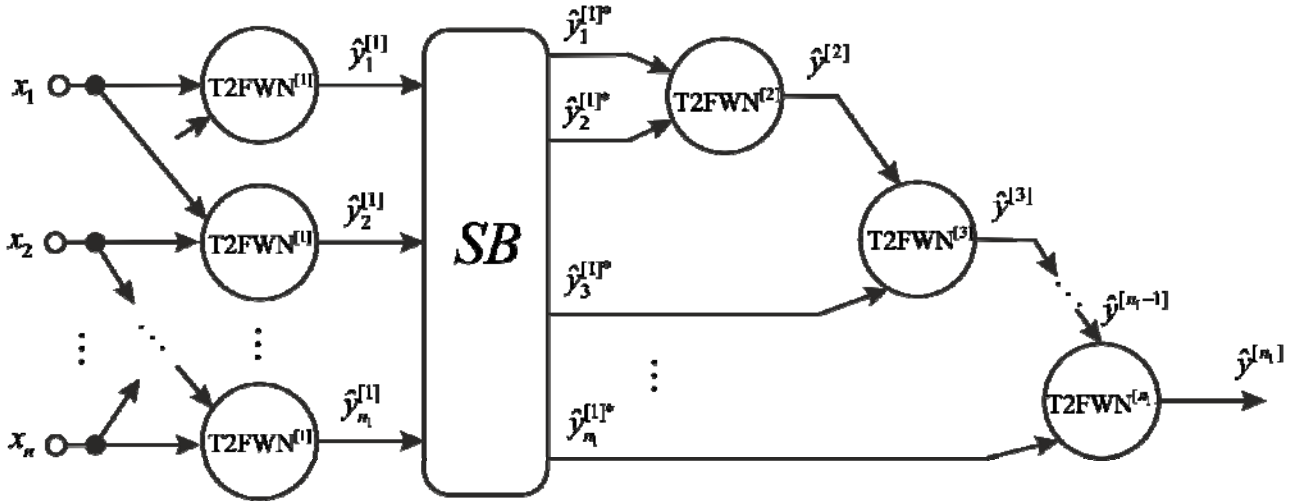


Рис.2. Еволюційна каскадна МГУА-нейронна мережа

Для реалізації ідеї нейронних мереж з активними нейронами пропонується використовувати фаззі-вейвлет-нейрон типу-2, що дозволяє налаштувати не тільки синаптичні ваги, але і усі параметри фаззі-вейвлет-функцій активації-належності типу-2 гібридної еволюційної каскадної МГУА-нейро-фаззі-мережі, що дає змогу побудови індивідуальної активаційної функції для кожного вузла. Далі розглянемо побудову вузла такої мережі.

3. Вейвлет-нейрон і алгоритм його навчання

Для вирішення задачі on-line прогнозування нестационарних сигналів в [6] було запропоновано вейвлет-нейронний предиктор, основою якого є вейвлет-нейрон, структуру якого наведено на Рис. 3.

Вейвлет-нейрон є достатньо близьким по конструкції до стандартного формального нейрона з n входами, однак замість звичайних синаптичних ваг, що налаштовуються, має вейвлет-синапси WS_i , $i = 1, 2, \dots, n$, в яких параметрами, що налаштовуються, є не тільки ваги w_{ji} , але і параметри розтягнення і зсуву вейвлетів $\varphi_{ji}(x_i(k))$.

Як видно, при надходженні на вхід вейвлет-нейрону векторного сигналу $x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T$ (тут $k = 0, 1, 2, \dots$ - поточний дискретний час) на його виході формується скалярне значення

$$y(k) = \sum_{i=1}^n f_i(x(k)) = \sum_{i=1}^n \sum_{j=1}^{h_i} w_{ji}(k) \varphi_{ji}(x_i(k)), \quad (1)$$

що визначається як синаптичними вагами $w_{ji}(k)$, що настроюються, так і вейвлет-функціями, які використовуються.

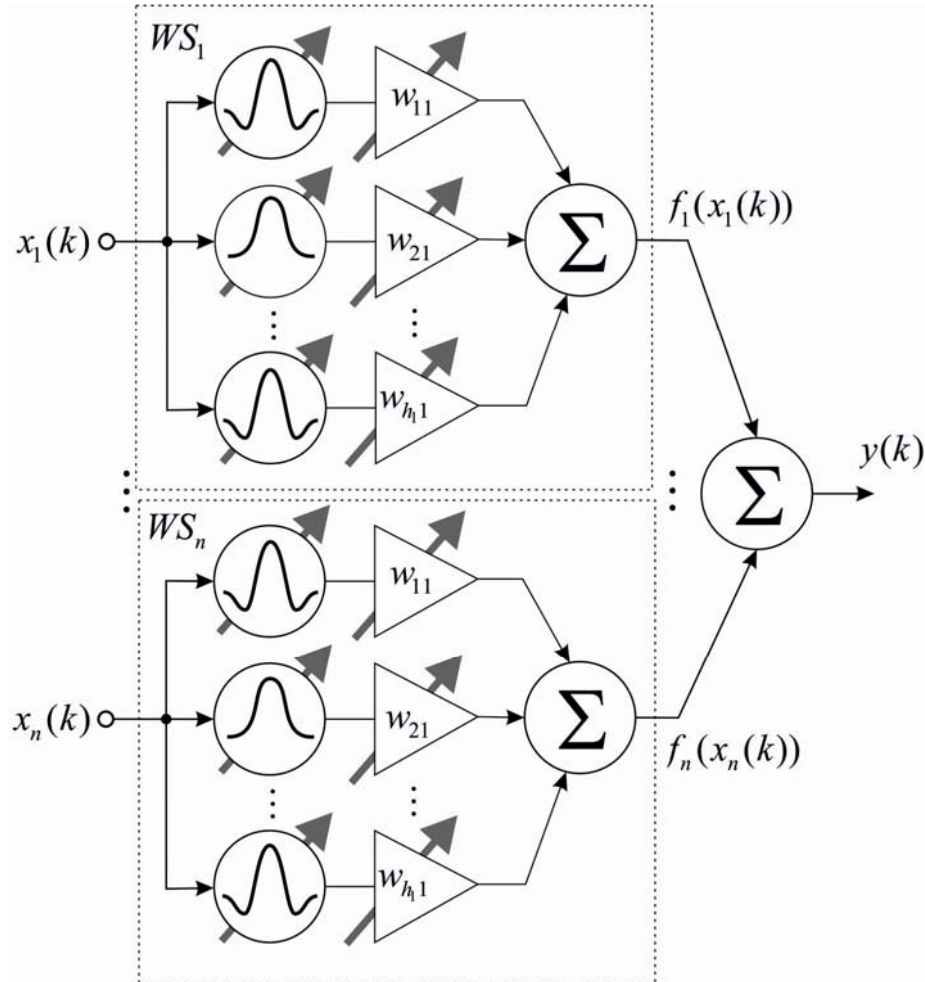


Рис. 3 – Архітектура вейвлет-нейрону

Зауважимо, що вейвлет-нейрон по архітектурі співпадає з нео-фаззі нейроном Т. Ямакави [8], відрізняючись тим, що замість трикутних функцій належності в нелінійних синапсах використовуються парні вейвлети. Разом з тим, як показав Б. Коско [9], використання парних вейвлетів не суперечить ідеям нечіткого висновування, при цьому конкретним значенням вейвлет-функцій може бути надано сенс рівнів належності.

В якості такої функції може бути використано модифікований адаптивний вейвлет [10], що має вигляд

$$\varphi_{ji}(x_i(k)) = (1 - \alpha_{ji}(k)\tau_{ji}^2) \exp\left(-\frac{\tau_{ji}^2(k)}{2}\right), \quad (2)$$

де $\tau_{ji}(k) = (x_i(k) - c_{ji}(k))\sigma_{ji}^{-1}(k)$, $c_{ji}(k), \sigma_{ji}(k)$ - параметри, що визначають положення центру (зсуву) та ширину (розтягнення) і належності деякому інтервалу $\underline{c} \leq c_{ji}(k) \leq \bar{c}$, $\underline{\sigma} \leq \sigma_{ji}(k) \leq \bar{\sigma}$, $0 = \underline{\alpha} \leq \alpha_{ji}(k) \leq \bar{\alpha} = 1$.

На Рис. 4 зображено форму цих вейвлетів, з різними видами невизначеності. Неможна не відмітити близької подібності даних конструкцій з функціями належності типу-2.




Рис.4 – Фаззі-вейвлет функція активації-належності типу-2 (а) невизначеність з ширини, б) невизначеність з центру, в) невизначеність з параметру форми)

В [6] було запропоновано достатньо простий і ефективний алгоритм навчання вейвлет-нейрону, включаючи значення синаптичних ваг, центрів, ширин та параметрів форми, що має вигляд

$$\begin{cases} w_{ji}(k+1) = w_{ji}(k) + \eta^w(k)e(k)(1 - \alpha_{ji}(k)\tau_{ji}(k)) \exp(-\tau_{ji}^2(k)/2), \\ c_{ji}(k+1) = c_{ji}(k) + \eta^c(k)e(k)2w_{ji}(k)\sigma_{ji}^{-1}(k) \cdot \\ \quad \cdot ((2\alpha_{ji} + 1)\tau_{ji}(x(k)) - \alpha_{ji}\tau_{ji}^3(x(k))) \exp(-\tau_{ji}^2(x(k))/2), \\ \sigma_{ji}^{-1}(k+1) = \sigma_{ji}^{-1}(k) + \eta^\sigma(k)e(k)w_{ji}(k) \cdot \\ \quad \cdot (\alpha_{ji}\tau_{ji}^3(x(k)) - (2\alpha_{ji} + 1)\tau_{ji}(x(k))) \exp(-\tau_{ji}^2(x(k))/2)(x(k) - c_{ji}(k)), \\ \alpha_{ji}(k+1) = \alpha_{ji}(k) + \eta^\alpha(k)e(k)w_{ji}(k)\tau_{ji}^2(x(k)) \exp(-\tau_{ji}^2(x(k))/2), \end{cases} \quad (3)$$

де скалярні коефіцієнти $\eta^w(k), \eta^c(k), \eta^\sigma(k), \eta^\alpha(k)$ визначають крок зміщення в просторі параметрів, що настроюються.

Підвищити швидкість збіжності процесів навчання можна, переходячи від градієнтних процедур до алгоритмів другого порядку, серед яких для настроювання нейронних мереж найбільше поширення отримав алгоритм Левенберга-Марквардта [11].

Вводячи $(h_i \times 1)$ - вектори змінних

$$\begin{aligned}\varphi_i(x_i(k)) &= (\varphi_{l_i}(x_i(k)), \dots, \varphi_{h_i}(x_i(k)))^T, \\ w_i(k) &= (w_{l_i}(k), \dots, w_{h_i}(k))^T, \\ c_i(k) &= (c_{l_i}(k), \dots, c_{h_i}(k))^T, \\ \sigma_i^{-1}(k) &= (\sigma_{l_i}^{-1}(k), \dots, \sigma_{h_i}^{-1}(k))^T, \\ \alpha_i(k) &= (\alpha_{l_i}(k), \dots, \alpha_{h_i}(k))^T, \\ \tau_i(k) &= (\tau_{l_i}(k), \dots, \tau_{h_i}(k))^T,\end{aligned}$$

можна отримати алгоритм навчання i -го вейвлет-синапсу:

$$\left\{ \begin{aligned} w_i(k+1) &= w_i(k) + \frac{e(k)\varphi_i(x_i(k))}{\eta^w + \|\varphi_i(x_i(k))\|^2} = w_i(k) + \frac{e(k)\varphi_i(x_i(k))}{\alpha^w(k)}, \\ c_i(k+1) &= c_i(k) + \frac{e(k)\varphi_i^c(x_i(k))}{\eta^c + \|\varphi_i^c(x_i(k))\|^2} = c_i(k) + \frac{e(k)\varphi_i^c(x_i(k))}{\alpha^c(k)}, \\ \sigma_i^{-1}(k+1) &= \sigma_i^{-1}(k) + \frac{e(k)\varphi_i^\sigma(x_i(k))}{\eta^\sigma + \|\varphi_i^\sigma(x_i(k))\|^2} = \sigma_i^{-1}(k) + \frac{e(k)\varphi_i^\sigma(x_i(k))}{\alpha^\sigma(k)}, \\ \alpha_i(k+1) &= \alpha_i(k) + \frac{e(k)\varphi_i^\alpha(x_i(k))}{\eta^\alpha + \|\varphi_i^\alpha(x_i(k))\|^2} = \alpha_i(k) + \frac{e(k)\varphi_i^\alpha(x_i(k))}{\eta^\alpha(k)}, \end{aligned} \right. \quad (4)$$

де

$$\left\{ \begin{aligned} \varphi_i^c(x_i(k)) &= 2w_i(k)\sigma_i^{-1}(k)\left((2\alpha_i + 1)\tau_i(x(k)) - \alpha_i\tau_i^3(x(k))\right)\exp\left(-\tau_i^2(x(k))/2\right), \\ \varphi_i^\sigma(x_i(k)) &= w_i(k)\left(\alpha_i\tau_i^3(x(k)) - (2\alpha_i + 1)\tau_i(x(k))\right) \cdot \\ &\quad \cdot \exp\left(-\tau_i^2(x(k))/2\right)(x(k) - c_i(k)), \\ \varphi_i^\alpha(x_i(k)) &= -w_i(k)\tau_i^2(x(k))\exp\left(-\tau_i^2(x(k))/2\right), \end{aligned} \right. \quad (5)$$

$\tau_i^2(k) = \sigma^{-1}(k) \square \sigma^{-1}(k) \square (x_i(k) - c_i(k)) \square (x_i(k) - c_i(k))$, \square - символ прямого (СКОТТОВА) добутку.

З метою надання алгоритму (4) слідкуючих та фільтруючих властивостей, можна ввести його модифікацію, при цьому параметри $\eta_i^w, \eta_i^c, \eta_i^\sigma, \eta_i^\alpha$ будуть рекурентно обчислюватися на основі процедури, що має вигляд

$$\begin{cases} \eta_i^w(k+1) = \beta \eta_i^w(k) + \|\varphi_i(x_i(k))\|^2, \\ \eta_i^c(k+1) = \beta \eta_i^c(k) + \|\varphi_i^c(x_i(k))\|^2, \\ \eta_i^\sigma(k+1) = \beta \eta_i^\sigma(k) + \|\varphi_i^\sigma(x_i(k))\|^2, \\ \eta_i^\alpha(k+1) = \beta \eta_i^\alpha(k) + \|\varphi_i^\alpha(x_i(k))\|^2, 0 \leq \beta \leq 1 \end{cases} \quad (6)$$

(тут γ - параметр забування застарілої інформації).

Необхідно відмітити, що якщо для навчання синаптичних ваг $w_{ji}(k)$ можна отримати максимально можливу швидкодію, що забезпечується алгоритмами типа Качмажа-Уїдрю-Хоффа або рекурентного методу найменших квадратів, то параметри $c_{ji}(k)$, $\sigma_{ji}(k)$ і $\alpha_{ji}(k)$ настроюються значно повільніше із-за нелінійної залежності вихідного сигналу $y(k)$ від цих значень, при цьому збіжність істотно залежить від прийнятих початкових значень.

В силу цих причин зручно скористатися ідеями нечітких систем типу-2, при цьому процес навчання проходить паралельно при довільних значеннях параметрів функцій $\varphi_{ji}(x_i(k))$.

4. Фаззі-вейвлет-нейрон типу-2

Позначимо фаззі-вейвлет-нейрон, що наведено на Рис. 3 – WN, і введемо до розгляду архітектуру фаззі-вейвлет-нейрону типу-2 (T2-FWN), що зображено на Рис. 5.

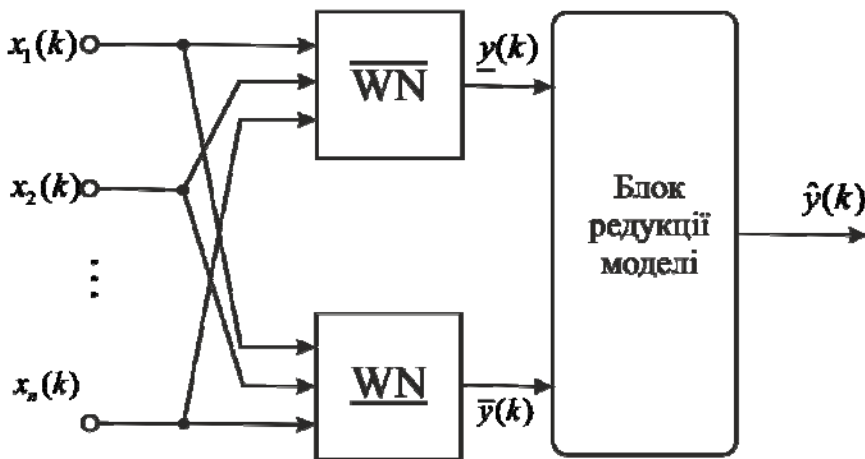


Рис. 5 – Вейвлет-фаззі-нейрон типу-2

Тут \underline{WN} має параметри, що відповідають нижнім межим функцій належності, а \overline{WN} - верхнім. У випадку звичайних (чітких) функцій $\varphi_{ji}(x_i(k))$ вихідні сигнали $\underline{y}(k)$ і $\overline{y}(k)$ звичайно співпадають.

В блоці редукції моделі сигнали $\underline{y}(k)$ і $\overline{y}(k)$ деяким чином об'єднуються та формують оптимальний в сенсі прийнятого критерію вихідний сигнал $\hat{y}(k)$.

Вводячи вихідний сигнал WFN-T2 у формі

$$\hat{y}(k) = c(k)\underline{y}(k) + (1 - c(k))\overline{y}(k) \quad (7)$$

(тут $c(k)$ - параметр, що настраюється, та визначає близькість сигналів $\underline{y}(k)$ і $\overline{y}(k)$ та навчальної послідовності $d(k)$) і глобальний критерій навчання блоку редукції моделі

$$\begin{aligned} \hat{E}(k) &= \sum_{k=1}^N 1/2 \hat{e}^2(k) = \sum_{k=1}^N 1/2 (d(k) - \hat{y}(k))^2 = \\ &= \sum_{k=1}^N 1/2 (d(k) - c(k)\underline{y}(k) - (1 - c(k))\overline{y}(k))^2, \end{aligned} \quad (8)$$

можна записати оптимальний адаптивний алгоритм об'єднання сигналів $\underline{y}(k)$ і $\overline{y}(k)$ у вигляді [12]

$$\begin{cases} \gamma(k+1) = \gamma(k) + (y(k+1) - \overline{y}(k+1))^2, \\ c(k+1) = c(k) \frac{\gamma(k)}{\gamma(k+1)} + \frac{(d(k+1) - \overline{y}(k+1))(y(k+1) - \overline{y}(k+1))}{\gamma(k+1)}. \end{cases} \quad (9)$$

Зрозуміло, що ознакою оптимального навчання є близькість сигналів $\underline{y}(k)$ і $\overline{y}(k)$, «стягнення» нечіткої вейвлет-функції належності типу-2 до звичайної конструкції «Mexican Hat» і наближення параметру $c(k)$ до значення 0.5.

Висновки

В статті запропоновано гібридну еволюційну каскадну МГУА-нейро-фаззі-мережу на базі фаззі-вейвлет-нейрону типу-2. Така мережа об'єднує переваги теорії нейронних мереж та МГУА, що дає змогу вирішення складних задач з підвищеною точністю в реальному часі. Запропоновано в якості вузла такої мережі використовувати фаззі-вейвлет-нейрон типу-2 з фаззі-вейвлетами,

параметри яких настроюються в процесі навчання. Експериментальне моделювання підтверджує ефективність та доцільність запропонованого підходу.

Література

1. Ивахненко А.Г. Долгосрочное прогнозирование и управление сложными системами. - Киев: Техніка, 1975. - 311 с.
2. Ивахненко А.Г., Степашко В.С. Помехоустойчивость моделирования. – К.: Наукова думка, 1984. – 295 с.
3. Бодянский Е.В., Руденко О.Г. Искусственные нейронные сети: архитектуры, обучение, применения. – Телетех: Харьков. – 2004. – 372 с.
4. Bodyanskiy Ye., Pliss I., Vynokurova O. Hybrid GMDH-neural network of computational intelligence // Proc. 3rd International Workshop on Inductive Modelling, Poland, Krynica – 2009. – CD. – 8 p.
5. Bodyanskiy Ye. Hybrid radial-basis neuro-fuzzy wavelon in the non-stationary sequences forecasting problems / Ye. Bodyanskiy, O. Vynokurova // Proc. 2nd Int. Conf. on Inductive Modeling. – Kyiv. 2008.– P.144-147.
6. Бодянский Е.В., Винокурова Е.А. Адаптивный вэйвлет-нейронный предиктор // Проблемы бионики. – 2003. - Вып. 58. - С. 10-17.
7. Ivakhnenko A.G., Ivakhnenko G.A., Müller J.-A. Self-organization of neural networks with active neurons // Pattern Recognition and Image Analysis. - 1994. - 4(2). - P. 185-196.
8. Yamakawa T., Uchino E., Miki T., Kusanagi H. A neo-fuzzy neuron and its application to system identification and prediction of the system behavior // Proc. 2nd Int. Conf. on Fuzzy Logic and Neural Networks, IIZUKA-92, Iizuka, Japan, 1992. - vol. II. - P. 477-483.
9. Mitaim S., Kosko B. Adaptive joint fuzzy sets for function approximation // Proc. Int. Conf. on Neural Networks. – 1997. - P. 537-542.
10. Бодянский Е.В., Винокурова Е.А. Вэйвлет-нейро-фаззи система типа-2 и алгоритм ее обучения в задачах интеллектуальной обработки информации // Адаптивные системы автоматического управления. – Киев: НТУУ «КПИ». - 2010. - 17(37). - С. 139-148.
11. Shepherd A. J. Second-Order Methods for Neural Networks - London: Springer-Verlag, 1997. – 145 p.
12. Бодянский Е. В., Михальов О. І., Плісс І. П. Адаптивне виявлення розладнань в об'єктах керування за допомогою штучних нейронних мереж. - Дніпропетровськ: Системні технології, 2000. – 140 с.