

АДАПТИВНИЙ W-НЕЙРОН ТА ЙОГО НАВЧАННЯ В ЗАДАЧАХ ПРОГНОЗУВАННЯ І ВИЯВЛЕННЯ РОЗЛАДНАНЬ

© Бодянський Є., Винокурова О., 2012

Розглянуто структуру адаптивного W-нейрона та його метод навчання. Запропонований алгоритм навчання має підвищену швидкість збіжності та забезпечує покращені апроксимуючі властивості за рахунок настроювання усіх параметрів вейвлет-функцій. Введена підсистема виявлення розладнань для W-нейрона, що дає змогу розв'язувати задачі діагностування в on-line режимі стохастичних процесів.

Ключові слова: W-нейрон, методи навчання, прогнозування, виявлення розладнань.

Adaptive W-neuron and its learning algorithm are considered. Proposed learning algorithm has increased convergence rate and provides improved approximative properties because of the all wavelet parameters tuning. The fault detection subsystem for W-neuron that allows to solve a stochastic process diagnosing problems in on-line mode.

Key words: W-neuron, learning algorithm, prediction, fault detection.

Вступ

Сьогодні штучні нейронні мережі набули поширення для розв'язання великого класу задач обробки інформації – насамперед для ідентифікації, емуляції, інтелектуального керування, прогнозування часових рядів довільної природи за умов структурної та параметричної невизначеності.

Ще однією важливою задачею є виявлення розладнань у довільного типу стохастичних процесах, що тісно пов'язана з проблемою діагностування об'єктів і систем різного призначення. Останні роки характеризуються сплеском досліджень у галузі діагностуючих нейронних мереж, що засновані переважно на багат шарових архітектурах.

Альтернативою традиційним багат шаровим мережам з сигмоїдальними функціями активації є радіально-базисні нейронні мережі, що мають один прихований шар, що складається із так званих R-нейронів, при цьому навчання цих мереж реалізується на рівні вихідного шару, який складається із лінійних асоціаторів [1–5]. На відміну від P-нейронів з сигмоїдальною функцією активації, R-нейрони мають, як правило, дзвонувату функцію активації $f_j(x)$, аргументом якої є відхилення (зазвичай у метриці Евкліда) між поточним значенням сигналу на вході $x(k)$ і центром c_j – j-го нейрону. Основною перевагою радіально-базисних мереж є висока швидкість навчання у вихідному шарі, що визначається тим, що налаштовувані параметри входять до опису мережі лінійно. Водночас залишається відкритою проблема розташування центрів R-нейронів, невдале вирішення якої призводить до виникнення «прокляття розмірності».

Поряд з нейронними мережами для обробки сигналів довільної природи достатньо часто використовується вейвлет-перетворення [7–9], що забезпечує компактне локальне подання сигналів як в частотній, так і в часовій областях. На стику теорії штучних нейронних мереж і вейвлетів виникли вейвлет-нейронні мережі [10–18], що підтвердили свою ефективність в задачах обробки нестационарних нелінійних сигналів і процесів.

У статті розглянуто питання синтезу адаптивного W-нейрона та його метод (алгоритм) навчання, що має підвищену швидкість збіжності та забезпечує покращені апроксимуючі властивості в задачах прогнозування і виявлення розладнань стохастичних послідовностей.

Архітектура адаптивного W-нейрона

Розглянемо структуру адаптивного W-нейрона, наведену на рис. 1, яка збігається по суті з радіально-базисною нейронною мережею з одним виходом.




Рис. 1. Архітектура адаптивного W-нейрона

Нульовий шар архітектури є рецепторним і в поточний момент дискретного часу k на нього або подається сигнал у формі вектора $x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T$, або формується вектор входів за допомогою елементів затримки вхідного сигналу. Прихований шар, на відміну від радіально-базисних мереж, складається не із R -нейронів, а із вейвлонів з багатовимірними активаційними функціями-вейвлетами вигляду

$$\varphi_j(x(k)) = \varphi_j\left((x(k) - c_j)^T Q_j^{-1}(x(k) - c_j)\right), \quad j=1, 2, \dots, h, \quad (1)$$

в яких замість параметрів ширин σ_{ji} використовується матриця Q_j^{-1} , тобто використовується не евклідова метрика, а відстань Ітакури–Сайто [19]. Це приводить до того, що рецепторні поля W-нейронів (1) можуть мати довільну орієнтацію відносно координатних осей простору X , що розширює функціональні можливості адаптивного W-нейрона.

На основі вейвлет-функції «Mexican Hat» [8] введемо налаштовувану активаційну функцію у структуру адаптивного W-нейрона, що має вигляд [20, 21]:

$$\varphi_j(x(k)) = (1 - \alpha_j \tau_j^2) \exp\left(-\frac{\tau_j^2}{2}\right), \quad (2)$$

де $\tau_j(x(k)) = \left((x(k) - c_j(k))^T Q_j^{-1}(k)(x(k) - c_j(k))\right)$, α_j – налаштовуваний параметр ($0 \leq \alpha \leq 1$).

Параметр α_j дає змогу налаштовувати форму активаційної функції у процесі навчання адаптивного W-нейрона, при цьому при $\alpha = 0$ маємо гауссову функцію активації, при $\alpha = 1$ маємо вейвлет-функцію «Mexican Hat», а при $0 < \alpha < 1$ – гібридну функцію активації. На рис. 2 наведені форми двовимірної активаційної функції W-нейронів (2) при довільних матрицях Q_j^{-1} і параметрі α_j .

І, нарешті, вихід W-нейрона – це звичайний адаптивний лінійний асоціатор із синаптичними вагами w_j , що налаштовуються:

$$\hat{y}(k) = w_0 + \sum_{j=1}^h w_j \varphi\left((x(k) - c_j) Q_j^{-1} (x(k) - c_j)\right) = w^T \varphi(x(k)), \quad (3)$$

де $\varphi_0(x(k)) \equiv 1$, $w = (w_0, w_1, w_2, \dots, w_h)^T$, $\varphi(x(k)) = (1, \varphi_1(x(k)), \varphi_2(x(k)), \dots, \varphi_h(x(k)))^T$.




Рис. 2. Активаційні функції W-нейронів при довільних матрицях Q_j^{-1} і параметрі α

Налаштовуваними параметрами структури адаптивного W-нейрона, що підлягають визначенню в процесі навчання, є $h+1$ синаптичних ваг w_j , h ($n \times 1$) – параметрів векторів c_j , h ($n \times n$) – елементів матриць Q_j^{-1} і h параметрів α_j .

Метод навчання адаптивного W-нейрона

Оскільки $(h+1) \times 1$ вектор синаптичних ваг w входить до опису мережі лінійно, для його уточнення може використовуватися будь-який із алгоритмів адаптивної ідентифікації [22] і насамперед традиційний рекурентний метод найменших квадратів:

$$\begin{cases} w(k+1) = w(k) + \frac{P(k)(y(k) - w^T(k)\varphi(x(k)))\varphi(x(k))}{1 + \varphi^T(x(k))P(k)\varphi(x(k))}, \\ P(k+1) = P(k) - \frac{P(k)\varphi(x(k+1))\varphi^T(x(k+1))P(k)}{1 + \varphi^T(x(k+1))P(k)\varphi(x(k+1))}, \end{cases} \quad (4)$$

що має згладжувальні властивості.

Для налаштування параметрів W-нейронів (векторів c_j , матриць Q_j^{-1} , параметрів α_j) використовуватимемо градієнтну мінімізацію локального критерію навчання

$$E(k) = \frac{1}{2} e^2(k) = \frac{1}{2} (y(k) - \hat{y}(k))^2, \quad (5)$$

при цьому на відміну від покомпонентного навчання, що розглянуто у [6], будемо проводити уточнення у векторно-матричній формі, що, по-перше, простіше з обчислювального погляду, а, по-друге, дає змогу оптимізувати процес навчання за швидкодією.

У загальному випадку алгоритм навчання можна записати у вигляді

$$\begin{cases} c_j(k+1) = c_j(k) - \eta_{c_j} \nabla_{c_j} E(k), \quad j=1,2,\dots,h, \\ Q_j^{-1}(k+1) = Q_j^{-1}(k) - \eta_{Q_j^{-1}} \left\{ \frac{\partial E(k)}{\partial Q_j^{-1}} \right\}, \quad j=1,2,\dots,h, \\ \alpha(k+1) = \alpha(k) - \eta_{\alpha} \nabla_{\alpha} E(k), \end{cases} \quad (6)$$

де $\nabla_{c_j} E$, $\nabla_{\alpha} E$ – $(n \times 1)$ -вектори-градієнти критерію (5) за c_j та α відповідно; $\alpha(k) = (\alpha_1(k), \alpha_2(k), \dots, \alpha_h(k))$; $\left\{ \frac{\partial E(k)}{\partial Q_j^{-1}} \right\}$ – $(n \times n)$ -матриця, що складається з частинних похідних E за компонентами Q_j^{-1} ; η_{c_j} , $\eta_{Q_j^{-1}}$ і η_{α} – параметри кроку алгоритму навчання.

Для функції активації (2) можна записати

$$\begin{cases} \nabla_{c_j} E(k) = 2e(k)w_j(k)Q_j^{-1}(k)(x(k) - c_j(k)) \cdot \\ \cdot \left(\alpha_j \tau_j^3(x(k)) - (2\alpha_j + 1)\tau_j(x(k)) \right) \exp(-\tau_j^2(x(k))/2) = e(k)J_{c_j}(k), \\ \left\{ \frac{\partial E(k)}{\partial Q_j^{-1}} \right\} = e(k)w_j(k)(x(k) - c_j(k))(x(k) - c_j(k))^T \cdot \\ \cdot \left(\alpha_j \tau_j^3(x(k)) - (2\alpha_j + 1)\tau_j(x(k)) \right) \exp(-\tau_j^2(x(k))/2) = -e(k)J_{Q_j^{-1}}(k), \\ \nabla_{\alpha} E(k) = -e(k)w(k) \odot \tau^2(x(k)) \odot \exp(-\tau^2(x(k))/2) = -e(k)J_{\alpha}(k). \end{cases} \quad (7)$$

де $\tau(x(k)) = (\tau_1(x(k)), \tau_2(x(k)), \dots, \tau_h(x(k)))^T$; $\tau^2(x(k)) = \tau(x(k)) \odot \tau(x(k))$; \odot – прямий (скотовий) добуток.

Тоді алгоритм навчання W-нейрона з урахуванням (7) має вигляд

$$\begin{cases} c_j(k+1) = c_j(k) - \eta_{c_j} e(k)J_{c_j}(k), \\ Q_j^{-1}(k+1) = Q_j^{-1}(k) + \eta_{Q_j^{-1}} e(k)J_{Q_j^{-1}}(k), \\ \alpha(k+1) = \alpha(k) + \eta_{\alpha} e(k)J_{\alpha}(k), \end{cases} \quad (8)$$

при цьому швидкість збіжності до оптимальних значень c_j і Q_j^{-1} повністю визначається параметрами кроку η_{c_j} і $\eta_{Q_j^{-1}}$.

Підвищити швидкість збіжності можна, використовуючи складніші, ніж градієнтні, процедури типу Хартлі або Марквардта, що для налаштування параметрів c_j і α можуть бути записані в загальній формі [21]

$$\begin{cases} c_j(k+1) = c_j(k) - \lambda_c (J_{c_j}(k)J_{c_j}^T(k) + \eta_c I)^{-1} J_{c_j}(k)e(k), \\ \alpha(k+1) = \alpha(k) + \lambda_{\alpha} (J_{\alpha}(k)J_{\alpha}^T(k) + \eta_{\alpha} I)^{-1} J_{\alpha}(k)e(k), \end{cases} \quad (9)$$

де I – $(n \times n)$ – одинична матриця; $\lambda_c, \lambda_{\alpha}$ – додатні параметри; η_c, η_{α} – параметри регуляризації.

Використовуючи лему обернення матриць, після достатньо простих перетворень можна отримати простий і ефективний алгоритм навчання центрів W-нейронів і параметра a у вигляді

$$\begin{cases} c_j(k+1) = c_j(k) - \lambda_c \frac{e(k)J_{c_j}(k)}{\eta_c + \|J_{c_j}(k)\|^2}, \\ \alpha(k+1) = \alpha(k) + \lambda_{\alpha} \frac{e(k)J_{\alpha}(k)}{\eta_{\alpha} + \|J_{\alpha}(k)\|^2} \end{cases} \quad (10)$$

з точністю до позначення, що збігається з оптимальним (при $\lambda_c = 1, \eta_c = 0, \lambda_{\alpha} = 1, \eta_{\alpha} = 0$) за швидкодією алгоритмом Качмажа–Уїдроз–Гоффа.

Для налаштування матриць Q_j^{-1} можна скористатися матричною модифікацією алгоритму (10) у вигляді [21]

$$Q_j^{-1}(k+1) = Q_j^{-1}(k) + \lambda_{Q_j^{-1}} \frac{e(k)J_{Q_j^{-1}}(k)}{\eta_{Q_j^{-1}} + \text{Tr}(J_{Q_j^{-1}}^T(k)J_{Q_j^{-1}}(k))}, \quad (11)$$

де $\lambda_{Q_j^{-1}}$, $\eta_{Q_j^{-1}}$ мають те саме значення, що і відповідні параметри в (9).

Отже, алгоритм навчання параметрів W-нейронів прихованого шару в оптимальному за швидкістю варіанті можна записати у формі

$$\begin{cases} c_j(k+1) = c_j(k) - \|J_{c_j}(k)\|^{-2} e(k)J_{c_j}(k), \quad j=1,2,\dots,h, \\ Q_j^{-1}(k+1) = Q_j^{-1}(k) + \left(\text{Tr}(J_{Q_j^{-1}}^T(k)J_{Q_j^{-1}}(k)) \right)^{-1} e(k)J_{Q_j^{-1}}(k), \quad j=1,2,\dots,h, \\ \alpha(k+1) = \alpha(k) + \|J_\alpha(k)\|^{-2} e(k)J_\alpha(k). \end{cases} \quad (12)$$

Відомо, що однокрокові алгоритми типу Качмажа, маючи високу швидкість, не мають фільтрувальних властивостей, тобто погано працюють за умов інтенсивних збурень та завад. Для надання процесу навчання згладжувальних властивостей використовують підхід, запропонований у [24], і можна ввести таку процедуру навчання, включаючи і вектор синаптичних ваг:

$$\begin{cases} w(k+1) = w(k) - \lambda_w \frac{e(k)J_w(k)}{\eta_w(k)}, \quad \eta_w(k+1) = \gamma_w \eta_w(k) + \|J_w(k+1)\|^2, \\ c_j(k+1) = c_j(k) - \lambda_{c_j} \frac{e(k)J_{c_j}(k)}{\eta_{c_j}(k)}, \quad \eta_{c_j}(k+1) = \gamma_c \eta_{c_j}(k) + \|J_{c_j}(k+1)\|^2, \\ Q_j^{-1}(k+1) = Q_j^{-1}(k) + \lambda_{Q_j^{-1}} \frac{e(k)J_{Q_j^{-1}}(k)}{\eta_{Q_j^{-1}}(k)}, \quad \eta_{Q_j^{-1}}(k+1) = \gamma_{Q_j^{-1}} \eta_{Q_j^{-1}}(k) + \text{Tr}\left(J_{Q_j^{-1}}^T(k+1)J_{Q_j^{-1}}(k+1) \right), \\ \alpha(k+1) = \alpha(k) + \lambda_\alpha \frac{e(k)J_\alpha(k)}{\eta_\alpha(k)}, \quad \eta_\alpha(k+1) = \gamma_\alpha \eta_\alpha(k) + \|J_\alpha(k+1)\|^2, \end{cases} \quad (13)$$

(тут $0 \leq \gamma_w \leq 1$, $0 \leq \gamma_c \leq 1$, $0 \leq \gamma_{Q_j^{-1}} \leq 1$, $0 \leq \gamma_\alpha \leq 1$ – параметри зважування застарілої інформації), яка є нелінійним гібридом алгоритму Качмажа–Уїдроу–Гоффа і Гудвіна–Ремеджа–Кейнеса і має як слідкувальні, так і фільтрувальні властивості.

Підсистема виявлення розладів у стохастичних послідовностях

Алгоритм навчання (13) призначено для налаштування усіх параметрів адаптивного W-нейрона в задачах обробки нестационарних зашумлених сигналів, при цьому що більше значення параметрів зважування γ , то яскравіші згладжувальні властивості, а наявність різких змін потребує зменшення значення γ – скорочення пам'яті алгоритму.

У зв'язку з цим уявляється доцільним введення в прогнозувальну систему на основі адаптивного W-нейрона додаткової підсистеми виявлення розладів, що дає змогу у on-line режимі виявляти різкі зміни у контрольованому сигналі. Для цього можна скористатися діагностуючим алгоритмом Т. Хеглунда [25], що у прийнятих нами позначеннях набуває вигляду

$$\begin{cases} \theta(k+1) = \lambda_\theta \theta(k) + w(k+1) - w(k) = \lambda_\theta \theta(k) + \Delta w(k+1), \quad 0 \leq \lambda_\theta < 1, \\ T(k+1) = \text{sign}(\theta^T(k+1)\Delta w(k+1)). \end{cases} \quad (14)$$

При цьому поява на декількох тактах контролю підряд значення діагностуючого сигналу $T(k+1)=1$ свідчить про розлад. У цьому випадку значення параметрів зважування застарілої

інформації повинні бути зменшені на деяке значення $\Delta\gamma$. Якщо ж діагностувальний сигнал $T(k+1)$ змінює свої знаки, то параметри зважування можуть бути збільшені, що, своєю чергою, покращує фільтрувальні властивості алгоритму.

Структурну схему підсистеми виявлення розладів з W-нейроном на основі алгоритму (14) наведено на рис. 3.

Задачу прогнозування та виявлення розладів у стохастичних послідовностях за допомогою підходу, що розвивається, можна розв'язати на основі адаптивного W-нейрона, у якого нульовий шар утворюється лінією елементів чистого запізнювання z^{-1} (як показано на рис. 3), а поточні значення синаптичних ваг, що обчислюються у вихідному шарі, подаються у підсистему виявлення розладів, що керує зміною параметрів зважування застарілої інформації.

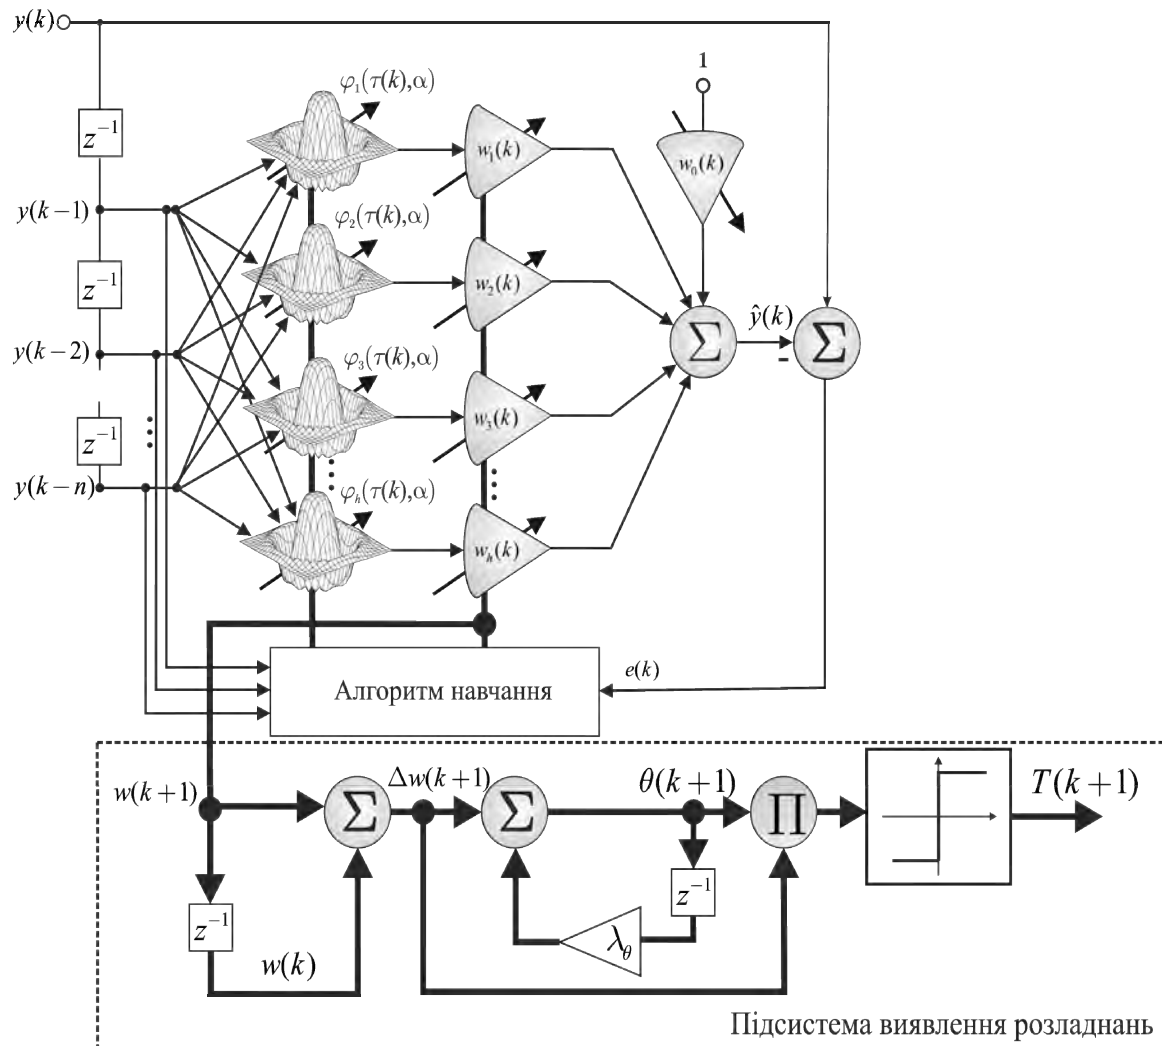


Рис. 3 – Структура W-нейрона з діагностувальною підсистемою

Висновки

Запропоновано простий та ефективний алгоритм навчання адаптивного W-нейрона, що має як слідкувальні, так і фільтрувальні властивості і дає змогу у on-line режимі обробляти нестационарні нелінійні сигнали та процеси. Структуру адаптивного W-нейрона можна використати і як самостійну мережу, і як елемент складнішої нейро-фаззи системи. Налаштуванням усіх параметрів W-нейрона покращено апроксимувальні властивості мережі. Для розв'язання задачі виявлення розладів в on-line режимі у стохастичних послідовностях до структури W-нейрону введено діагностувальну підсистему. Імітаційне моделювання підтверджує ефективність запропонованого підходу порівняно з відомими системами прогнозування та діагностування.

1. Moody J., Darken C. J. Fast learning in networks of locally-tuned processing units // *Neural Computation*. – 1989. – 1. – P. 281–294. 2. Park J., Sandberg I. W. Universal approximation using radial-basis-function networks // *Neural Computation*. – 1991. – 3. – P. 246–257. 3. Leonard J. A., Kramer M. A., Ungar L. H. Using radial basis functions to approximate a function and its error bounds // *IEEE Trans. on Neural Networks*. – 1992. – 3. – P. 614–627. 4. Sunil E. V. T., Yung C. Sh. Radial basis function neural network for approximation and estimation of nonlinear stochastic dynamic systems // *IEEE Trans. on Neural Networks*. – 1994. – 5. – P. 594–603. 5. Poggio T., Girosi F. A Theory of Networks for Approximation and Learning // A. I. Memo № 1140, C.B.I.P. Paper № 31. – Massachusetts Institute of Technology, 1994. – 63 p. 6. Bishop C. M. *Neural Networks for Pattern Recognition*. – Oxford: Clarendon Press, 1995. – 482 p. 7. Chui C. K. *An Introduction to Wavelets*. – New York: Academic, 1992. – 264 p. 8. Daubechies I. *Ten Lectures on Wavelets*. – Philadelphia, PA: SIAM., 1992. – 228 p. 9. Meyer Y. *Wavelets: Algorithms and Applications*. – Philadelphia, PA: SIAM., 1993. – 133 p. 10. Billings S. A., Wei H.-L. A new class of wavelet networks for nonlinear system identification // *IEEE Trans. on Neural Networks*. – 16 (4). – 2005. – P. 862–874. 11. Zhang Q. H., Benveniste A. Wavelet networks // *IEEE Trans. on Neural Networks*. – 3 (6). – 1992. – P. 889–898. 12. Zhang J., Walter G. G., Miao Y., Lee W. N. W. Wavelet neural networks for function learning // *IEEE Trans. on Signal Process.* – 43(6). – 1995. – P. 1485–1497. 13. Zhang Q. H. Using wavelet network in nonparametric estimation // *IEEE Trans. on Neural Networks*. – 8(2). – 1997. – P. 227–236. 14. Bodyanskiy Ye., Pavlov O., Vynokurova O. Outliers resistant learning algorithm for radial-basis-fuzzy-wavelet-neural network in stomach acute injury diagnosis tasks // Eds. by K.Markov, K.Ivanova, I.Mitov. – International Book Series “Information Science and Computing”, Number 2. – Sofia: Institute of Information Theories and Application FOI ITHEA, 2008. – P.55–62. 15. Bodyanskiy Ye., Pliss I., Vynokurova O. Adaptive wavelet-neuro-fuzzy network in the forecasting and emulation tasks // *Int. Journal on Information Theory and Applications*. – 2008. – V. 15. – 1. – P. 47–55. 16. Bodyanskiy Ye., Vynokurova O. Robust learning algorithm for wavelet-neural fuzzy network based on Polywog wavelet // *Системные технологии*. – 2008. – Т.2. – № 3(56). – С. 129–134. 17. Бойко В. В., Бодянский Е. В., Винокурова Е. А., Сушков С. В., Павлов А. А. Анализ клинических данных в медицинских исследованиях на основе методов вычислительного интеллекта. – Харків: ТО Ексклюзив, 2008. – 120 с. 18. Reyneri L. M. Unification of neural and wavelet networks and fuzzy systems // *IEEE Trans. on Neural Networks*. – 1999. – 10. – P. 801-814. 19. Itakura F. Maximum prediction residual principle applied to speech recognition // *IEEE Trans. on Acoustics, Speech, and Signal Processing*. – 1975. – 23. – P. 67–72. 20. Бодянский Е.В., Винокурова Е.А. Составной адаптивный взйвлон и алгоритм его обучения // *Управляющие системы и машины*. – 2009. – 1 (219). – С. 47–53. 21. Bodyanskiy Ye., Vynokurova O., Yegorova E. Radial-basis-fuzzy-wavelet-neural network with adaptive activation-membership function // *ICGST Int. J. on Artificial Intelligence and Machine Learning (AIML)*. – 2008. – 8. – II. – P. 9–15. 22. Льюнг Л. Идентификация систем. Теория для пользователя. – Москва: Наука. ГРФМЛ, 1991. – 432 с. 23. Бодянский Е. В. Адаптивные алгоритмы идентификации нелинейных объектов управления // *АСУ и приборы автоматизики*. – Харьков: Выща шк., 1987. – Вып. 81. – С. 43–46. 24. Bodyanskiy Ye., Kolodyazhniy V., Stephan A. An adaptive learning algorithm for a neuro-fuzzy network / Ed. by B. Reusch "Computational Intelligence. Theory and Applications." – Berlin – Heidelberg – New York: Springer, 2001. – P. 68–75. 25. Hagglund T. Adaptive control of systems subject to large parameter changes // *Proc. IFAC 9-th Triennial WorldCongress*. – Budapest, 1984. – P. 993–998.